

Анализ временных рядов физических характеристик ледовой арены с использованием технологий интернета вещей и машинного обучения

А.А. Карманов, П.В. Никитин

*Финансовый университет при правительстве Российской Федерации, Москва,
Российская Федерация*

Аннотация: В условиях климатического кризиса и роста стоимости энергоресурсов возрастает необходимость повышения энергоэффективности. Государства стремятся к сокращению выбросов углекислого газа, а бизнес — к оптимизации расходов на энергию. Цифровизация энергетики и внедрение технологий интернета вещей (IoT) создают условия для применения искусственного интеллекта (ИИ) в управлении энергопотреблением. В данной статье представлен обзор технологий ИИ и их применение в управлении энергопотреблением на примере ледовой арены. Проведен анализ данных энергопотребления, собранных с реального объекта, и рассмотрены методы нейросетевого моделирования временных рядов для прогнозирования и оптимизации управления. Представлены результаты моделирования, демонстрирующие потенциал использования предиктивных алгоритмов в снижении энергозатрат и повышении эффективности эксплуатации ледовых арен.

Ключевые слова: глобальное потепление, энергопотребление, энергоэффективность, цифровизация, интернет вещей, искусственный интеллект, управление энергопотреблением, машинное обучение, глубокое обучение, временные ряды, предиктивные алгоритмы

Введение

Современные экономические и экологические реалии заставляют предприятия и государства пересматривать подходы к энергопотреблению. По данным исследований, доля расходов на электроэнергию для крупных и средних предприятий в Российской Федерации составляет значительную часть общих затрат на производство товаров и услуг, колеблясь от 6% до 20% [1]. Спортивные сооружения, в частности ледовые арены, особенно подвержены высоким энергозатратам из-за необходимости поддержания специфических климатических условий, большого объема помещений и использования сложного оборудования.

Эффективное управление такими объектами представляет собой сложную задачу, требующую баланса между качеством предоставляемых услуг и оптимизацией энергопотребления. Ледовые арены включают в себя

различные зоны с разными сценариями использования и архитектурой [2]. Прогнозирование энергопотребления и уровня комфорта в помещениях зависит от множества факторов: функциональных особенностей объектов, климатических условий, интенсивности эксплуатации и других внешних факторов.

Развитие технологий интернета вещей (IoT) и цифровизация энергетики открывают новые возможности для оптимизации энергопотребления. Системы мониторинга и управления, основанные на IoT, позволяют собирать большие объемы данных в реальном времени, что создает предпосылки для применения методов искусственного интеллекта (ИИ) и машинного обучения (МО) в управлении энергопотреблением [3].

Цель данного исследования — изучение возможностей применения методов предиктивной аналитики и моделей глубокого обучения для прогнозирования параметров управления энергопотреблением ледовых арен. В статье представлен обзор существующих исследований в данной области, анализ данных, собранных с реального объекта, и результаты моделирования на основе нейросетевых архитектур.

Актуальность исследования

Глобальное потепление и связанные с ним климатические изменения требуют принятия срочных мер по сокращению выбросов парниковых газов. Одним из наиболее эффективных способов борьбы с климатическим кризисом является повышение энергоэффективности. Это не только способствует снижению выбросов CO₂, но и позволяет предприятиям сократить расходы на энергоресурсы.

В спортивной индустрии энергопотребление играет ключевую роль в операционных затратах. Ледовые арены потребляют значительные объемы энергии для поддержания ледового покрытия, систем отопления, вентиляции и кондиционирования воздуха (HVAC), освещения и других

вспомогательных систем. Оптимизация энергопотребления на таких объектах может привести к существенной экономии и снижению экологического следа.

Обзор исследований

Существующие подходы к оптимизации управления энергопотреблением спортивных сооружений можно разделить на два основных направления: методы, основанные на физических моделях, и методы, основанные на анализе данных.

Методы, основанные на физических моделях

Данный подход предполагает создание математических моделей физических процессов, происходящих в системе. Например, в работе [6] авторы разработали физическую модель для контроля теплового комфорта на футбольном стадионе в условиях жаркого и влажного климата с использованием методов вычислительной гидродинамики. В другом исследовании [7] предложена модель, основанная на прогнозах, использующая алгоритм многоцелевой генетической оптимизации для сокращения энергопотребления системами HVAC в бассейне. Эта модель включает информационное моделирование зданий (BIM) для создания базы исторических данных.

Преимуществом физических моделей является их способность точно описывать процессы на основе фундаментальных законов физики. Однако их разработка требует значительных усилий, наличия подробной информации о здании и системах, а также может быть сложной для комплексных структур.

Методы машинного обучения

С развитием технологий IoT и накоплением больших объемов данных методы, основанные на анализе данных, становятся все более популярными. Эти методы используют исторические данные для обучения моделей,

способных прогнозировать поведение системы и оптимизировать управление.

В теории управления процессами растет интерес к моделированию на основе прогноза, особенно для систем с многомерными временными рядами [9]. Метод управления на основе прогноза (Model Predictive Control, MPC) использует встроенную модель для прогнозирования будущего состояния системы и определения оптимальных управляющих воздействий с учетом ограничений.

Рекуррентные нейронные сети (RNN), особенно, архитектуры типа LSTM (Long Short-Term Memory) и GRU (Gated Recurrent Unit), эффективно используются для прогнозирования временных рядов благодаря их способности учитывать долгосрочные зависимости [10]. Сверточные нейронные сети (CNN) также применяются для анализа временных рядов, извлекая важные особенности из данных [11]. Комбинация RNN и CNN позволяет создавать гибридные модели, объединяющие преимущества обоих подходов [11].

Применение методов МО и ИИ в управлении энергопотреблением ледовых арен позволяет:

- Прогнозировать потребление энергии и температурные режимы с учетом различных факторов.
- Оптимизировать работу оборудования, снижая энергозатраты без ущерба для качества льда.
- Учитывать внешние и внутренние воздействия, такие, как погодные условия, расписание мероприятий, количество посетителей и т.д.
- Реагировать на изменения в реальном времени благодаря интеграции с системами IoT.

Набор данных

Для проведения исследования использовались данные, собранные с реальной ледовой арены, оборудованной системой мониторинга на базе IoT. Данные включают различные параметры, измеренные с интервалом в одну минуту, что позволяет анализировать динамику процессов с высокой детализацией.

Описание набора данных:

1. temp_ice – температура поверхности льда, °C
2. consumption_compressors – потребление суммы компрессоров, кВт*ч
3. temp_outside – внешняя температура, °C
4. hum_outside – относительная внешняя влажность, %
5. temp_inside – внутренняя температура над помещением ледового поля, °C
6. hum_inside – относительная внутренняя влажность над помещением ледового поля, %
7. max_motion – уровень движения на ледовой арене, у.е.
8. illuminance – уровень освещения на ледовой арене, у.е.
9. CO₂ – уровень углекислого газа на ледовой арене, ppm
10. temp_condensation – температура фреона в испарителе, °C
11. temp_supply_glyc – температура подачи теплоносителя (гликоля) в контур охлаждающих труб
12. temp_return_glyc – температура возвращаемого теплоносителя (гликоля) из контура охлаждающих труб

Перед началом моделирования данные были очищены от аномалий и пропусков. Были устранены накопления значений из-за прерываний в передаче данных и другие возможные искажения. Это обеспечило высокое качество обучающей выборки и повысило точность моделей.

Температура поверхности льда является ключевым параметром, влияющим на качество льда и энергопотребление. Целевым значением температуры льда для рассматриваемой арены является $-3,5^{\circ}\text{C}$. Анализ данных показал, что фактическая температура льда часто отклоняется от эталонного значения, что может приводить к увеличению энергозатрат и снижению качества льда.

На температуру льда влияют как внешние, так и внутренние факторы:

- **Внешние факторы:** температура и влажность окружающей среды, активность на льду (количество и интенсивность занятий), уровень освещения, уровень CO_2 .
- **Внутренние факторы:** работа холодильной установки (компрессоров, циркуляционных насосов, системы конденсации), температура и расход гликоля.

Так, на рисунке 1 видны пики, которые характеризуют фактор заливки, что приводит к повышению температуры льда, с последующим плавным затуханием до значения, стремящегося к целевому параметру. В среднем заливки проводятся от 7 до 12 раз в сутки, и, как показывает практика эксплуатации ледовых арен, время и частота проводимых заливок не зависят от расписания.

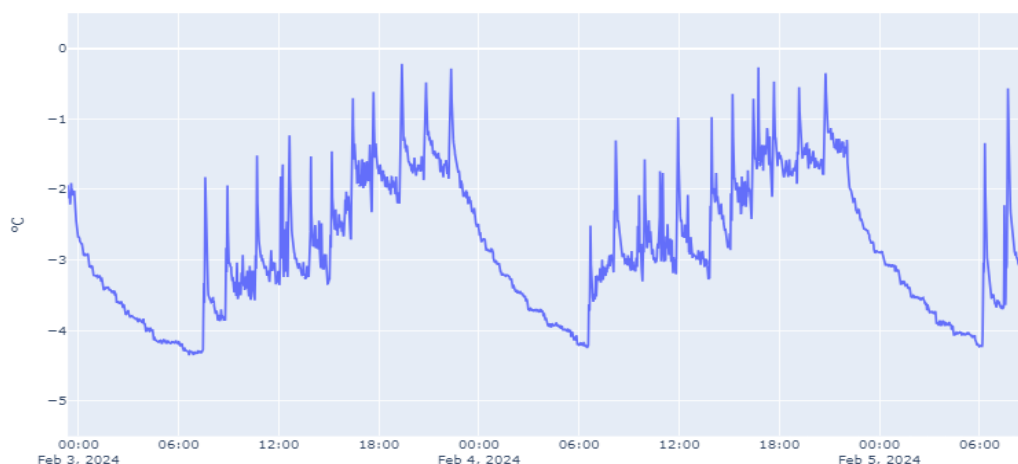


Рис. 1. – Динамика температуры льда в течение двух суток

Обслуживающий персонал зачастую исходит из своего опыта и наблюдений для принятия решений о проведении заливки, что является человеческим фактором. Из этого следует, что на лед оказывается резкое стохастическое воздействие в виде большого количества теплой разливаемой воды на поверхность. Температура воды может варьироваться от +45 до +60 °С, которая также зависит от обслуживающего персонала. Помимо этого, внешними факторами воздействия являются теплообмен с внутренней температурой воздуха арены и самого здания, на которое оказывает влияние внешняя атмосферная температура, а также уровень влажности, активность на льду и уровень теплового излучения от системы освещения.

В рассматриваемой работе собран набор данных при различных сценариях эксплуатации объекта, что должно улучшить обобщающие способности предиктивной модели.

Работа компрессоров осуществляется через уставку подаваемого теплоносителя, в данном случае гликоля, которую он должен поддерживать с гистерезисом ± 0.5 °С. Таким образом, реализация динамического изменения уставки теплоносителя позволит управлять мощностью компрессоров, влияя на температуру ледового покрытия.

Методология

Для прогнозирования температуры поверхности льда была разработана модель на основе рекуррентной нейронной сети LSTM. Модель использует временные ряды входных параметров за предыдущие 60 минут для прогнозирования температуры льда на 30 минут вперед. Архитектура LSTM была выбрана из-за ее способности учитывать долгосрочные зависимости во временных рядах и обрабатывать последовательные данные с высоким уровнем шума и вариабельности. Данные были разделены на обучающую (70%), валидационную (15%) и тестовую (15%) выборки. Для

предотвращения переобучения использовались методы регуляризации, такие как dropout и ранняя остановка. Обучение модели проводилось с использованием оптимизатора Adam и функции потерь MSE (Mean Squared Error).

Обсуждения

Результаты моделирования показали, что разработанная модель на основе рекуррентной нейронной сети LSTM способна прогнозировать температуру льда на арене с метриками качества: MSE – $0,25\text{ }^{\circ}\text{C}^2$; RMSE – $0,5\text{ }^{\circ}\text{C}$; MAE – $0,4\text{ }^{\circ}\text{C}$. Это свидетельствует о том, что модель справляется с общей динамикой изменения температуры льда. Однако модель не может точно предсказать резкие скачки температуры, связанные с процессом заливки льда, что снижает её эффективность при управлении холодильной машин. Пропуск большинства заливок указывает на то, что текущая архитектура модели имеет ограниченную способность к обработке краткосрочных изменений.

Для повышения точности прогнозирования краткосрочных аномальных событий в будущем можно рассмотреть более сложные подходы. Одним из перспективных направлений является использование автоэнкодеров, которые могут эффективно кодировать сложные зависимости в данных, помогая улучшить обработку многомерных временных рядов. В частности, вариационные автоэнкодеры (VAE) могут быть применены для генерации дополнительных признаков или восстановления недостающих данных, что может улучшить прогнозирование в ситуациях с резкими скачками температуры.

Еще одним перспективным направлением являются трансформеры, которые уже доказали свою эффективность в обработке последовательных данных в задачах обработки естественного языка. В контексте управления временными рядами трансформеры могут предложить значительное

улучшение по сравнению с традиционными рекуррентными сетями, поскольку они лучше справляются с длинными зависимостями и способны предсказать даже сложные и аномальные события, такие как заливки льда.

Включение этих методов в будущие исследования может значительно повысить точность прогнозирования и адаптивность системы к различным сценариям эксплуатации арены.

Заключение

Применение методов машинного обучения для управления энергопотреблением ледовых арен демонстрирует значительный потенциал. Разработанная модель на основе LSTM показала хорошую способность предсказывать температуру ледового покрытия, что позволяет использовать её в системах управления холодильным оборудованием. Однако ограничения в точности прогнозирования резких изменений, таких, как заливки, свидетельствуют о необходимости доработки модели для повышения её эффективности.

Перспективные направления улучшения включают в себя использование автоэнкодеров, которые могут помочь модели лучше захватывать сложные зависимости в данных и восстанавливать пропущенные события. Также перспективным направлением являются трансформеры, которые предлагают высокую точность в обработке последовательностей данных и могут улучшить способность модели предсказывать резкие изменения, такие как заливки льда.

Внедрение этих методов в будущие исследования позволит повысить точность прогнозирования и снизить энергозатраты, улучшая качество льда и продлевая срок службы оборудования. В целом, развитие подобных решений будет способствовать экономической эффективности и экологической устойчивости спортивных объектов, что является важной целью для бизнеса и общества.

Литература

1. Ивановский Б. Г. Проблемы и перспективы перехода к «зеленой» энергетике: опыт разных стран мира (Обзор) // Экономические и социальные проблемы России. 2022. №1(49). С. 58-78. DOI: 10.31249/espr/2022.01.04
 2. Li L., Liu X., Zhang T. Investigation of heat and mass transfer characteristics in the ice rink: Ice making, maintaining and resurfacing processes // Building and Environment. 2021. №196. P. 107779. DOI: 10.1016/j.buildenv.2021.107779
 3. Ложникова А. В., Эльмурзаева Р. А., Земцов А. А., Куделина О. В. Собственники и работники компаний-резидентов сколково: эмпирический анализ // Terra Economicus. 2023. №21(2). С. 84-100. DOI:10.18522/2073-6606-2023-21-2-84-100
 4. Rudin A. R. A., Lukman Audah, A. Jamil, Jiwa Abdullah. Occupancy monitoring system for campus sports facilities using the Internet of Things (IoT) // IEEE Conference on Wireless Sensors (ICWiSE). IEEE, 2016. pp. 100-105. DOI: 10.1109/ICWISE.2016.8188550
 5. Himeur Y., Ghanem K., Alsalemi A., Bensaali F., Amira A. Artificial intelligence based anomaly detection of energy consumption in buildings: A review, current trends and new perspectives // Applied Energy. 2021. №287. P. 116601. DOI: 10.1016/j.apenergy.2021.116601
 6. Losi G., Bonzanini A., Aquino A., Poesio P. Analysis of thermal comfort in a football stadium designed for hot and humid climates by CFS // Journal of Building Engineering. 2021. №33. P. 101599. DOI: 10.1016/j.jobe.2020.101599
-

7. Petri I., Kubicki S., Rezgui Y., Guerriero A., Li H. Optimizing energy efficiency in operating built environment assets through building information modeling: A case study // *Energies*. 2017. №10(8). P. 1167. DOI: 10.3390/en10081167
8. Park J., Choi H., Kim D., Kim T. Development of novel PMV-based HVAC control strategies using a mean radiant temperature prediction model by machine learning in kuwaiti climate // *Building and Environment*. 2021. №206. P. 108357. DOI: 10.1016/j.buildenv.2021.108357
9. Заки Д. А. А., Котин Д. А., Панкратов В. В. Непосредственное векторное управление асинхронными электроприводами с использованием прогнозирующих моделей // *Инженерный вестник Дона*, 2014, №1. URL: ivdon.ru/ru/magazine/archive/n1y2014/2247
10. Горлатов Д. В. Машинное обучение прогнозных моделей на несбалансированных данных по опасным астероидам // *Инженерный вестник Дона*, 2023, №5. URL: ivdon.ru/ru/magazine/archive/n5y2023/8394
11. Rodney Rick, Lilian Berton. Energy forecasting model based on CNN-LSTM-AE for many time series with unequal lengths // *Engineering Applications of Artificial Intelligence*. 2022. №113. P. 104998. DOI: 10.1016/j.engappai.2022.104998
12. Imasheva B., Azamat N., Sidelkovskiy A., Sidelkovskaya A. The practice of moving to big data on the case of the NoSQL database, ClickHouse // *Optimization of Complex Systems: Theory, Models, Algorithms and Applications*. 2020. pp. 820-828. DOI: 10.1007/978-3-030-21803-4_82

References

1. Ivanovskij B. G. *Ekonomicheskie i social'nye problemy Rossii*. 2022. №1(49). pp. 58-78. DOI: 10.31249/espr/2022.01.04

2. Li L., Liu X., Zhang T. Building and Environment. 2021. №196. p. 107779. DOI: 10.1016/j.buildenv.2021.107779
3. Lozhnikova A. V., El'murzaeva R. A., Zemcov A. A., Kudelina O. V. Terra Economicus. 2023. №21(2). pp. 84-100. DOI:10.18522/2073-6606-2023-21-2-84-100
4. Rudin A. R. A., Lukman Audah, A. Jamil, Jiwa Abdullah. IEEE Conference on Wireless Sensors (ICWiSE). IEEE, 2016. pp. 100-105. DOI: 10.1109/ICWISE.2016.8188550
5. Himeur Y., Ghanem K., Alsalemi A., Bensaali F., Amira A. Applied Energy. 2021. №287. p. 116601. DOI: 10.1016/j.apenergy.2021.116601
6. Losi G., Bonzanini A., Aquino A., Poesio P. Journal of Building Engineering. 2021. №33. p. 101599. DOI: 10.1016/j.jobbe.2020.101599
7. Petri I., Kubicki S., Rezgui Y., Guerriero A., Li H. Energies. 2017. №10(8). p. 1167. DOI: 10.3390/en10081167
8. Park J., Choi H., Kim D., Kim T. Building and Environment. 2021. №206. p. 108357. DOI: 10.1016/j.buildenv.2021.108357
9. Zaki D. A. A., Kotin D. A., Pankratov V. V. Inzhenernyi vestnik Dona, 2014, №1 URL: ivdon.ru/ru/magazine/archive/n1y2014/2247
10. Gorlatov D. V. Inzhenernyi vestnik Dona, 2023, №5. URL: ivdon.ru/ru/magazine/archive/n5y2023/8394
11. Rodney Rick, Lilian Berton. Engineering Applications of Artificial Intelligence. 2022. №113. p. 104998. DOI: 10.1016/j.engappai.2022.104998
12. Imasheva B., Azamat N., Sidelkovskiy A., Sidelkovskaya A. Optimization of Complex Systems: Theory, Models, Algorithms and Applications. 2020. p. 820-828. DOI: 10.1007/978-3-030-21803-4_82.

Дата поступления: 19.10.2024

Дата публикации: 30.11.2024
