ПОВЫШЕНИЕ ЭНЕРГОЭФФЕКТИВНОСТИ СИСТЕМ HVAC МЕТОДАМИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Бехруз Азам[1], Шерзод Алимов[1], Владимир Фролов[1], Глеб Алшански[1], Султан Мурзабеков[1]

[1]ООО "Smart Energy"
E-mail: contact@smartenergy.uz

K E Y W O R D S

Системы HVAC, искусственный интеллект, энергоэффективность, коммерческие здания, модельно-прогнозное управление (MPC), обучение с подкреплением (RL), качество внутреннего воздуха, BMS, гибридное управление

A B S T R A C T

Статья посвящена проблеме повышения энергоэффективности систем отопления, вентиляции и кондиционирования воздуха (HVAC) в крупных коммерческих зданиях. Рассматривается разработка и внедрение платформы управления на базе искусственного интеллекта (ИИ), интегрируемой в существующую систему диспетчеризации здания (BMS). Предложен гибридный алгоритм управления, объединяющий подходы модельно-прогнозного управления (MPC), обучения с подкреплением (RL) и эвристики Trim&Respond, что позволяет решать многокритериальную задачу оптимизации: минимизацию энергопотребления при строгом соблюдении нормативов по тепловому комфорту и качеству воздуха (IAQ). Эффективность подхода продемонстрирована в ходе пилотного внедрения в крупном торгово-развлекательном центре. Результаты показывают снижение потребления электроэнергии системами вентиляции на 23% относительно базового сценария при сохранении концентрации CO_2 и температуры в пределах нормативных диапазонов. Полученные данные сопоставлены с международными бенчмарками, подтверждая перспективность применения гибридных AI-стратегий без капитальной модернизации оборудования.

1. Введение

Системы отопления, вентиляции и кондиционирования воздуха (HVAC) являются одним из ключевых источников энергопотребления в крупных коммерческих зданиях и одновременно отвечают за соблюдение требований к тепловому комфорту и качеству внутреннего воздуха. Для торгово-развлекательных и многофункциональных объектов характерны выраженная нестационарность нагрузок (переменная посещаемость, неоднородные внутренние тепловлаговыделения, сложная зональность), из-за чего эффективность управления HVAC существенно зависит от способности системы адаптироваться к текущему режиму эксплуатации.

На практике в эксплуатируемых зданиях часто доминируют фиксированные уставки и расписания, а корректировки выполняются вручную и реактивно. При наличии BMS/BEMS значительная часть доступных измерений (температура, влажность, CO_2, индикаторы занятости, погодные данные) используется ограниченно и не формирует единый контур принятия решений, что приводит к избыточному энергопотреблению при нестабильном качестве микроклимата.

Современные исследования по AI-управлению HVAC демонстрируют потенциал двузначной экономии: мета-анализы указывают снижение энергопотребления HVAC до порядка ~40% в зависимости от типа здания и алгоритма, а для суммарного энергопотребления здания приводятся диапазоны экономии 5–58%. При этом в литературе подчёркивается разрыв между

© Б.Азам, Ш.Алимов, В.Фролов, Г.Алшански, С.Мурзабеков

результатами в моделях/симуляциях и устойчивыми полевыми эффектами, а также дефицит качественных, стандартизованных данных по реальным объектам, особенно для крупных коммерческих зданий с переменной занятостью.

В настоящей работе рассматривается AI-платформа управления HVAC, интегрируемая поверх существующей BMS/BEMS, и предлагается гибридная стратегия, объединяющая MPC-класс проверки ограничений, RL-оптимизацию и эвристику Trim&Respond для безопасного старта и накопления данных. Показана промышленная применимость подхода на пилотном внедрении в крупном торгово-развлекательном центре: зафиксировано снижение потребления электроэнергии системами вентиляции на 23% относительно базового режима при сохранении температуры и концентрации CO_2 в нормативных диапазонах.

Основные вклады статьи:

1. формализация многокритериальной постановки управления HVAC (энергия/стоимость/комфорт/IAQ/плавность) с явным учётом нормативных ограничений и метрик качества внутренней среды
2. описание архитектуры AI-слоя, надстраиваемого над BMS и использующего штатные каналы данных и управления без капитальной модернизации
3. результаты полевого внедрения с количественной оценкой энергоэффекта и соблюдения ограничений по микроклимату и IAQ

Дальнейшая структура статьи организована следующим образом: далее кратко рассматривается состояние исследований и практик AI-управления HVAC и формулируются ключевые ограничения существующих подходов; затем описываются постановка задачи и метод управления (включая гибридную схему), архитектура платформы и протокол эксперимента; в заключение приводятся результаты и обсуждение применимости решения в промышленной эксплуатации.

2. Обзор литературы

2.1. AI для энергосбережения в зданиях и HVAC

Систематические обзоры и мета-анализы по AI в зданиях показывают, что переход от статических уставок и простых эвристик к прогнозно-адаптивному управлению даёт значимый потенциал экономии энергии при сохранении (или улучшении) показателей микроклимата. Для HVAC в разных типах зданий в обзорах фиксируются снижения потребления вплоть до порядка десятков процентов, а для суммарного энергопотребления здания — широкий диапазон эффектов, зависящий от архитектуры BEMS и выбранных алгоритмов.

Однако литература подчёркивает устойчивые барьеры внедрения: (i) дефицит качественных и стандартизованных датасетов по реальным коммерческим объектам, особенно при переменной занятости; (ii) разрыв между результатами симуляций и стабильными полевыми эффектами из-за эксплуатационных ограничений, требований нормативов и ограниченного доверия операторов. Эти факторы смещают фокус исследований от «алгоритмической оптимальности в вакууме» к инженерной воспроизводимости, контролю рисков и интеграции в существующие контуры BMS/BEMS.

2.2. Сравнительный анализ традиционных методов управления (MPC, T&R, RL)

Несмотря на зрелость MPC в академической литературе и понятность эвристик T&R в инженерной практике, ни один из «чистых» подходов не закрывает одновременно требования коммерческого объекта: многозонность, переменная занятость, неполные/шумные данные, жёсткие ограничения по комфорту/IAQ и потребность в объяснимости решений.

MPC силён тем, что естественно учитывает ограничения и формализует многокритериальность (энергия/стоимость/комфорт/IAQ), но его

переносимость на реальные объекты ограничивают необходимость калибровки модели под конкретное здание, чувствительность к ошибкам модели и измерений, вычислительные затраты при росте размерности и горизонта, а также ограниченная гибкость при структурных изменениях объекта.

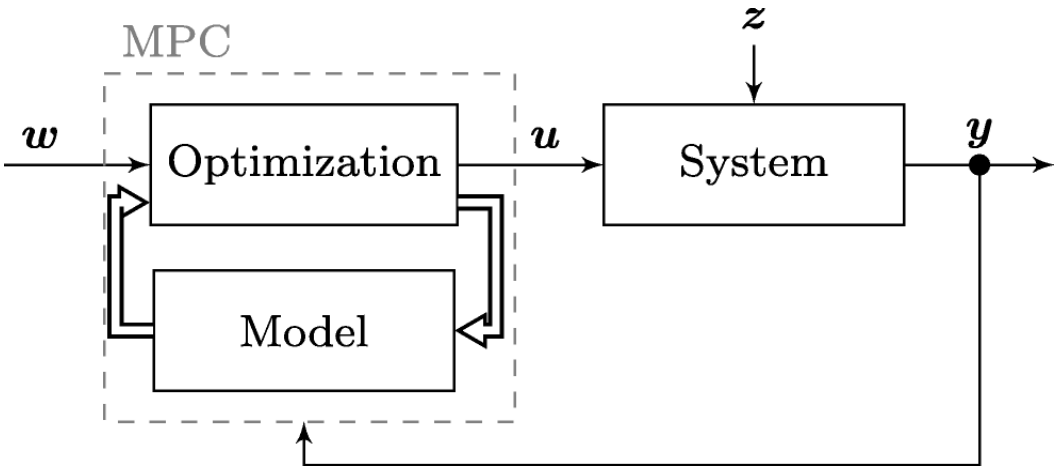


Рис. 2.1. Иллюстрация принципа работы алгоритма Model Predictive Control (MPC).

Trim&Respond (T&R) ценен как надёжная и интерпретируемая baseline-политика (простая эксплуатационная логика и предсказуемое поведение), но остаётся эвристикой: результат существенно зависит от настройки параметров trim/respond и может деградировать при нерегулярной занятости и неоднородных требованиях зон. Ключевой недостаток — отсутствие систематической оптимизации по многокритериальной цели и слабое использование исторических данных.

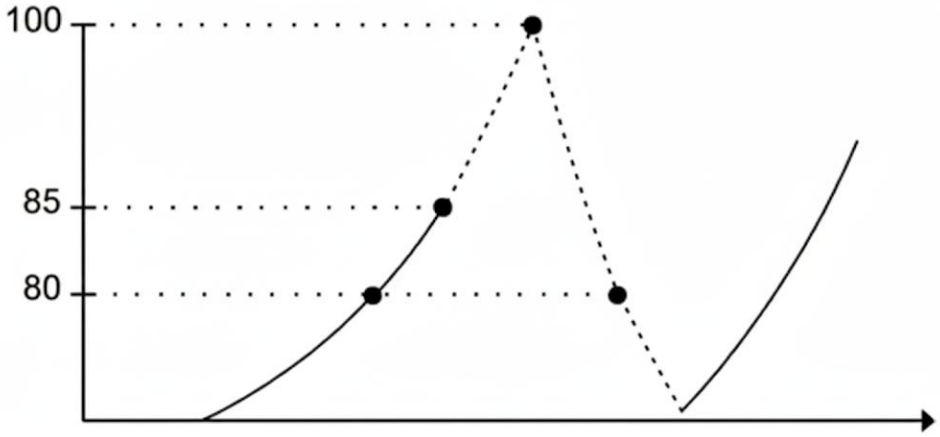


Рис. 2.2. Иллюстрация принципа работы алгоритма Trim&Respond.

Reinforcement Learning (RL) потенциально извлекает объект-специфические закономерности и может улучшать энергоэффективность, но в литературе акцентируются риски и ограничения практического применения: высокая чувствительность к данным и инициализации, необходимость длительного обучения и тщательной настройки функции вознаграждения, проблемы безопасности online-обучения, а также вопросы интерпретируемости и доверия эксплуатации к «чёрному ящику». Поэтому в практических внедрениях RL часто применяют в гибридных схемах и пропускают управляющие действия через «safety layer»/валидацию ограничений.

© Б.Азам, Ш.Алимов, В.Фролов, Г.Алшански, С.Мурзабеков

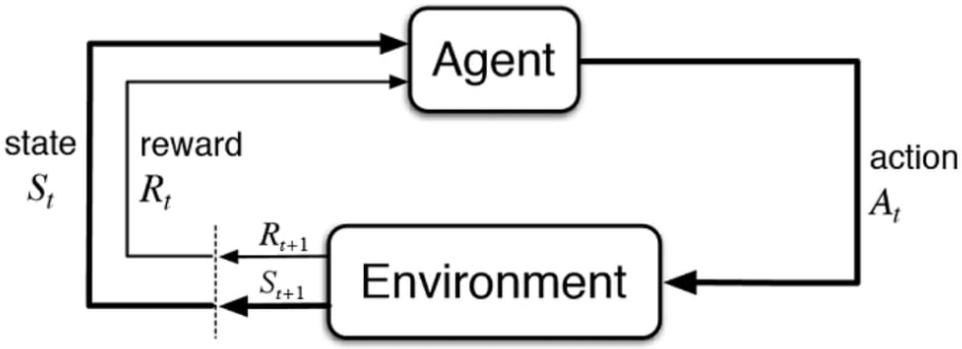


Рис. 2.3. Иллюстрация принципа работы алгоритма Reinforcement Learning (RL).

Совокупно это формирует главный gap: MPC обеспечивает дисциплину ограничений, но требует модели и вычислений; RL обеспечивает адаптацию, но требует данных/безопасности/доверия; T&R обеспечивает безопасную и понятную эксплуатацию, но не оптимизирует системно. Отсюда следует логика гибридизации: безопасный старт и сбор данных на T&R, адаптивная оптимизация на RL и MPC-класс проверок/проекций для соблюдения ограничений и промышленной надёжности. Именно такая «мостовая» стратегия прямо адресует cold-start, интерпретируемость и контроль рисков.

2.3. Прогнозные модели и FDD

Отдельный пласт работ рассматривает ML как инфраструктуру для управления: прогнозирование температур, CO_2, нагрузок, занятости и энергопотребления, а также обнаружение/диагностику неисправностей (FDD). Практический вывод обзоров состоит в том, что качество управления упирается в качество данных: пропуски, шумы, дрейф/калибровка датчиков, неполные метаданные и неконсистентная адресация точек BMS напрямую ухудшают точность прогнозов и надёжность FDD, а значит — устойчивость AI-управления в целом.

2.4. Нормативы комфорта и IAQ

Стандарты (ASHRAE 55/62.1, ISO 7730, EN 16798-1) задают числовые рамки комфорта и качества воздуха и используются как источник ограничений и метрик (доля времени в диапазонах, вероятность превышений, интегральные показатели дискомфорта). При этом в литературе отмечается типичная упрощённая трактовка нормативов — через статические пороги/уставки, без полноценной интеграции в многокритериальные постановки. Для масштабирования AI-подходов в коммерческих зданиях критично именно алгоритмическое «вшивание» нормативов в целевые функции и ограничения (в т.ч. как мягких ограничений со штрафами), чтобы корректно балансировать энергосбережение и качество среды.

2.5. Мировые практики внедрения AI-HVAC

Публичные кейсы AI-HVAC демонстрируют двузначные проценты экономии и архитектуры, близкие к академическим: прогнозирование, многокритериальные цели, адаптивное управление и FDD. Однако уровень детализации методов и данных часто недостаточен для строгого сопоставления с формальными постановками MPC/RL, а большая часть открытых примеров относится к офисным и образовательным зданиям; крупные торгово-развлекательные центры и многофункциональные объекты представлены существенно менее полно. Это формирует практический gap и повышает ценность полевых исследований/пилотов на сложных коммерческих объектах с вариативной занятостью и жёсткими ограничениями по IAQ/комфорту.

3. Постановка задачи управления HVAC с использованием AI

(cc) BY © Б.Азам, Ш.Алимов, В.Фролов, Г.Алшански, С.Мурзабеков

3.1. Объект управления и контур внедрения

В работе рассматривается крупный коммерческий объект с выраженной многозонностью и переменной занятостью, для которого критичны одновременно энергоэффективность, тепловой комфорт и качество внутреннего воздуха. Типовая инженерная конфигурация включает центральные приточно-вытяжные установки с регулируемой подачей наружного воздуха и распределение воздуха по зонам через VAV-подобную архитектуру; исполнительные механизмы (вентиляторы, заслонки, клапаны) работают под управлением частотных преобразователей и локальных регуляторов. Управление реализуется через существующую BMS/BEMS, где базовый уровень обычно представлен ПИД-контуром по температуре/давлению и расписаниями работы оборудования, а AI-уровень надстраивается поверх имеющейся инфраструктуры и формирует обновлённые уставки и режимы без требования капитальной замены оборудования.

3.2. Данные и наблюдаемое состояние

Состояние системы описывается совокупностью временных рядов, поступающих из BMS и внешних источников. Внутренние данные включают температуры и относительную влажность в репрезентативных зонах, концентрации CO_2, параметры приточного и вытяжного воздуха, а также телеметрию оборудования, отражающую текущий режим вентиляции и кондиционирования. Для оценки энергетического эффекта используются измерения электрической мощности ключевых потребителей HVAC и/или показания счётчиков. Внешний контекст задаётся метеопараметрами и, при наличии, информацией о тарифах; для коммерческих объектов существенны индикаторы занятости, которые выступают прокси внутренней нагрузки и позволяют прогнозно адаптировать вентиляционные режимы. Типичный шаг дискретизации данных лежит в диапазоне минут, при этом архив характеризуется пропусками, шумами и изменениями конфигурации точек, что требует стандартного пайплайна очистки, синхронизации и восстановления перед обучением моделей и запуском онлайн-управления.

3.3. Управляемые переменные и ограничения

Управление формализуется как выбор траектории уставок и режимов основных контуров HVAC на дискретном горизонте. В качестве управляемых воздействий рассматриваются уставки температуры приточного воздуха, уставки расхода/давления в магистралях (или эквивалентные задания на частоту вентиляторов), доля наружного воздуха, а также, при доступности, уставки температур теплоносителей и элементы расписаний. На эти воздействия накладывается набор ограничений трёх типов: ограничения по комфорту (диапазоны температур и влажности, а при необходимости — область PMV/PPD), ограничения по IAQ (минимальная вентиляция и верхние границы по CO_2) и эксплуатационные ограничения оборудования (границы сигналов и ограничения на скорость изменения уставок, а также ограничения, связанные с ресурсом и безопасностью). Часть требований реализуется как жёсткие ограничения (недопустимость длительных превышений), а часть допускается в виде мягких ограничений со штрафованием в критерии качества, что позволяет управлению сохранять устойчивость в редких нештатных режимах и при неопределённостях измерений.

3.4. Целевая функция

Задача формулируется как многокритериальная оптимизация на горизонте длиной N шагов и сводится к скаляризованному критерию, в котором энергия (или стоимость/эквивалентные выбросы) балансируется с метриками дискомфорта и качества воздуха при регуляризации управляющих воздействий. В компактной форме критерий может быть записан как:

$$J = \sum_{k=0}^{N-1} \Big(w_E E_k + w_{\text{cost}} C_k + w_{\text{disc}} \Phi_k^{\text{comfort}} + w_{\text{IAQ}} \Phi_k^{\text{IAQ}} + w_{\Delta u} \Phi_k^{\text{smooth}} \Big)$$

где E_k характеризует энергопотребление HVAC на шаге k, C_k — стоимостной компонент с учётом тарифов, $\Phi_k^{comfort}$ и Φ_k^{IAQ} — штрафы за отклонения параметров внутренней среды от нормативных диапазонов, а Φ_k^{smooth} пенализирует излишне частые/резкие изменения уставок. Такой единый формализм позволяет сопоставимо задавать цель для разных алгоритмических парадигм: в MPC он используется непосредственно в задаче оптимизации с ограничениями, а в RL транслируется в структуру вознаграждения (с противоположным знаком), обеспечивая согласованность критериев при переходе между режимами управления и при сравнении стратегий.

3.5. Benchmarking

Таблица. 3.1.

Сравнение алгоритмов (относительно baseline).

Алгоритм	**Экономия ЭЭ %**	**ΔDiscomfort, %**
Trim & Respond (T&R)	5–12	−5…+5
Reinforcement Learning (RL)	8–18	−10…+10
Model Predictive Control (MPC)	10–20	−15…0
Гибрид (T&R + RL + MPC)	15–25	−20…0

Для выбора практической стратегии управления и калибровки ожиданий по эффекту был применён единый протокол сравнения четырёх подходов: Trim&Respond, Reinforcement Learning, Model Predictive Control и гибридной схемы, в которой Trim&Respond используется для безопасного старта и накопления данных, RL — для адаптации к объекту, а MPC-класс safety-слой — для контроля ограничений. Сопоставление проводилось на согласованных эксплуатационных окнах при одинаковых расписаниях и едином наборе ограничений, а качество оценивалось совместно по энергопотреблению и метрике интегрального дискомфорта, поскольку сравнение «только по энергии» без контроля comfort/IAQ методологически некорректно. В результате гибридная схема демонстрирует доминирующий профиль по Парето-критерию, обеспечивая наибольшую экономию при неухудшении качества внутренней среды по выбранной интегральной метрике; MPC показывает устойчивый компромисс, RL — сопоставимую по медиане экономию с большей вариативностью, а Trim&Respond — умеренный эффект, ограниченный отсутствием межвременной оптимизации и адаптации.

4. Архитектура AI-платформы для управления HVAC

4.1. Общая архитектура системы

AI-платформа проектируется как надстройка над действующей системой автоматизации здания (BMS/BEMS) и не подменяет локальные контуры регулирования. Платформа получает телеметрию и состояния оборудования, формирует управляющие воздействия в виде динамически обновляемых уставок и передаёт их обратно в BMS через стандартные интерфейсы, сохраняя ПИД-регуляторы и штатные механизмы BMS в роли нижнего уровня управления. Для безопасного ввода в эксплуатацию предусмотрены режимы поэтапного включения, включая мониторинг и «теневой» режим рекомендаций (shadow mode), а также автоматический возврат к базовым стратегиям при отказах или аномалиях (fallback).

На концептуальном уровне архитектура

(рис. 4.1) разделяется на слой данных, слой AI-ядра и слой интеграции. Слой данных отвечает за сбор сигналов из BMS и внешних источников, их нормализацию, синхронизацию по времени и формирование признаков, необходимых для прогнозирования и оптимизации. AI-ядро включает подсистему прогнозных моделей и модуль оптимизации/управления, которые используют единый формализм целевой функции и ограничений, заданный в постановке задачи. Слой интеграции обеспечивает доставку уставок в BMS, журналирование принятых решений и возможность контроля со стороны эксплуатационного персонала.

4.1.1. Программная архитектура и компоненты

Программно платформа реализуется как набор сервисов, разделяющих ответственность между семантической подготовкой данных, хранением временных рядов и признаков, обучением моделей и онлайн-контуром управления. Семантическая нормализация (Embedding & Mapping) обеспечивает сопоставление «сырых» имён/тегов точек BMS с канонической моделью объекта (оборудование, контуры, зоны) и тем самым снижает зависимость алгоритмов от неоднородных схем адресации и именования сигналов. Хранилище временных рядов и признаков (Time-series DB / Feature Store) формирует единый источник данных для прогнозных моделей и RL, включая агрегаты, лаговые признаки, погодные факторы и индикаторы занятости. Контур обучения (Training Pipeline) отвечает за периодическое или событийно-инициируемое переобучение, версионирование и публикацию артефактов, а сервис управления (Control Service) реализует онлайн-цикл: получение текущего состояния и прогнозов, расчёт уставок (в парадигме MPC/T&R/RL), применение safety-проверок и ведение audit-следа по принятым решениям.

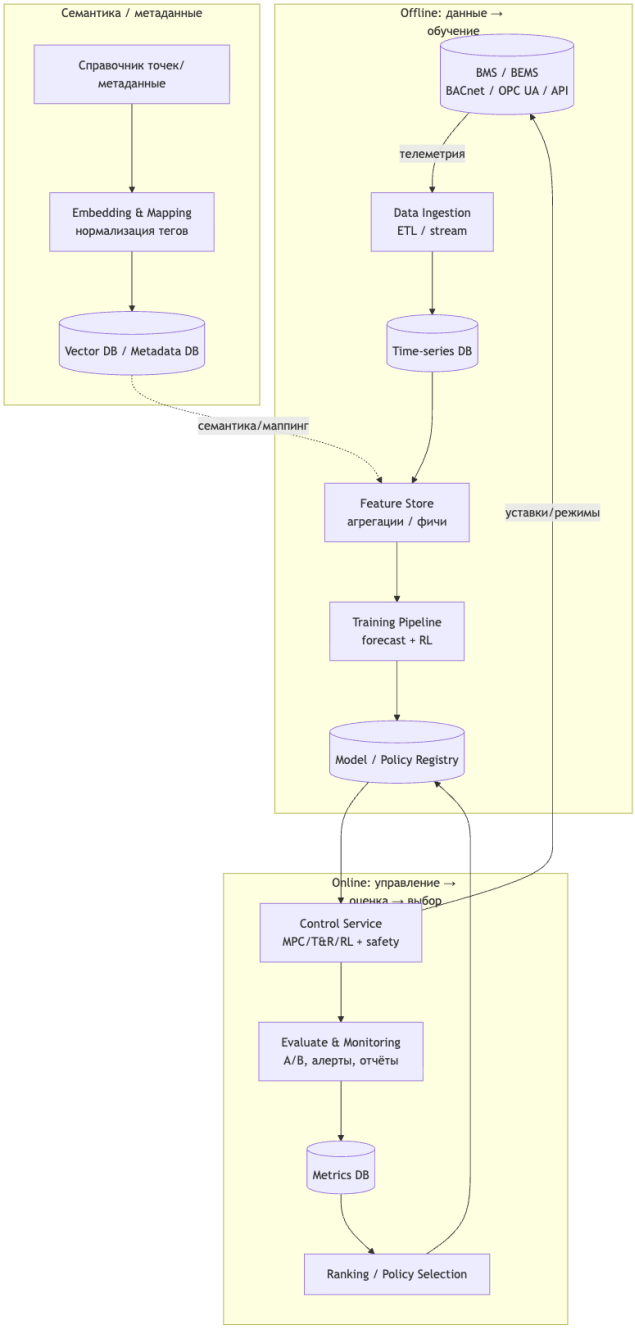


Рис. 4.1. Архитектура AI-платформы HVAC.

4.2. Подсистема прогнозных моделей

Прогнозная подсистема строит краткосрочные оценки динамики микроклимата и нагрузок на горизонте управления и служит входом для оптимизационного слоя. Модели обучаются на исторических данных BMS с привлечением внешних факторов и подбираются по принципу достаточности: в зависимости от качества и объёма данных используются как простые регрессионные/авторегрессионные схемы, так и нелинейные ML-модели. Валидация выполняется не только по

(cc) BY © Б.Азам, Ш.Алимов, В.Фролов, Г.Алшански, С.Мурзабеков

усреднённым метрикам точности (например, RMSE, MAPE), но и по распределению ошибок в режимах, критичных для комфорта и IAQ, поскольку именно ошибки в пиковых и пограничных состояниях наиболее чувствительны для качества управления.

В эксплуатационной фазе прогнозные модели должны адаптироваться к изменению характеристик объекта. Для этого применяется регулярное дообучение на новых данных, процедуры drift detection для выявления структурных сдвигов в нагрузках и параметрах оборудования, а также переключение между сезонными и контекстными вариантами моделей (например, по типу дня или сезону). Для повышения устойчивости управления прогнозы сопровождаются оценкой доверия и интервалами неопределённости; эти оценки используются модулем оптимизации для более консервативных стратегий в условиях высокой неопределённости входных данных и внешних воздействий.

4.3. Модуль оптимизации/управления

Модуль оптимизации/управления преобразует прогнозы в конкретные управляющие воздействия на заданном горизонте, решая многокритериальную задачу при наличии эксплуатационных и нормативных ограничений. Для многозональных коммерческих объектов это означает высокую размерность управлений и состояний, поскольку одновременно учитываются зоны, установки и ограничения по скорости и диапазонам изменения уставок. В MPC-парадигме решение строится по принципу receding horizon: оптимизируется последовательность воздействий на конечном горизонте, а в BMS передаётся только ближайший шаг, после чего оптимизация повторяется с учётом новых измерений и уточнённых прогнозов.

В RL-парадигме управление задаётся политикой, формирующей действие по текущему состоянию, при этом практическая архитектура ориентирована на гибридизацию: RL может генерировать рекомендации или параметры, которые затем проходят через слой оптимизации с жёсткими ограничениями (safety layer), реализованный в духе MPC или другого детерминированного оптимизатора. Такой каскад позволяет использовать адаптивность RL без потери гарантий по соблюдению критичных ограничений.

Независимо от выбранной парадигмы, в контуре управления выделяется слой безопасности и устойчивости. Он включает явные safety constraints на диапазоны и скорости изменения уставок, минимальные уровни вентиляции и предельные значения температур и CO_2, онлайн-контроль выполняемости ограничений и механизм автоматического fallback к базовым стратегиям BMS при недоступности данных, некорректных прогнозах, вычислительных сбоях или обнаружении аномального поведения алгоритма.

4.4. Интеграция нормативных требований в контур управления

Нормативные требования по тепловому комфорту и качеству внутреннего воздуха рассматриваются как формальный источник ограничений и критериев, встраиваемых непосредственно в постановку оптимизационной задачи и в правила safety layer. На уровне ограничений нормативные параметры переводятся в математические неравенства и допустимые области состояний по температуре, влажности и индикаторам комфорта, а требования к вентиляции и CO_2 — в нижние границы на воздухообмен и верхние границы на концентрации. На уровне целевой функции нормативы отражаются через структуру штрафов и приоритетов так, чтобы решения, достигающие энергосбережения ценой систематического ухудшения микроклимата, становились невыгодными по критерию качества.

В сокращённой версии статьи детальные численные значения диапазонов и формализация ограничений целесообразно фиксируются в разделе постановки задачи, а в архитектурном описании достаточно подчеркнуть, что нормативы реализуются одновременно как «жёсткие» ограничения в safety layer и как «мягкие» компоненты критерия (через штрафы и веса), что обеспечивает трассируемый баланс «энергия–комфорт–IAQ» в принятии решений.

4.5. Практические аспекты внедрения

Частота пересчёта управляющих воздействий выбирается согласованно с инерционностью термодинамики здания и частотой обновления данных BMS; на практике рационально использовать шаг управления порядка нескольких минут при пересчёте прогнозов и оптимизации на скользящем горизонте каждые 5–15 минут. Вычисления целесообразно размещать на сервере, связанном с BMS через защищённый канал, а задержки связи и времени расчёта учитываются как в постановке управления, так и на уровне архитектуры через буферизацию и механизмы устойчивого исполнения команд при кратковременных разрывах.

Для масштабирования на портфель зданий критичны стандартизация процедур интеграции, переносимость семантического mapping и модульность программной реализации, позволяющая переиспользовать прогнозные и оптимизационные компоненты при адаптации параметров и ограничений под конкретный объект; при этом эксплуатационный контур должен сохранять прозрачность через мониторинг, отчётность и возможность ручного вмешательства.

5. Экспериментальные исследования / кейс стади

5.1. Описание сценария внедрения (крупный торгово-развлекательный центр)

Пилотная проверка предложенного подхода выполнена на объекте типа «крупный торгово-развлекательный центр» с развитой инженерной инфраструктурой приточно-вытяжной вентиляции и кондиционирования и существенно вариабельной посещаемостью по времени суток и дням недели. Система HVAC включает центральные приточно-вытяжные установки с рекуперацией тепла, вентиляторы с частотным регулированием и многозональное распределение воздуха для торговых галерей, зоны общественного питания, кинозалов и вспомогательных помещений. В статье соблюдены условия конфиденциальности: наименование и точное местоположение объекта не раскрываются, а анализ ведётся по обезличенным данным эксплуатации.

Экспериментальный период сформирован из типичных рабочих дней в сезонно сопоставимых условиях, когда профиль внутренней нагрузки является показательным для оценки управления вентиляцией. Для корректности сравнения дополнительно учитывались внешние климатические факторы, прежде всего наружная температура, а также особенности эксплуатации арендаторов и режимы работы объекта, поскольку именно эти факторы существенно влияют на энергопотребление и параметры микроклимата.

5.2. Базовый сценарий управления

До внедрения AI-платформы управление выполнялось традиционными средствами BMS, основанными на фиксированных либо ступенчато изменяемых уставках и расписаниях. На нижнем уровне работали стандартные ПИД-регуляторы по температуре приточного воздуха и по давлению/расходу в воздуховодах, а логика верхнего уровня задавала режимы включения установок и смену уставок по времени суток. Такой подход обеспечивал в среднем приемлемые условия по температуре и качеству воздуха, однако слабо учитывал фактическую динамику посещаемости и, как следствие, приводил к избыточной вентиляции в периоды низкой нагрузки и к запаздывающей реакции в периоды резкого роста трафика, когда параметры IAQ могли кратковременно приближаться к верхним границам допустимых диапазонов.

Для базового режима были зафиксированы сравнимые метрики, отражающие энергопотребление вентиляционных установок и качество внутренней среды. В энергетической части рассматривались интегральные показатели потребления электроэнергии за выбранные интервалы, а для микроклимата анализировались отклонения температуры от комфортного диапазона и доля времени, когда концентрация CO_2 превышала установленный порог.

5.3. Сценарий с AI-управлением

В AI-сценарии платформа интегрировалась поверх существующей BMS, получая телеметрию в режиме, близком к реальному времени. В контур поступали температуры по зонам, концентрации CO_2, влажность, параметры воздушного тракта (расходы/давления), состояния оборудования и текущие уставки, а также сигналы по энергопотреблению. Дополнительно использовались внешние погодные данные и индикаторы занятости, позволяющие оценивать текущую и ожидаемую внутреннюю нагрузку. На этой основе строились краткосрочные прогнозы микроклимата и энергопотребления на горизонте управления.

Управляющие воздействия формировались как динамически обновляемые уставки (в первую очередь для вентиляции: целевые значения по давлению/расходу и режимы частотного регулирования вентиляторов, а также связанные параметры, влияющие на долю наружного воздуха), согласованные с дискретизацией обновления данных. Практическая конфигурация в кейсе соответствовала гибридной логике: предиктивное принятие решений опиралось на прогнозы и оптимизацию на горизонте нескольких часов, при этом соблюдение эксплуатационных и нормативных ограничений обеспечивалось механизмами safety, а при деградации качества данных или аномалиях предусматривался автоматический возврат к базовым стратегиям BMS (fallback). Ввод в эксплуатацию выполнялся поэтапно: от режима мониторинга и рекомендаций к автоматическому управлению с постоянным контролем ограничений.

5.4. Методика оценки эффектов

Эффект AI-управления оценивался сравнением «до/после» на репрезентативных периодах базового и AI-сценариев, сопоставимых по типу дней и режиму эксплуатации. Из выборки исключались аномальные дни, связанные с внештатными событиями, крупными мероприятиями либо изменениями конфигурации оборудования, чтобы минимизировать систематические смещения. Поскольку энергопотребление HVAC чувствительно к погоде и внутренней нагрузке, сравнение выполнялось с учетом нормализации по наружной температуре и индикаторам занятости: анализировались зависимости потребления и параметров IAQ от этих факторов, что позволяло отделить вклад управления от влияния внешней конъюнктуры.

Набор KPI включал энергетику, комфорт и качество воздуха. В энергетической группе рассматривались суммарное электрическое энергопотребление вентиляции (и связанного оборудования, если данные доступны), а также производные показатели стоимости и эквивалентных выбросов CO_2 при наличии коэффициентов пересчета. Для комфорта оценивалась доля времени нахождения температуры в пределах нормативного диапазона выбранной категории качества внутренней среды и интегральные показатели отклонений. Для IAQ анализировались доля времени соблюдения порога CO_2 и характеристики эпизодов превышения. Дополнительно контролировалось качество управляющих воздействий с инженерной точки зрения: сглаженность профиля, отсутствие частых резких переключений и признаков потенциально неблагоприятной работы для ресурса оборудования.

5.5. Результаты и визуализация управления и микроклимата

В этом пункте сопоставляются два режима эксплуатации одной из приточно-вытяжных установок: базовый сценарий управления средствами BMS и управление с использованием AI-платформы. Для компактного представления результатов целесообразно опираться на три ключевые визуализации: профиль частоты вращения вентилятора как прокси-показатель уровня вентиляции, динамику CO_2 как основной KPI качества воздуха и интегральную панель/свод по энергопотреблению. Температура приводится как подтверждение отсутствия деградации теплового комфорта и может быть оставлена в виде одного рисунка либо сведена к краткому утверждению в тексте, если требуется максимальная экономия объёма.

5.5.1. Динамика частоты вращения вентилятора при AI управлении

ISSN: 3030-3346

На рисунке 5.1 показано сопоставление профиля относительной частоты вращения вентилятора (одной из репрезентативных приточно-вытяжных установок) в базовом сценарии и при работе AI-платформы. В базовом режиме управление носит преимущественно расписательный характер и выражается в длительных «плато» частоты на фиксированных уровнях, что типично для ручных уставок и ступенчатых программ. При AI-управлении профиль становится адаптивным: частота удерживается на минимально достаточном уровне в периоды низкой нагрузки и повышается по мере роста потребности в воздухообмене, формируя более «дыхательную» траекторию. Это отражает переход от вентиляции «с запасом» к дозированному воздухообмену, согласованному с фактической и ожидаемой нагрузкой, и является основным механизмом энергетического эффекта при сохранении требований по IAQ.

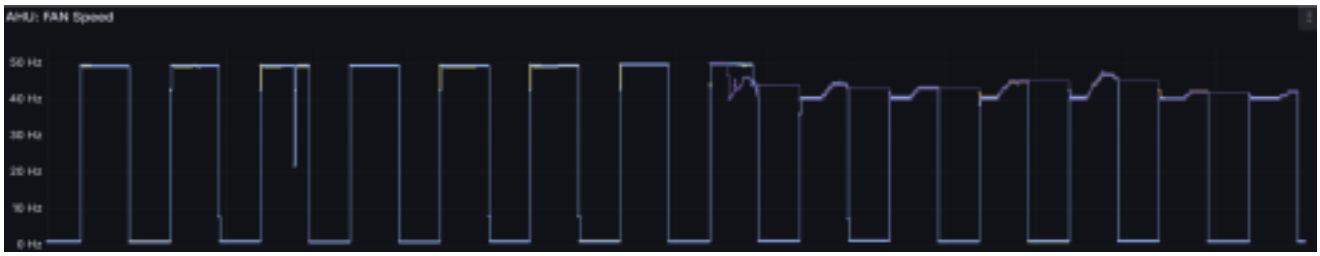


Рис. 5.1. Динамика частоты вращения вентилятора приточно-вытяжной установки при базовом управлении. Характерный профиль с фиксированными ступенчатыми уровнями частоты, задаваемыми расписаниями и ручными уставками.

5.5.2. Концентрация CO_2 при адаптивном управлении вентиляцией

На рисунке 5.2 приведена динамика концентрации CO_2 в одной из торговых зон, обслуживаемых анализируемой установкой, на фоне верхней границы рекомендованного диапазона для выбранной категории качества внутреннего воздуха. В сравнимые по посещаемости дни AI-управление сохраняет средние значения CO_2 на уровне базового сценария или улучшает их, при этом принципиально меняется характер реакции: вентиляция увеличивается упреждающе, что ограничивает амплитуду пиков в периоды максимальной нагрузки и сокращает длительность эпизодов приближения к пороговым значениям. Существенно, что снижение оборотов в часы низкой нагрузки не приводит к выходу CO_2 за пределы допустимого диапазона, поскольку минимально необходимый воздухообмен поддерживается с учётом измерений и ограничений.



Рис. 5.2. Динамика концентрации CO_2 в обслуживаемой торговой зоне при переходе к адаптивному AI-управлению вентиляцией. Горизонтальной линией показана верхняя граница рекомендованного диапазона качества внутреннего воздуха; видно ограничение пиков и удержание средних значений в пределах допустимого уровня.

5.5.3. Температура внутреннего воздуха и комфортный диапазон

(cc) BY © Б.Азам, Ш.Алимов, В.Фролов, Г.Алшански, С.Мурзабеков

ISSN: 3030-3346

Температурные ряды в контрольных зонах при AI-управлении демонстрируют сопоставимый суточный ритм с базовым режимом и не показывают систематического смещения средних значений в сторону менее комфортных условий. Подавляющую часть времени температура находится в комфортном диапазоне выбранной категории внутренней среды либо в непосредственной близости от его границ, а возможные отклонения носят ограниченный по длительности характер и не изменяют интегральную долю времени соблюдения требований теплового комфорта. Это важно методологически: энергетический выигрыш достигается за счёт оптимизации вентиляции и связанных уставок, а не за счёт ухудшения температурных условий.



Рис. 5.3. Температура внутреннего воздуха в одной из контрольных зон, обслуживаемой системой вентиляции под управлением AI-платформы. Суточные колебания находятся в узком диапазоне, соответствующем требованиям стандартов теплового комфорта.

5.5.4. Сводные численные результаты и сопоставление с литературой

Интегральные результаты по анализируемым установкам сведены на рисунке 5.4 и подтверждают, что переход к AI-управлению приводит к устойчивому снижению энергопотребления вентиляции на сопоставимом периоде при сохранении требований к качеству воздуха и тепловому комфорту. Для пилотной группы установок снижение суммарного потребления составляет порядка одной четверти от базового уровня (около 23%), что эквивалентно экономии нескольких сотен кВт·ч за анализируемый интервал и сопровождается сопоставимым снижением эквивалентных выбросов CO_2 при пересчёте по принятому коэффициенту. Наблюдаемый эффект находится в согласии с диапазонами, описываемыми в работах по AI-управлению HVAC для коммерческих зданий, при этом в данном случае ключевой вклад достигается без капитальных ретрофитов, за счёт оптимизации уставок и режимов существующей BMS-инфраструктуры.



Рис. 5.4. Интегральная панель мониторинга AI-платформы для систем вентиляции: динамика потребления электроэнергии, достигнутая экономия и эквивалентное сокращение выбросов CO_2 за анализируемый период работы.

© Б.Азам, Ш.Алимов, В.Фролов, Г.Алшански, С.Мурзабеков

6. Обсуждение

Полученные на крупном торгово-развлекательном центре результаты подтверждают, что AI-управление способно обеспечивать двузначную экономию электроэнергии систем вентиляции при сохранении температурных и газовых параметров в пределах нормативных диапазонов. В рассматриваемом пилоте зафиксировано снижение потребления электроэнергии системами вентиляции на 23% относительно базового сценария при сохранении концентрации CO_2 и температуры в допустимых пределах. Это согласуется с тем, как в систематических обзорах описываются эффекты от AI-подходов в HVAC: экономия энергии варьируется в широком диапазоне (вплоть до десятков процентов) и для коммерческих объектов часто указывается на уровне, сопоставимом с достигнутыми значениями. Существенно, что энергосбережение достигается без глубокой модернизации инженерного оборудования, за счёт надстройки на уровне управления, архитектуры BEMS и использования данных.

Интерпретация эффекта указывает на важность многокритериальной постановки задачи, где энергосбережение достигается не «любой ценой», а через смещение компромисса «энергия–комфорт–IAQ» в сторону более эффективных режимов при сохранении нормативных ограничений. На практике это означает, что стратегия управления должна учитывать инерционность объекта и переменную нагрузку, а также иметь механизмы предотвращения деградации микроклимата при неопределённостях, неизбежных в реальной эксплуатации.

Ключевым фактором воспроизводимости результатов является качество и полнота данных. В литературе подчёркивается, что неоднородность источников данных, различия в точности и калибровке датчиков, а также пропуски и шумы в архивах напрямую ограничивают надёжность AI-контуров. Поэтому промышленная реализация должна включать процедуры предварительного аудита и стандартизации сигналов, а также устойчивость к пропускам и ошибкам данных на уровне фильтрации, реконструкции и мониторинга согласованности. Важным элементом надёжности остаются safety- и fallback-режимы, позволяющие при аномалиях данных или ухудшении качества прогнозов смещать решения в сторону консервативных режимов либо временно возвращаться к базовому управлению. Дополнительно, на уровне интеграции с BMS должны быть предусмотрены механизмы автоматического возврата к базовым стратегиям при сбоях, что снижает операционные риски.

Границы применимости подхода определяются инфраструктурой объекта и характером нагрузки. Наиболее выраженный эффект ожидаем в зданиях с развитой механической вентиляцией и кондиционированием, наличием BMS и возможностью управлять параметрами в реальном времени, а также при наличии измерений температуры, CO_2, расхода воздуха и энергопотребления. В то же время для объектов с устаревшим оборудованием без телеметрии и дистанционного управления, а также для небольших зданий с близкой к постоянной нагрузкой потенциал сложных алгоритмов ограничен либо требует предварительных капитальных вложений в базовую инфраструктуру данных и управления. Отдельной категорией остаются объекты с особыми требованиями к надёжности и безопасности (например, медицинские и лабораторные), где внедрение требует усиленной валидации, консервативных ограничений и регламентированных процедур эксплуатации.

7. Заключение и направления дальнейших исследований

Проведённое исследование подтверждает, что применение методов искусственного интеллекта в управлении HVAC коммерческих зданий позволяет улучшить компромисс между энергопотреблением и качеством внутренней среды при формализованной многокритериальной постановке задачи, учитывающей энергопотребление, тепловой комфорт и качество воздуха. В пилотном внедрении на крупном торгово-развлекательном центре достигнуто снижение потребления электроэнергии системами

вентиляции на 23% относительно базового сценария при сохранении концентрации CO_2 и температуры в пределах нормативных диапазонов, что демонстрирует практическую применимость подхода в условиях эксплуатации.

Дальнейшие исследования целесообразно сосредоточить на масштабировании подхода с уровня отдельного объекта на портфель зданий, включая перенос моделей и конфигураций между разными архитектурами HVAC и климатическими условиями, а также на стандартизации представления данных и использовании общих онтологий инженерных систем для ускорения внедрений. Перспективным направлением является более глубокая интеграция AI-управления с энергосистемой здания и внешней энергосистемой через учёт динамических тарифов, demand response и ограничений по мощности, что позволит использовать гибкость HVAC для управления пиками нагрузки и участия в энергетических программах.

Литература

1. Aghili S.A., Olofsson T., Mahlia T.M.I. et al. Artificial Intelligence Approaches to Energy Management in HVAC Systems: A Systematic Review. Buildings, 2025.
2. Lee D., Lee S.-T., Kim B. et al. Artificial Intelligence Enabled Energy-Efficient Heating, Ventilation and Air Conditioning System: Design, Analysis and Necessary Hardware Upgrades. Applied Thermal Engineering, 2023.
3. Gassar A.A.A., Jafar R. Artificial Intelligence-Enabled Heating, Ventilation, and Air Conditioning Systems Toward Zero-Emission Buildings: A Systematic Review of Applications, Challenges, and Future Directions. Applied Sciences, 2025.
4. Ekanayaka Gunasinghalge L.U.G., Bandara H.M.N.D., Jayasinghe G.Y. et al. Artificial Intelligence for Energy Optimization in Smart Buildings: A Systematic Review and Meta-Analysis. Energy Informatics, 2025.
5. Ali D.M.T.E., Motuzienė V. AI Applications in Buildings: A Review of Energy Management Advancements. Journal of New Technologies in Environmental Science, 2024.
6. Ali D.M.T.E., Motuzienė V. AI-Driven Innovations in Building Energy Management Systems: A Review of Potential Applications and Energy Savings. Energies, 2024.
7. Emedo C., Jones R.V., Patterson M. et al. AI-Driven Transformations in Smart Buildings: A Review of Energy, Comfort, and User-Centric Control. Smart Energy, 2025.
8. Taheri S., Amini M.H., Shafie-khah M. et al. Model Predictive Control of Heating, Ventilation, and Air Conditioning Systems: A Review. Energy and Buildings, 2022.
9. Yang S., Drgoňa J., Vrabie D. et al. Lessons Learned from Field Demonstrations of Model Predictive Control and Reinforcement Learning in Buildings. Frontiers in Energy Research / arXiv, 2025.
10. Ali D. Data Challenges in AI-Driven HVAC Systems. Environmental and Climate Technologies, 2025.
11. Zhao Y., Wen J., Xiao F. Artificial Intelligence-Based Fault Detection and Diagnosis Methods for Building Energy Systems. Renewable and Sustainable Energy Reviews, 2019.
12. Zhou S.L., Li Y., Wang Y. et al. A Comprehensive Review of the Applications of Machine Learning for HVAC. DeCarbon, 2023.
13. Sustainability Education Academy. AI-HVAC Optimization in Smart Buildings: Guide. Sustainability Education Academy, 2025.
14. Xin X., Jiang Y., Wang S. et al. A Comprehensive Review of Predictive Control Strategies in HVAC Systems. Energy and Buildings / Building and Environment, 2024.
15. Michailidis P., Papantoniou S., Kolokotsa D. Model Predictive Control for Smart Buildings: Applications and Challenges. Buildings, 2025.
16. Rockett P., Hathway E.A. Model-Predictive Control for Non-Domestic Buildings: A Critical Review. Building Research & Information, 2017.
17. Bamdad K., Nik-Bakht A., Shahnazari H. Model Predictive Control for Energy

(cc) BY © *Б.Азам, Ш.Алимов, В.Фролов, Г.Алшански, С.Мурзабеков*

Optimization of HVAC Systems in Office Buildings. Buildings, 2023.
18. Yang Y., Drgoňa J., Vrabie D. Optimizing HVAC Systems with Model Predictive Control. Frontiers in Energy Research, 2025.
19. Al Sayed K., Zaidan E., Psomas T. et al. Reinforcement Learning for HVAC Control in Intelligent Buildings: A Review. Energy and Buildings, 2024.
20. Xu S., Zhang S., Li N. et al. Efficient and Assured Reinforcement Learning Based Control for HVAC Systems. Scientific Reports, 2025.
21. Boutahri Y., Elmansouri M., Benhammou M. et al. Reinforcement Learning for HVAC Control and Energy Management. Information Retrieval Journal, 2025.
22. Yu L., Zhang X., Hong T. Multi-Agent Deep Reinforcement Learning for HVAC Control in Commercial Buildings. arXiv preprint arXiv:2006.14156, 2020.
23. Blad C. Reinforcement Learning Based Control for Heating, Ventilation and Air-Conditioning (HVAC) Systems. PhD Thesis, Aalborg University, 2022.
24. Gharbi A., Dhaou I., Hamdaoui F. et al. Intelligent HVAC Control: Comparative Simulation of Reinforcement Learning and PID Control. Mathematics, 2025.
25. Myrspoven, Schneider Electric. AI-Powered HVAC in Educational Buildings – White Paper. Myrspoven / Schneider Electric, 2024.
26. Analytika by Cimetrics. AI Powered HVAC Optimization – Cut Costs & Boost Efficiency. Online report, 2024.
27. ANSI/ASHRAE Standard 55-2023. Thermal Environmental Conditions for Human Occupancy. American Society of Heating, Refrigerating and Air-Conditioning Engineers (ASHRAE), 2023.
28. ANSI/ASHRAE Standard 62.1-2022. Ventilation for Acceptable Indoor Air Quality. ASHRAE, 2022.
29. ISO 7730:2025. Ergonomics of the Thermal Environment – Analytical Determination and Interpretation of Thermal Comfort Using PMV and PPD Indices. International Organization for Standardization (ISO), 2025.
30. EN 16798-1:2019. Energy Performance of Buildings – Indoor Environmental Input Parameters for Design and Assessment of Energy Performance of Buildings. European Committee for Standardization (CEN), 2019.
31. Google DeepMind. DeepMind AI Reduces Google Data Centre Cooling Bill by 40%. Technical blog / case study, 2016.
32. BrainBox AI. Montreal Office Building Achieves Energy Cost Savings in First 5 Months. Case Study, BrainBox AI, 2020.
33. BrainBox AI. Holiday Inn Longueuil: Realizing Energy Savings with AI. Case Study, BrainBox AI, 2020.
34. Welcome.ai. Australian Mall Achieves 21% Energy Savings with AI HVAC System. Online case study, 2021.
35. Aegis Solvo Group, Byteflow AI Lab. AI Revolutionizes HVAC: 87 Educational Buildings in Stockholm. Blog / case study, 2024.
36. Siemens. Dynamic VAV Optimization (DVO) – 1111 Broadway Case Study. Siemens, 2019.
37. Business Action Bank. Enhance Building Energy Efficiency Through AI Automation. Online case study on a European commercial building, 2024.
38. Panorad.ai. HVAC AI Agents: How Smart Buildings Cut Energy Costs and Carbon Emissions. Blog article, 2025.

(cc) BY © *Б.Азам, Ш.Алимов, В.Фролов, Г.Алшански, С.Мурзабеков*