УДК 004.8, 004.94 10.56564/27825264_2025_3_3

ПРОГНОСТИЧЕСКИЕ МОДЕЛИ ИНЖЕНЕРНЫХ СИСТЕМ ЦЕНТРОВ ОБРАБОТКИ ДАННЫХ НА ОСНОВЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА: ОБЗОР АРХИТЕКТУР И ДАТАСЕТОВ

А. С. Буторова [1,2], В. И. Борисов [1], А. П. Сергеев [1,2], М. В. Ронкин [1], В. С. Бобаков [2], С. С. Иванов [1], С. О. Поляков [1], К. А. Игнатков [1], Ю. Ю. Чернышов [1,3], А. В. Скороходов [3], А. И. Манжуров [1,3]

[1] Уральский федеральный университет им. первого Президента России Б. Н. Ельцина, г. Екатеринбург, Россия
[2] Институт промышленной экологии УрО РАН, г. Екатеринбург, Россия
[3] ООО «Сайберлимфа», Москва, Россия

Обзор посвящен проблеме прогнозирования отказов инженерных систем центров обработки данных (ЦОД). Современные ЦОД играют ключевую роль в цифровой инфраструктуре, обеспечивая условия для непрерывной работы облачных сервисов, телекоммуникаций и корпоративных систем. С ростом вычислительных нагрузок возрастает энергопотребление и нагрузка на инженерные системы ЦОД, в первую очередь на системы энергоснабжения и системы отопления, вентиляции и кондиционирования воздуха (Heating, Ventilation, and Air Conditioning, или HVAC). Неэффективная работа этих систем приводит не только к увеличению операционных затрат, но и к риску отказов ЦОД.

В настоящей работе представлен обзор современных подходов к построению прогностических моделей отказов обеспечивающих инженерных систем ЦОД с элементами искусственного интеллекта. Рассмотрены модели прогнозирования и датасеты для обучения моделей, полученные как в реальных, так и симулированных условиях. Особое внимание уделено применению нейросетевых архитектур, таких как рекуррентные, сверточные сети, сети с долгой краткосрочной памятью, генеративно-состязательные сети. Обсуждаются проблемы, связанные с дефицитом доступных размеченных датасетов и низкой адаптивностью и интерпретируемостью существующих прогностических моделей. Результаты обзора могут быть использованы при разработке интеллектуальных систем мониторинга и прогнозирования отказов в ЦОД.

Ключевые слова: центр обработки данных; энергопотребление; энергоснабжение; отопление; вентиляция; кондиционирование; HVAC; искусственный интеллект; машинное обучение; прогнозирование отказов.

1. Введение

Ускоряющийся темп развития технологий, таких как облачные вычисления, привел к стремительному росту рынка центров обработки данных (ЦОД) [1]. По мере увеличения вычислительной нагрузки возрастает и общее энергопотребление ЦОД, большую часть которого составляют затраты на охлаждение. В случае неэффективных систем кондиционирования они могут достигать до 40 % от общего энергопотребления ЦОД [2]. Поэтому оптимизация работы инженерных систем, в частности системы отопления, вентиляции и кондиционирования воздуха (HVAC), становится ключевым направлением повышения энергоэффективности ЦОД [3]. В HVAC встречаются множественные неисправности, вызывающие либо энергетические, либо тепловые потери. Примерами таких неисправностей могут быть утечки хладагента, загрязнение теплообменника, поломка вентиляторов,

заблокированные воздуховоды, неконденсирующиеся газы и т. д. [4]. Кроме того, по мере роста нагрузки увеличивается риск сбоев в работе других систем, обеспечивающих работоспособность ЦОД, в том числе системы энергоснабжения [5].

Уязвимость инженерных систем ЦОД требует не только оперативного реагирования на возможные неисправности, но и перехода к предиктивному управлению [6]. В отличие от традиционных подходов к обслуживанию ЦОД, основанных на регламенте или обнаружении уже произошедшего сбоя, интеллектуальные методы позволяют предсказывать неисправности на ранних этапах [7]. Это особенно важно для таких систем, как HVAC, где отказ одного компонента может повлечь каскадные сбои в работе системы.

Алгоритмы обнаружения и диагностики неисправностей используются для прогнозирования состояния систем ЦОД [4, 8, 9]. Современные подходы на базе искусственного интеллекта (ИИ) и машинного обучения (МО) позволяют выявлять аномалии и предсказывать вероятности отказов с учетом текущего состояния оборудования и внешних условий [10]. Прогностические модели обучаются на временных рядах данных, синтетических или полученных с датчиков, размещенных в ЦОД (датчиков температуры, давления, энергопотребления и др.). В задачах прогнозирования временных рядов используются как традиционные подходы, включая регрессионные модели [11] и деревья решений [12], так и более сложные архитектуры – рекуррентные нейронные сети (Recurrent Neural Networks (RNN)) [13], в том числе сети долгой краткосрочной памяти (Long Short-Term Memory (LSTM)) [14], графовые нейронные сети [15] и гибридные модели [16].

Несмотря на активные исследования в этой области, по-прежнему отсутствуют универсальные, интерпретируемые и адаптивные модели прогнозирования отказов, которые можно было бы масштабировать и применять в различных типах ЦОД. Отсутствие качественных размеченных данных остается ключевым ограничением развития моделей прогнозирования. Кроме того, доступные модели обучены выявлять ограниченное количество типов неисправностей систем HVAC.

Цель настоящей работы – обзор современных методов прогнозирования отказов в инженерных системах ЦОД с применением ИИ. Обзор ссылается на работы, опубликованные в 2018–2025 гг., и освещает архитектуры моделей, их успехи и ограничения. Практическая ценность работы заключается в обзоре датасетов, полученных в условиях штатных и нештатных режимов работы функционирующих ЦОД или в результате компьютерного моделирования и симуляции.

2. Материалы и методы

Центр (хранения и) обработки данных (ЦОД/ЦХОД)/Дата-центр – это специализированный объект, представляющий собой связанную систему ИТ-инфраструктуры и инженерной инфраструктуры, оборудование, части которых размещены в здании или помещении, подключенном к внешним сетям, как инженерным, так и телекоммуникационным [17]. Работоспособность ЦОД в значительной степени зависит от надежности их вспомогательных инженерных систем, в частности, систем энергоснабжения [18] и HVAC [4, 19, 20].

Система энергоснабжения ЦОД обеспечивает бесперебойную подачу электроэнергии для работы оборудования, размещенного в ЦОД, и включает в себя основное и резервное электроснабжение, источники бесперебойного питания (ИБП), системы стабилизации напряжения, дизель-генераторные установки (ДГУ), которые обеспечивают стабильную подачу электроэнергии при различных условиях [18]. Основное электроснабжение ЦОД поступает из местной электросети. При отключениях основного электроснабжения задействуется резервное электроснабжение. ИБП накапливают электроэнергию и обеспечивают работу оборудования при отключениях, а также стабилизируют напряжение. ДГУ обеспечивают автономное электроснабжение в случае продолжительных отключений

основного электроснабжения. Системы стабилизации напряжения защищают оборудование в ЦОД от перепадов напряжения.

Современные системы HVAC делятся на воздушные и жидкостные, с возможностью естественного и искусственного охлаждения [20]. Жидкостное охлаждение использует жидкости для отвода тепла от оборудования, тогда как при воздушном охлаждении воздух циркулирует через оборудование для его охлаждения. Для повышения эффективности и экономии энергии важно выбрать подходящую систему охлаждения, учитывая условия эксплуатации ЦОД. Один из известных способов повышения энергоэффективности системы охлаждения ЦОД использует капиллярные маты, которые позволяют отводить тепловую энергию от серверной для отопления других помещений здания [19].

2.1. Модели отказов инженерных систем с элементами ИИ

Разработка и применение моделей отказов подсистем ЦОД играют решающую роль в обеспечении прогнозирования их работоспособности в различных условиях [21]. В этом разделе рассмотрены модели отказов, связанные с системами энергоснабжения и HVAC, с акцентом на интеграцию ИИ.

2.1.1. Модели отказов систем энергоснабжения

Как показано в [22], отказы узлов ЦОД значительно повышают энергопотребление и влияют на общую энергоэффективность ЦОД. Аномалии в метриках производительности могут привести к истощению ресурсов и полному отказу узлов, что может в свою очередь повлиять на доступность сервисов. Комплексная модель [22] учитывает рабочую нагрузку, затраты на охлаждение и последствия сбоев, что позволяет снизить затраты на охлаждение на 15,4–50 % и общее энергопотребление до 65–78 % по сравнению с существующими решениями. Методы планирования задач при помощи генетических алгоритмов позволяют эффективно управлять планированием задач с учетом отказов узлов, тем самым снижая энергопотребление [23].

В работе [24] предложены два новых показателя: «единая точка снижения доступности» (SpOra) и «двойная точка снижения доступности» (dPORA), которые позволяют оценить число однократных и двойных отказов, которые могут произойти до того, как общая доступность системы упадет ниже желаемого уровня. Это является значительным прогрессом в оценке устойчивости систем энергоснабжения ЦОД во время отключений.

Различные типы линейной регрессии для предсказания энергопотребления в ЦОД тестировались [25]. Авторами [26] освещается применение МО в сочетании с аддитивным объяснением SHapley (SHapley Additive exPlanation (SHAP)) для отбора параметров, влияющих на энергоэффективность и надежность работы ЦОД. Метод был протестирован на данных реального ЦОД, сравнивались модели Random Forest, Extreme Gradient Boosting, TreeSHAP, kernelSHAP. SHAP позволил улучшить модели прогнозирования и снизить вычислительные затраты по сравнению с другими методами.

2.1.2. Модели отказов систем отопления, вентиляции и кондиционирования

В большинстве исследований в качестве показателя энергоэффективности ЦОД использовался параметр Power Usage Effectiveness (PUE). Авторы [27] использовали модели МО, включая искусственные нейронные сети (ИНС) и деревья решений (Light Gradient Boosting Machine, Recurrent Neural Network, Random Forest), чтобы предсказать PUE и оптимизировать работу систем охлаждения (например, за счет регулировки потока воды в охладителях). Подход к оптимизации охлаждения в ЦОД на основе линейной регрессии [11] продемонстрировал, что за счет

небольшого повышения температуры в ЦОД можно существенно увеличить энергоэффективность охлаждения. Так, при повышении температуры с 19,73 до 21,17 °С мощность, затрачиваемая на охлаждение, уменьшилась с 607 до 414 кВт.

В работе [28] сравнивалась производительность 6 моделей: регрессия опорных векторов (Support Vector Regression), регрессия на основе гауссовских процессов (Gaussian Process Regression), экстремальный градиентный бустинг (eXtreme Gradient Boosting, XGBoost), градиентный бустинг с открытым исходным кодом (Light Gradient-Boosting Machine (LightGBM)), ИНС и LSTM в их способности предсказывать температуру в воздушно-охлаждаемых ЦОД в стабильных и нестабильных сценариях (например, при отказе системы охлаждения). В ходе симуляций XGBoost и LightGBM показали наилучшие результаты в обоих сценариях. Метод прогнозирования эффективности инфраструктуры охлаждения ЦОД с использованием МО [29] использовался для прогнозирования коэффициента полезного действия системы горячего водяного охлаждения в суперкомпьютерном ЦОД.

Подход [30] на основе глубокого обучения позволил улучшить эффективность системы охлаждения в ЦОД на 22 % по сравнению с традиционными алгоритмами. Применение RNN в системах управления HVAC улучшило прогноз температуры и воздушного потока, сводя к минимуму потери энергии в результате переохлаждения [31, 32]. Комбинация сверточной нейронной сети и стековой многослойной двунаправленной LSTM для теплового прогнозирования позволила достичь наибольшего значения R^2 = 97,15 % и уменьшить уровень ошибок RMSE до 0,2892 [33].

Метод диагностики неисправностей системы HVAC в ЦОД [8] основан на генеративно-состязательных нейронных сетях (Generative Adversarial Network (GAN)) и методе опорных векторов (Support Vector Machine). Поскольку данных о неисправностях в реальных условиях недостаточно, GAN использовалась для генерации новых данных о неисправностях и дополнения обучающей выборки, что помогло сбалансировать данные и повысить точность моделей. Авторами [34] разработана модель на основе адаптивной модели ИНС (Adaptive Artificial Neural Network Model (AAM)) и алгоритма оптимального управления для системы охлаждения в ЦОД. Модель AAM обучалась в реальном времени, что позволило ей адаптироваться к изменениям в окружающей среде и поддерживать стабильную работу системы. Предложенный подход позволил снизить энергопотребление без необходимости модернизировать существующее оборудование.

В работе [6] методы обучения с подкреплением применялись для оптимизации охлаждения в ЦОД. В статье используют модель предсказательного управления (Model Predictive Control (MPC)) на основе авторегрессионной модели с экзогенным входом (Autoregressive Model with Exogenous Input, ARX model), которая позволяет эффективно регулировать температуру и поток воздуха, улучшая энергосбережение. Эксперименты показали, что MPC более эффективно снижает затраты по сравнению с традиционными методами, обеспечивая оптимальные условия для работы оборудования.

2.2. Датасеты

Рассмотренные датасеты представляют собой наборы числовых данных, сопоставленные идентификаторам источника данных и/или временным меткам. Датасеты размещены на платформах Zenodo, Kaggle, IEEE Xplore, Mendeley, для части из них есть открытый доступ, для части к просмотру доступны только метаданные.

Большая часть данных собрана непосредственно с объектов инфраструктуры ЦОД: серверов, сетевых устройств, жестких дисков, процессоров, карт памяти, систем отопления, вентиляции, кондиционирования [6, 26, 27, 29, 35–43]. В ходе лабораторных экспериментов на стенде были получены данные о работе HVAC

в различных режимах [44–48]. Часть датасетов была получена с использованием физического [48] или программного [30, 47] моделирования.

Датасеты содержат технические и эксплуатационные данные ЦОД, такие как характеристики аппаратного обеспечения (серверов [25], жестких дисков [37, 39], систем охлаждения [26, 29, 30, 44, 46, 48]), данные сетевого трафика (журналы событий, регистрации активности пользователей) [38, 45], энергопотребление [25], распределение нагрузки на оборудование [6, 35, 40, 41, 47], параметры окружающей среды (температура, влажность, давление) [27]. Датасет [36] содержит информацию о географическом положении ЦОД крупных технологических компаний. Преобладают международные проекты, например проекты из США [6, 30, 35, 37, 39, 44], Германии [29], Италии [26], Китая [27], Таиланда [43].

3. Результаты

3.1. Анализ ИИ-подходов к прогнозированию отказов

Таким образом, в рамках проблемы прогнозирования отказов в ЦОД можно выделить две задачи:

1. Прогноз поведения системы в штатном режиме.
2. Прогноз аварийных событий в системе.

Хотя вышеуказанные модели демонстрируют значительный прогресс в поддержании работоспособности обеспечивающих инженерных систем центров обработки данных, остаются проблемы адаптации этих систем к различным реальным сценариям и обеспечения их устойчивости к непредвиденным сбоям. Таким образом, выбор конкретной модели или комбинации моделей зависит от особенностей объекта ЦОД, требований к надежности и возможности сбора данных. Применяя комплексный подход, специалисты по эксплуатации ЦОД могут не только оценивать текущую надежность системы, но и прогнозировать ее поведение, что позволяет реализовывать своевременное техническое обслуживание и повышать общую отказоустойчивость ЦОД.

Задачи прогноза в ЦОД могут быть решены, например, с использованием графового нейросетевого подхода, который связан с преобразованием потока входных данных в графовые структуры [15]. Графовые нейросетевые архитектуры способны моделировать пространственно-временные зависимости между параметрами состояния ЦОД. Авторами настоящей работы представлен подход к прогнозированию отказов инженерных систем ЦОД, в котором временные ряды с датчиков, размещенных в ЦОД, могут быть преобразованы в графовые структуры, подаваемые на вход графовых нейронных сетей. Такой подход перспективен для задач прогнозирования в условиях высокой взаимосвязанности компонентов и динамически меняющихся условий работы ЦОД.

3.2. Анализ датасетов

На рис. 1 представлен анализ покрытия рассмотренными датасетами доменов инженерных систем ЦОД: энергоснабжение, HVAC, жесткие диски, сетевой трафик, инфраструктура в целом.

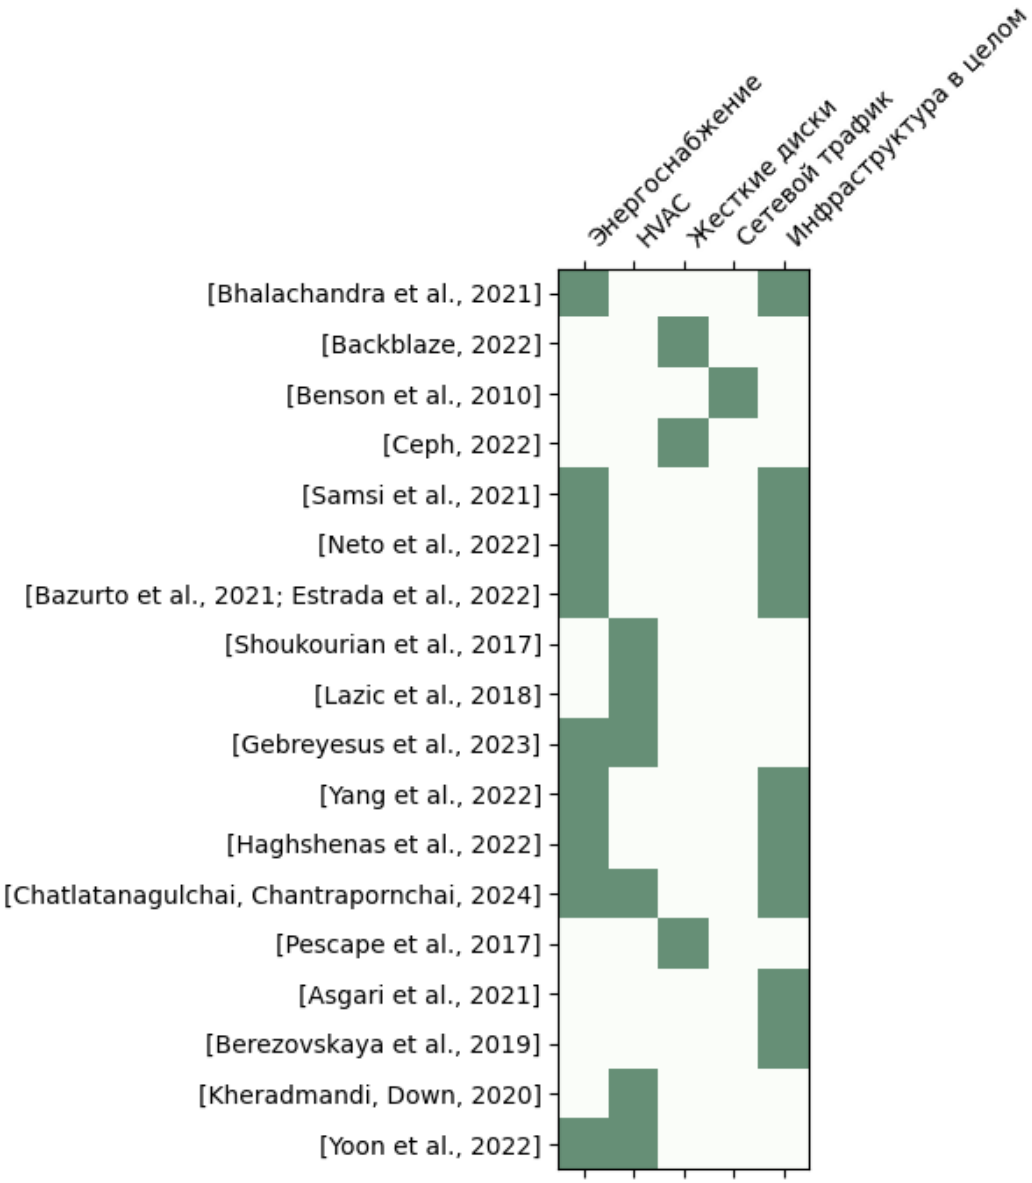

Рис. 1. Покрытие доменов инженерных систем рассмотренными датасетами

Для задач прогноза отказов в системах HVAC и энергоснабжения ЦОД наибольшую практическую ценность представляют датасеты, содержащие временные ряды параметров работы оборудования (температура, влажность, ток, напряжение и пр.), метки событий или аномалий (или возможность их сгенерировать), высокую частоту сбора данных (предпочтителен опрос датчиков каждую секунду или каждую минуту), подробное описание конфигурации инфраструктуры (HVAC/ИБП и т. д.), реальные эксплуатационные условия или реалистичную симуляцию отказов.

Из проведенного обзора наиболее пригодными датасетами представляются Data Server Energy Consumption Dataset [25] и Kasetsart University Data Center Dataset [43], которые имеют приемлемую периодичность сбора данных. Однако в датасетах [25, 43] отсутствует разметка об отказах оборудования.

Датасет [46] представляет собой подходящий симулированный кейс, который содержит данные температур, скорости воздуха, давления, а также данные об отказе вентиляторов. HVAC Multizone Dataset [44] содержит данные контролируемого эксперимента о температуре, давлении, влажности, инсоляции, параметрах HVAC, собранные с периодичностью в 1 минуту.

Наименее пригодны для анализа датасеты [37, 39], которые содержат данные только о жестких дисках, датасет [45] с данными сетевого трафика, датасет [36], который содержит только информацию о географическом положении ЦОД.

3.3. Предлагаемый подход к прогнозированию отказов

Для контроля над температурным режимом и утечками в ЦОД предполагается следующая схема размещения датчиков (рис. 2):

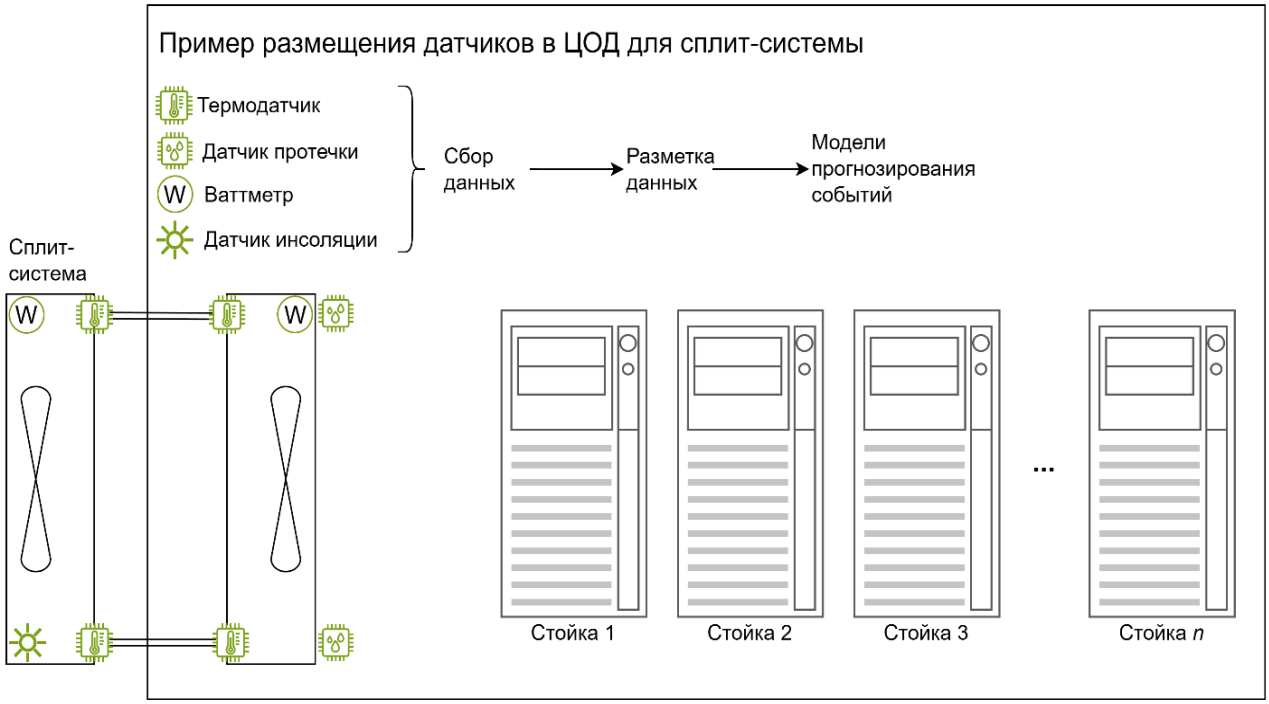

Рис. 2. Схема размещения датчиков в ЦОД (пример для сплит-системы)

Четыре термодатчика устанавливаются на трубах сплит-системы:

- два – на вход/выход наружного блока (у радиатора);
- два – на вход/выход внутреннего блока (у радиатора).

Датчик инсоляции монтируется на наружный блок, датчик протечки – под радиатором внутреннего блока. Датчики протечки необходимы при использовании жидкостного охлаждения или увлажнителей. Они размещаются под сплит-системами, в местах соединений труб, около клапанов и кранов.

Дополнительные термодатчики могут устанавливаться:

- в холодных и горячих коридорах;
- в инженерных помещениях (насосные, АКБ, ГРЩ и др.).

Дополнительно могут быть установлены портативные метеостанции снаружи и внутри здания, чтобы измерять температуру, влажность, давление, скорость и направление ветра. Ваттметры могут быть установлены на каждую серверную стойку, на внутренний и внешний блоки кондиционеров, счетчики сетевого трафика – на каждую стойку. Тепловизоры (один или несколько) размещаются таким образом, чтобы охватить всю площадь машинного зала.

Данные от каждого датчика записываются с заданной периодичностью (например, раз в 1 секунду, раз в 60 секунд) в следующем формате: «временная метка», «вектор измеренных значений». Файлы с собранными данными сохраняются в базе данных, откуда они могут быть доступны для дальнейшего анализа или скачивания пользователями.

Наконец, для предсказания событий на основе временного ряда с использованием графовых сверточных сетей (Graph Convolutional Network (GCN)), временной ряд сначала разбивается на окна фиксированной длины (рис. 3).

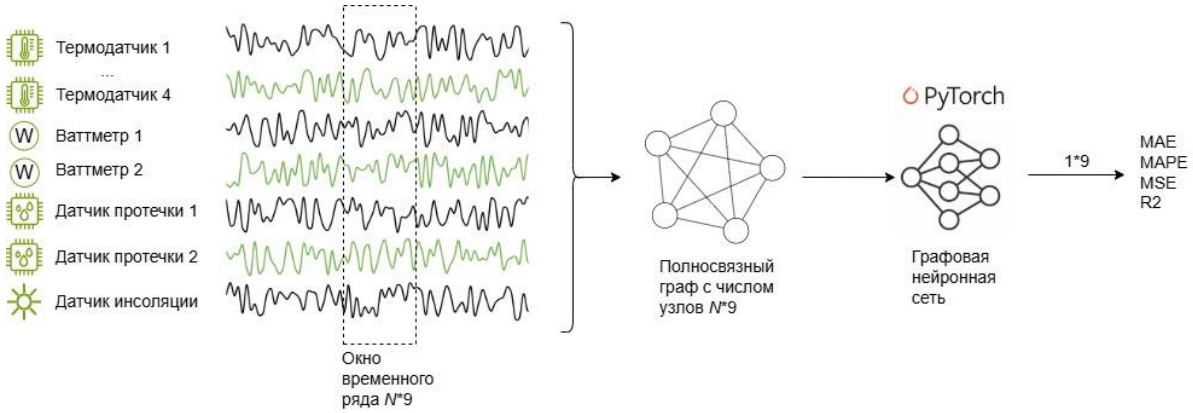

Рис. 3. Граф-структурированный подход к анализу данных с датчиков в ЦОД

Каждое окно преобразуется в граф, где узлы соответствуют временным шагам, а ребра отражают зависимости между ними (например, по времени или корреляции между измерениями). Веса ребер могут быть бинарными или пропорциональными силе этих зависимостей. Затем граф подается в GCN, где выполняются свертки по узлам графа с учетом их соседей. После нескольких слоев сверток применяются операции пулинга, которые агрегируют информацию от всех узлов и уменьшают размер представления. Полученные данные передаются в полносвязную сеть, которая преобразует их в окончательное представление. На выходе обычно используется softmax для предсказания вероятностей различных событий, происходящих в следующие промежутки времени. Также можно задавать различные горизонты прогнозирования. Такой подход позволяет учитывать как временные, так и структурные зависимости во временном ряду, улучшая точность предсказаний.

4. Обсуждение

В настоящей работе представлен обзор современных подходов к построению прогностических моделей отказов инженерных систем с элементами ИИ. Рассмотрены архитектуры прогностических моделей и их применение к системам HVAC и энергоснабжения, а также проанализированы датасеты, используемые для обучения и тестирования моделей.

Большинство существующих моделей ориентированы на отдельные подсистемы (например, HVAC) и обучены выявлять ограниченное количество типов неисправностей подсистем ЦОД. Для практического внедрения ИИ-систем в управление ЦОД необходимы универсальные, интерпретируемые модели, учитывающие не только технические параметры, но и различные режимы работы ЦОД. Таким образом, направлением развития предиктивной аналитики в ЦОД являются: разработка комплексных моделей, способных учитывать взаимосвязь между различными инженерными системами ЦОД, использование гибридных подходов, сочетающих прогноз штатного поведения и оценку вероятности аварийных событий, повышение интерпретируемости моделей для интеграции в процессы эксплуатации и технического обслуживания, создание инструментов адаптивного обучения, позволяющих учитывать динамику реальных условий работы ЦОД.

Среди проанализированных датасетов только единичные содержат высокочастотные данные с разметкой о нештатных ситуациях, пригодные для обучения прогностических моделей. Это существенно ограничивает возможности разработки и тестирования моделей отказов по нескольким причинам. Во-первых, большинство доступных наборов данных содержат только нормальные режимы работы, что не позволяет формировать сбалансированные обучающие выборки. Во-вторых, отсутствие разметки событий снижает возможность применения методов контролируемого обучения и ведет к необходимости использовать синтетические данные или подходы без учителя. Наконец, в-третьих, низкая частота опроса

датчиков не отражает быстрых переходных процессов, критичных для диагностики отказов в HVAC и энергоснабжении. Следовательно, для практического внедрения прогностических моделей необходимы открытые датасеты, включающие реальные сценарии отказов и метки событий, более тесное взаимодействие исследователей и операторов ЦОД для совместного сбора и анонимизации эксплуатационных данных.

Авторами настоящей работы представлен подход к прогнозированию отказов инженерных систем ЦОД, в котором временные ряды с датчиков, размещенных в ЦОД, преобразуются в графовые структуры, подаваемые на вход графовых нейронных сетей. Такой подход перспективен для задач прогнозирования в условиях высокой взаимосвязанности компонентов и динамически меняющихся условий работы ЦОД.

Результаты настоящего обзора могут быть использованы при построении интеллектуальных систем мониторинга и предиктивного управления в ЦОД. Будущие исследования могут быть направлены на разработку моделей с улучшенной интерпретируемостью, формирование открытых размеченных датасетов, учитывающих не только параметры работы подсистем, но и информацию об условиях эксплуатации ЦОД.

5. Выводы

Существующие модели преимущественно сосредоточены на выявлении неисправностей отдельных подсистем (например, HVAC) и не охватывают комплексное управление ЦОД.

Для практического внедрения ИИ-систем в управление ЦОД необходимы универсальные, интерпретируемые модели, учитывающие не только технические параметры, но и различные режимы работы ЦОД.

Для обучения прогностических моделей необходимы открытые размеченные датасеты, включающие реальные сценарии отказов и различные типы неисправностей.

6. Благодарности

Статья подготовлена в ходе реализации Комплексного проекта научно-технологического развития «Платформа автоматического управления промышленными объектами информационной инфраструктуры на базе искусственного интеллекта на примере центров обработки данных (ЦОД)» (Соглашение № 25 от «14» мая 2025 г. с Фондом технологического развития промышленности Свердловской области).

Исследование частично выполнено за счет субсидий Минобрнауки РФ на выполнение научной темы FUMN-2024-0003.

7. Список литературы

1. International Energy Agency. Data centres and data transmission networks [Электронный ресурс]. – URL: https://www.iea.org/energy-system/buildings/data-centres-and-data-transmission-networks (дата обращения: 25.06.2025).
2. Cooling technologies for data centres and telecommunication base stations – A comprehensive review / Y. Zhang, Y. Zhao, S. Dai [et al.] // Journal of Cleaner Production. – 2022. – Vol. 334. – P. 130280.
3. Strategies for data center temperature control during a cooling system outage / M. Lin, S. Shao, X. Zhang [et al.] // Energy and Buildings. – 2014. – Vol. 73. – P. 146–152.
4. *Singh, V.* A comprehensive review: Fault detection, diagnostics, prognostics, and fault modeling in HVAC systems / V. Singh, J. Mathur, A. Bhatia // International Journal of Refrigeration. – 2022. – Vol. 144. – P. 283–295.

5. *Григорьев, А. А.* Анализ показателей работы центров обработки данных / А. А. Григорьев, Е. А. Исаев, В. Д. Пугачев // Приборы и системы. Управление, контроль, диагностика. – 2024. – № 5. – С. 32–38.
6. *Lazic, N*. Data Center Cooling Using Model-Predictive Control / N. Lazic, C. Boutilier, T. Lu [et al.] // Advances in Neural Information Processing Systems. – 2018. – Vol. 31.
7. *Gao, J.* Task Failure Prediction in Cloud Data Centers Using Deep Learning / J. Gao, H. Wang, H. Shen // IEEE Transactions on Services Computing. – 2020. – Vol. 15, No. 3. – P. 1411–1422.
8. *Du, Z.* Deep Learning GAN-Based Data Generation and Fault Diagnosis in the Data Center HVAC System / Z. Du, K. Chen, S. Chen [et al.] // Energy and Buildings. – 2023. – Vol. 289. – P. 113072.
9. *Taheri, S.* Learning-Based Power Prediction for Geo-Distributed Data Centers: Weather Parameter Analysis / S. Taheri, M. Goudarzi, O. Yoshie // Journal of Big Data. – 2020. – Vol. 7, No. 1. – P. 1–16.
10. *Григорьев, А. А.* Применение искусственного интеллекта в системах управления центрами обработки данных / А. А. Григорьев, Е. А. Исаев // Приборы и системы. Управление, контроль, диагностика. – 2025. – № 1. – С. 18–27.
11. *Kumar, R*. Power Usage Efficiency (PUE) Optimization with Counterpointing Machine Learning Techniques for Data Center Temperatures / R. Kumar, S. K. Khatri, M. J. Diván // International Journal of Mathematical, Engineering and Management Sciences. – 2021. – Vol. 6, No. 6. – P. 1594.
12. *Xie, S.* A Decision Tree-Based Online Traffic Classification Method for QoS Routing in Data Center Networks / S. Xie, G. Hu, X. Wang [et al.] // Security and Communication Networks. – 2022. – Vol. 2022, No. 1. – P. 9419676.
13. *Relli, G. K.* Task Failure Prediction in Cloud Data Centers Using Deep Learning / G. K. Relli, S. U. M. Rao, M. Tech, [et al.] // Journal of Survey in Fisheries Sciences. – 2023. – P. 2742–2749.
14. *Sergeev, A. P.* Preprocessing of the Initial Data with Discrete Wavelet Transform to Predict Time Series Using LSTM / A. P. Sergeev, A. S. Butorova, A. V. Shichkin // 2024 8th Scientific School Dynamics of Complex Networks and their Applications (DCNA). – IEEE, 2024. – P. 216–219.
15. Application of graph-structured data for forecasting the dynamics of time series of natural origin / V. Bobakov, S. Kuzmin, A. Butorova [et al.] // Eur. Phys. J. Spec. Top. –2024.
16. A permutation approach to evaluating the performance of a forecasting model of methane content in the atmospheric surface layer of arctic region / A. Sergeev, A. Shichkin, E. Baglaeva [et al.] // Atmospheric Pollution Research. – 2024. – Vol. 15, No. 2. – P. 102000.
17. ГОСТ Р 57723–2017. Информационно-коммуникационные технологии в образовании. Системы электронно-библиотечные. Общие положения : национальный стандарт Российской Федерации : утв. Приказом Федерального агентства по техническому регулированию и метрологии от 28 сентября 2017 г. № 1262-ст : введён впервые. – М. : Стандартинформ, 2017. – URL: https://docs.cntd.ru/document/1200156825 (дата обращения: 21.06.2025).
18. Энергоэффективность центра обработки данных как совокупности инженерной и ИТ инфраструктуры / М. Б. Амзараков, Р. Р. Сухов, Е. А. Исаев, А. М. Амзаракова // Приборы и системы. Управление, контроль, диагностика. – 2019. – № 12. – С. 50–55.
19. Совершенствование систем охлаждения серверных / А. И. Катунина, Е. В. Жигулина, Д. Р. Ильясов, Н. С. Люльченко // Энергобезопасность и энергосбережение. – 2024. – № 2. – С. 65–69.
20. *Бусахин, А. В.* Современные системы охлаждения ЦОД в России / А. В. Бусахин, Е. В. Халфин // АВОК: Вентиляция, отопление, кондиционирование воздуха, теплоснабжение и строительная теплофизика. – 2025. – № 2. – С. 56–63.
21. *Скворцова, Т. И.* Аналитический обзор программных решений проектирования архитектуры ЦОД / Т. И. Скворцова // Промышленные АСУ и контроллеры. – 2025. – № 8. – С. 123–139.
22. Towards Thermal-Aware Workload Distribution in Cloud Data Centers Based on Failure Models / J. Li, Y. Deng, Y. Zhou [et al.] // IEEE Transactions on Computers. – 2022. – Vol. 72, No. 2. – P. 586–599.
23. Machine Learning-Based Bridge Cable Damage Detection Under Stochastic Effects of Corrosion and Fire / J. Feng , K. Gao, W. Gao [et al.] // Engineering Structures. – 2022. – Vol. 264. – P. 114421.

24. Müller, U. Resilience of Data Centre Power System: Modelling of Sustained Operation Under Outage, Definition of Metrics, and Application / U. Müller, K. Strunz // The Journal of Engineering. – 2019. – Vol. 2019, No. 12. – P. 8419–8427.
25. Learning-Based Energy Consumption Prediction / R. Estrada, V. Asanza, D. Torres [et al.] // Procedia Computer Science. – 2022. – Vol. 203. – P. 272–279.
26. Machine learning for data center optimizations: feature selection using Shapley additive exPlanation (SHAP) / Y. Gebreyesus, D. Dalton, S. Nixon [et al.] // Future Internet. – 2023. – Vol. 15, No. 3. – P. 88.
27. Increasing the Energy Efficiency of a Data Center Based on Machine Learning / Z. Yang, J. Du, Y. Lin [et al.] // Journal of Industrial Ecology. – 2022. – Vol. 26, No. 1. – P. 323–335.
28. Thermal prediction for air-cooled data center using data driven-based model / J. Lin, W. Lin, W. Lin [et al.] // Applied Thermal Engineering. – 2022. – Vol. 217. – P. 119207.
29. Using machine learning for data center cooling infrastructure efficiency prediction / H. Shoukourian, T. Wilde, D. Labrenz, A. Bode // 2017 IEEE International Parallel and Distributed Processing Symposium Workshops (IPDPSW). IEEE, 2018. – P. 954–963.
30. Reinforcement learning testbed for power-consumption optimization / T. Moriyama, G. De Magistris, M. Tatsubori [et al.] // Methods and Applications for Modeling and Simulation of Complex Systems: 18th Asia Simulation Conference, AsiaSim 2018, Kyoto, Japan, October 27–29, 2018, Proceedings 18. Springer Singapore, 2018. – P. 45–59.
31. Computational Engineering Based Approach on Artificial Intelligence and Machine Learning-Driven Robust Data Centre for Safe Management / G. Senthilkumar, P. Rajendran, Y. Suresh // Journal of Machine and Computing. – 2023. – Vol. 465–474.
32. *Darla, R. B.* A Comprehensive Review of Distributed Power System Architecture for Telecom and Datacenter Applications / R. B. Darla, A. Chitra // International Journal of Power Electronics and Drive Systems. – 2021. – Vol. 12, No. 3. – P. 1535–1555.
33. *Tabrizchi, H.* Thermal Prediction for Energy Management of Clouds Using a Hybrid Model Based on CNN and Stacking Multi-Layer Bi-Directional LSTM / H. Tabrizchi, J. Razmara, A. Mosavi // Energy Reports. – 2023. – Vol. 9. – P. 2253–2268.
34. Development of an adaptive artificial neural network model and optimal control algorithm for a data center cyber–physical system / Y. J. Choi, B. R. Park, J. Y. Hyun [et al.] // Building and Environment. – 2022. – Vol. 210. – P. 108704.
35. *Bhalachandra, S.* NERSC Cori Power Consumption 2020 [Data Set] / S. Bhalachandra, B. Austin, N. Wright // Zenodo. 2021 [Электронный ресурс]. – URL: https://dx.doi.org/10.5281/zenodo.4678113 (дата обращения: 25.06.2025).
36. *Amiri, F.* DataCenterMap: Top Tech Companies / F. Amiri [Электронный ресурс]. – URL: https://www.kaggle.com/datasets/farnazamiri/datacentermap-toptechcompanies (дата обращения: 25.06.2025).
37. Backblaze. Hard Drive Reliability – Failure Prediction [Электронный ресурс]. –URL: https://www.kaggle.com/datasets/thedevastator/hard-drive-reliability-data-set (дата обращения: 25.06.2025).
38. *Benson, T.* Network Traffic Characteristics of Data Centers in the Wild / T. Benson, A. Akella, D. A. Maltz // Proceedings of the 10th ACM SIGCOMM Conference on Internet Measurement. – 2010. – P. 267–280.
39. Ceph. Ceph Drive Telemetry Data [Электронный ресурс]. – URL: https://www.kaggle.com/datasets/chauhankaranraj/ceph-drive-telemetry-data (дата обращения: 25.06.2025).
40. The MIT Supercloud Dataset / S. Samsi, M. L. Weiss, D. Bestor [et al.] // 2021 IEEE High Performance Extreme Computing Conference (HPEC). – IEEE, 2021. – P. 1–8.
41. *Neto, W. L.* DC Health Node Performance Data From a Real Datacenter of the Instituto Metropole Digital/UFRN / W. L. Neto, I. de Morais Barroca Filho, J. S. Nunes // IEEE Dataport. – 2022. [Электронный ресурс]: https://dx.doi.org/10.21227/e870-4e87 (дата обращения: 25.06.2025).
42. MAGNETIC: Multi-Agent Machine Learning-Based Approach for Energy Efficient Dynamic Consolidation in Data Centers / K. Haghshenas, A. Pahlevan, M. Zapater [et al.] // IEEE Transactions on Services Computing. – 2022. – Vol. 15, No. 1. – P. 30–44.
43. *Chatlatanagulchai, W.* Energy Consumption Data Collection: Case Study on Data Center in a Thai University / W. Chatlatanaguchai, C. Chantrapornchai // Energy Informatics. – 2024. – Vol. 7. – P. 26.
44. Datasets of a Multizone Office Building Under Different HVAC System Operation Scenarios / Y. Yoon, S. Jung, P. Im, A. Gehl // Scientific Data. – 2022. – Vol. 9, No. 1. – P. 775.

45. Cloud Interdatacenter Network Performance dataset / A. Pescape, V. Persico, A. Montieri, A. Botta [Электронный ресурс]: https://data.mendeley.com/datasets/tvpj528mwz/1 (дата обращения: 25.06.2025).
46. A Gray-Box Model for Real-Time Transient Temperature Predictions in Data Centers / S. Asgari, S. MirhoseiniNejad, H. Moazamigoodarzi [et al.] // Applied Thermal Engineering. – 2021. – Vol. 185. – P. 116319.
47. A Hybrid Fault Detection and Diagnosis Method in Server Rooms' Cooling Systems / Y. Berezovskaya, C.-W. Yang, A. Mousavi [et al.] // IEEE 17th International Conference on Industrial Informatics (INDIN). IEEE, 2019. – P. 1405–1410.
48. *Kheradmandi, M.* Data driven fault tolerant thermal management of data centers / M. Kheradmandi, D. G. Down // 2020 International Conference on Computing, Networking and Communications (ICNC). – IEEE, 2020. – P. 736–740.

Сведения об авторах:

Буторова Анастасия Сергеевна, ассистент учебно-научного центра «Искусственный интеллект» ИРИТ-РтФ УрФУ, младший научный сотрудник лаборатории искусственного интеллекта и сложных систем Института промышленной экологии УрО РАН, г. Екатеринбург, Россия; эл. почта: a.s.butorova@urfu.ru;

Борисов Василий Ильич, к. т. н., доцент учебно-научного центра «Искусственный интеллект» ИРИТ-РтФ УрФУ, г. Екатеринбург, Россия;

Сергеев Александр Петрович, к. ф.-м. н., доцент учебно-научного центра «Искусственный интеллект» ИРИТ-РтФ УрФУ, ведущий научный сотрудник, и. о. заведующего лабораторией искусственного интеллекта и сложных систем Института промышленной экологии УрО РАН, г. Екатеринбург, Россия;

Ронкин Михаил Владимирович, к. т. н., доцент учебно-научного центра «Искусственный интеллект» ИРИТ-РтФ УрФУ, г. Екатеринбург, Россия;

Бобаков Вениамин Сергеевич, лаборант лаборатории искусственного интеллекта и сложных систем Института промышленной экологии УрО РАН, г. Екатеринбург, Россия;

Иванов Сергей Сергеевич, аспирант ИРИТ-РтФ УрФУ, г. Екатеринбург, Россия;

Поляков Станислав Олегович, старший преподаватель учебно-научного центра «Искусственный интеллект» ИРИТ-РтФ УрФУ, г. Екатеринбург, Россия;

Игнатков Кирилл Александрович, к. т. н., доцент, и. о. замдиректора по науке ИРИТ-РтФ УрФУ, г. Екатеринбург, Россия;

Чернышов Юрий Юрьевич, к. ф.-м. н., доцент учебно-научного центра «Искусственный интеллект», заведующий учебно-научным центром «Информационная безопасность» ИРИТ-РтФ УрФУ, г. Екатеринбург, Россия; руководитель исследовательского центра ООО «Сайберлимфа», г. Москва, Россия;

Скороходов Андрей Владимирович, руководитель исследовательского проекта ООО «Сайберлимфа», г. Москва, Россия;

Манжуров Александр Игоревич, аспирант ИРИТ-РтФ УрФУ, г. Екатеринбург, Россия; младший исследователь ООО «Сайберлимфа», г. Москва, Россия.

PREDICTIVE MODELS OF DATA CENTER ENGINEERING SYSTEMS BASED ON ARTIFICIAL INTELLIGENCE: A REVIEW OF ARCHITECTURES AND DATASETS

A. S. Butorova [1,2], V. I. Borisov [1], A. P. Sergeev [1,2], M. V. Ronkin [1], V. S. Bobakov [2], S. S. Ivanov [1], S. O. Polyakov [1], K. A. Ignatkov [1], Y. Y. Chernyshov [1,3], A. V. Skorokhodov [3], A. I. Manzhurov [1,3]

[1] Ural Federal University named after the first President of Russia B.N. Yeltsin, Ekaterinburg, Russia
[2] Institute of Industrial Ecology of the Ural Branch of the Russian Academy of Sciences, Ekaterinburg, Russia
[3] Cyberlimpha LLC, Moscow, Russia

This review addresses the problem of failure prediction in data centers' (DCs) critical engineering systems. Modern DCs play a pivotal role in digital infrastructure, enabling the continuous operation of cloud services, telecommunications, and enterprise systems. As key elements of digital infrastructure, modern DCs ensure the continuous operation of cloud services, telecommunications, and enterprise systems. The growing computational demand leads to increased energy consumption and greater strain on engineering subsystems – primarily power supply and Heating, Ventilation, and Air Conditioning (HVAC) systems. The inefficient operation of these systems not only raises operational costs but also increases the risk of DC failures. The present work provides a comprehensive review of contemporary approaches to building failure prediction models for DC critical engineering systems using artificial intelligence techniques. It examines predictive modeling approaches and datasets used for model training, collected from both real-world and simulated environments. Special attention is given to neural network architectures, including Recurrent Neural Networks (RNNs), Convolutional Neural Networks (CNNs), Long Short-Term Memory (LSTM), and generative adversarial networks (GANs). The review also highlights challenges such as the scarcity of labeled datasets and the limited adaptability and interpretability of existing predictive models. The review's findings can inform the development of intelligent monitoring and predictive maintenance systems for DCs.

Key words: data center (DC); energy consumption; power supply; heating; ventilation; air conditioning; HVAC; artificial intelligence (AI); machine learning (ML); failure prediction.

References

1. International Energy Agency. Data centres and data transmission networks [Электронный ресурс]. – URL: https://www.iea.org/energy-system/buildings/data-centres-and-data-transmission-networks (дата обращения: 25.06.2025).
2. Cooling technologies for data centres and telecommunication base stations – A comprehensive review / Y. Zhang, Y. Zhao, S. Dai [et al.] // Journal of Cleaner Production. – 2022. – Vol. 334. – P. 130280.
3. Strategies for data center temperature control during a cooling system outage / M. Lin, S. Shao, X. Zhang [et al.] // Energy and Buildings. – 2014. – Vol. 73. – P. 146–152.
4. *Singh, V.* A comprehensive review: Fault detection, diagnostics, prognostics, and fault modeling in HVAC systems / V. Singh, J. Mathur, A. Bhatia // International Journal of Refrigeration. – 2022. – Vol. 144. – P. 283–295.
5. Grigoriev A. A., Isaev E. A., Pugachev V. D. Analiz pokazateley raboty tsentrov obrabotki dannykh [Data center performance analysis] // Pribory i sistemy. Upravleniye, kontrol', diagnostika. – 2024. – No. 5. – P. 32–38. [in Russian]
6. *Lazic, N*. Data Center Cooling Using Model-Predictive Control / N. Lazic, C. Boutilier, T. Lu [et al.] // Advances in Neural Information Processing Systems. – 2018. – Vol. 31.
7. *Gao, J.* Task Failure Prediction in Cloud Data Centers Using Deep Learning / J. Gao, H. Wang, H. Shen // IEEE Transactions on Services Computing. – 2020. – Vol. 15, No. 3. – P. 1411–1422.

8. *Du, Z.* Deep Learning GAN-Based Data Generation and Fault Diagnosis in the Data Center HVAC System / Z. Du, K. Chen, S. Chen [et al.] // Energy and Buildings. – 2023. – Vol. 289. – P. 113072.
9. *Taheri, S.* Learning-Based Power Prediction for Geo-Distributed Data Centers: Weather Parameter Analysis / S. Taheri, M. Goudarzi, O. Yoshie // Journal of Big Data. – 2020. – Vol. 7, No. 1. – P. 1–16.
10. Grigoriev A. A., Isaev E. A. Primeneniye iskusstvennogo intellekta v sistemakh upravleniya tsentrami obrabotki dannykh [The use of artificial intelligence in data center management systems] // Pribory i sistemy. Upravleniye, kontrol', diagnostika. – 2025. – No. 1. – P. 18–27. [in Russian]
11. *Kumar, R*. Power Usage Efficiency (PUE) Optimization with Counterpointing Machine Learning Techniques for Data Center Temperatures / R. Kumar, S. K. Khatri, M. J. Diván // International Journal of Mathematical, Engineering and Management Sciences. – 2021. – Vol. 6, No. 6. – P. 1594.
12. *Xie, S.* A Decision Tree-Based Online Traffic Classification Method for QoS Routing in Data Center Networks / S. Xie, G. Hu, X. Wang [et al.] // Security and Communication Networks. – 2022. – Vol. 2022, No. 1. – P. 9419676.
13. *Relli, G. K.* Task Failure Prediction in Cloud Data Centers Using Deep Learning / G. K. Relli, S. U. M. Rao, M. Tech, [et al.] // Journal of Survey in Fisheries Sciences. – 2023. – P. 2742–2749.
14. *Sergeev, A. P.* Preprocessing of the Initial Data with Discrete Wavelet Transform to Predict Time Series Using LSTM / A. P. Sergeev, A. S. Butorova, A. V. Shichkin // 2024 8th Scientific School Dynamics of Complex Networks and their Applications (DCNA). – IEEE, 2024. – P. 216–219.
15. Application of graph-structured data for forecasting the dynamics of time series of natural origin / V. Bobakov, S. Kuzmin, A. Butorova [et al.] // Eur. Phys. J. Spec. Top. –2024.
16. A permutation approach to evaluating the performance of a forecasting model of methane content in the atmospheric surface layer of arctic region / A. Sergeev, A. Shichkin, E. Baglaeva [et al.] // Atmospheric Pollution Research. – 2024. – Vol. 15, No. 2. – P. 102000.
17. GOST R 57723–2017. Informatsionno-kommunikatsionnyye tekhnologii v obrazovanii. Sistemy elektronno-bibliotechnyye. Obshchiye polozheniya [Information and communication technologies in education. Electronic library systems. General provisions] : natsional'nyy standart Rossiyskoy Federatsii : utv. Prikazom Federal'nogo agentstva po tekhnicheskomu regulirovaniyu i metrologii ot 28-09-2017 No. 1262-st : vvedon vpervyye. — M.: Standartinform, 2017. — URL: https://docs.cntd.ru/document/1200156825 (accessed 21.06.2025). [in Russian]
18. Amzarakov M. B., Sukhov R. R., Isaev Ye. A., Amzarakova A.M. Energoeffektivnost' tsentra obrabotki dannykh kak sovokupnosti inzhenernoy i IT infrastruktury [Power usage effectiveness of the data center as a combination of engineering and IT infrastructure] // Pribory i sistemy. Upravleniye, kontrol', diagnostika. – 2019. – No. 12. – P. 50–55. [in Russian]
19. Katunina A. I., Zhigulina E. V., Iliasov D. R., Lulchenko N. S. Sovershenstvovaniye sistem okhlazhdeniya servernykh [Advanced data cen-ter cooling systems] // Energobezopasnost' i energosberezheniye. – 2024. – No 2. – P. 65–69. [in Russian]
20. Busakhin A. V., Khalfin E. V. Sovremennyye sistemy okhlazhdeniya TSOD v Rossii [Modern cooling systems of data centers in Russia] // AVOK: Ventilation, heating, air conditioning, heat supply and building thermal physics. – 2025. – No. 2. – P. 56–63. [in Russian]
21. Skvortsova T. I. Analiticheskiy obzor programmnykh resheniy proyektirovaniya arkhitektury TSOD [Analytical review of software solutions for data center architecture design] // Promyshlennyye ASU i kontrollery. – 2025. – No. 8. – P. 123–139 [in Russian]
22. Towards Thermal-Aware Workload Distribution in Cloud Data Centers Based on Failure Models / J. Li, Y. Deng, Y. Zhou [et al.] // IEEE Transactions on Computers. – 2022. – Vol. 72, No. 2. – P. 586–599.
23. Machine Learning-Based Bridge Cable Damage Detection Under Stochastic Effects of Corrosion and Fire / J. Feng , K. Gao, W. Gao [et al.] // Engineering Structures. – 2022. – Vol. 264. – P. 114421.
24. Müller, U. Resilience of Data Centre Power System: Modelling of Sustained Operation Under Outage, Definition of Metrics, and Application / U. Müller, K. Strunz // The Journal of Engineering. – 2019. – Vol. 2019, No. 12. – P. 8419–8427.
25. Learning-Based Energy Consumption Prediction / R. Estrada, V. Asanza, D. Torres [et al.] // Procedia Computer Science. – 2022. – Vol. 203. – P. 272–279.

26. Machine learning for data center optimizations: feature selection using Shapley additive exPlanation (SHAP) / Y. Gebreyesus, D. Dalton, S. Nixon [et al.] // Future Internet. – 2023. – Vol. 15, No. 3. – P. 88.
27. Increasing the Energy Efficiency of a Data Center Based on Machine Learning / Z. Yang, J. Du, Y. Lin [et al.] // Journal of Industrial Ecology. – 2022. – Vol. 26, No. 1. – P. 323–335.
28. Thermal prediction for air-cooled data center using data driven-based model / J. Lin, W. Lin, W. Lin [et al.] // Applied Thermal Engineering. – 2022. – Vol. 217. – P. 119207.
29. Using machine learning for data center cooling infrastructure efficiency prediction / H. Shoukourian, T. Wilde, D. Labrenz, A. Bode // 2017 IEEE International Parallel and Distributed Processing Symposium Workshops (IPDPSW). IEEE, 2018. – P. 954–963.
30. Reinforcement learning testbed for power-consumption optimization / T. Moriyama, G. De Magistris, M. Tatsubori [et al.] // Methods and Applications for Modeling and Simulation of Complex Systems: 18th Asia Simulation Conference, AsiaSim 2018, Kyoto, Japan, October 27 – 29, 2018, Proceedings 18. Springer Singapore, 2018. – P. 45–59.
31. Computational Engineering Based Approach on Artificial Intelligence and Machine Learning-Driven Robust Data Centre for Safe Management / G. Senthilkumar, P. Rajendran, Y. Suresh // Journal of Machine and Computing. – 2023. – Vol. 465–474.
32. *Darla, R. B.* A Comprehensive Review of Distributed Power System Architecture for Telecom and Datacenter Applications / R. B. Darla, A. Chitra // International Journal of Power Electronics and Drive Systems. – 2021. – Vol. 12, No. 3. – P. 1535–1555.
33. *Tabrizchi, H.* Thermal Prediction for Energy Management of Clouds Using a Hybrid Model Based on CNN and Stacking Multi-Layer Bi-Directional LSTM / H. Tabrizchi, J. Razmara, A. Mosavi // Energy Reports. – 2023. – Vol. 9. – P. 2253–2268.
34. Development of an adaptive artificial neural network model and optimal control algorithm for a data center cyber–physical system / Y. J. Choi, B. R. Park, J. Y. Hyun [et al.] // Building and Environment. – 2022. – Vol. 210. – P. 108704.
35. Bhalachandra S., Austin B., Wright N. NERSC Cori Power Consumption 2020 [Data Set] // Zenodo. 2021. [Electronic resource]: https://dx.doi.org/10.5281/zenodo.4678113 (accessed 25.06.2025).
36. Amiri F. DataCenterMap: Top Tech Companies [Electronic resource]. Available at: https://www.kaggle.com/datasets/farnazamiri/datacentermap-toptechcompanies (accessed 25.06.2025).
37. Backblaze. Hard Drive Reliability – Failure Prediction [Electronic resource]: https://www.kaggle.com/datasets/thedevastator/hard-drive-reliability-data-set (accessed 25.06.2025).
38. Benson T., Akella A., Maltz D. A. Network Traffic Characteristics of Data Centers in the Wild // Proceedings of the 10th ACM SIGCOMM Conference on Internet Measurement. – 2010. – P. 267–280.
39. Ceph. Ceph Drive Telemetry Data [Electronic resource]: https://www.kaggle.com/datasets/chauhankaranraj/ceph-drive-telemetry-data (accessed 25.06.2025).
40. Samsi S., Weiss M. L., Bestor D., Li B., Jones M., Reuther A., ..., Gadepally V. The MIT Supercloud Dataset // 2021 IEEE High Performance Extreme Computing Conference (HPEC). – IEEE, 2021. – P. 1–8.
41. Neto W. L., de Morais Barroca Filho I., Nunes J. S. DC Health Node Performance Data From a Real Datacenter of the Instituto Metropole Digital/UFRN // IEEE Dataport. 2022. [Electronic resource]: https://dx.doi.org/10.21227/e870-4e87 (accessed 25.06.2025).
42. Haghshenas K., Pahlevan A., Zapater M., Mohammadi S. Atienza D. MAGNETIC: Multi-Agent Machine Learning-Based Approach for Energy Efficient Dynamic Consolidation in Data Centers // IEEE Transactions on Services Computing. – 2022. – Vol. 15, No. 1. – P. 30–44.
43. Chatlatanagulchai W., Chantrapornchai C. Energy Consumption Data Collection: Case Study on Data Center in a Thai University // Energy Informatics. – 2024. – Vol. 7. – P. 26.
44. Yoon Y., Jung S., Im P., Gehl A. Datasets of a Multizone Office Building Under Different HVAC System Operation Scenarios // Scientific Data. – 2022. – Vol. 9, No. 1. – P. 775.
45. Pescape A., Persico V., Montieri A., Botta A. Cloud Interdatacenter Network Performance dataset. [Electronic resource]: https://data.mendeley.com/datasets/tvpj528mwz/1 (accessed 25.06.2025).
46. Asgari S., MirhoseiniNejad S., Moazamigoodarzi H., Gupta R., Zheng R., Puri I. K. A Gray-Box Model for Real-Time Transient Temperature Predictions in Data Centers // Applied Thermal Engineering. – 2021. – Vol. 185. – P. 116319.

47. Berezovskaya Y., Yang C.-W., Mousavi A., Zhang X., Vyatkin V. A Hybrid Fault Detection and Diagnosis Method in Server Rooms' Cooling Systems // IEEE 17th International Conference on Industrial Informatics (INDIN). – IEEE, 2019. – P. 1405–1410.
48. Kheradmandi M., Down D. G. Data driven fault tolerant thermal management of data centers // 2020 International Conference on Computing, Networking and Communications (ICNC). – IEEE, 2020. – P. 736–740.