

Методы и алгоритмы глубокого обучения для управления энергопотреблением спортивных объектов

А. А. Карманов

ФГБОУ ВО «Финансовый университет при Правительстве Российской Федерации», г. Москва, Российская Федерация

Адрес: 125167, Российская Федерация, г. Москва, Ленинградский проспект, д. 49/2
aleksandr.karmanov@outlook.com

Аннотация

В условиях климатического кризиса, вызванного глобальным потеплением и растущей стоимости энергоносителей, необходимо принимать срочные и активные меры в области энергопотребления. Государства должны минимизировать выбросы углекислого газа, а бизнес – оптимизировать расходы на энергопотребление. В связи с этим, повышение энергоэффективности играет ключевую роль в решении климатического кризиса и сокращении затрат бизнеса. В большинстве случаев, меры по улучшению энергоэффективности оказываются наиболее экономически эффективным способом борьбы с изменением климата, позволяя одновременно сократить потери энергии, сэкономить средства и обеспечить доступное расширение использования возобновляемых источников энергии. Активная цифровизация энергетической отрасли и внедрение технологий интернета вещей создают благоприятные условия для внедрения искусственного интеллекта в управление энергопотреблением. В данной статье представлен обзор технологий искусственного интеллекта (ИИ) и его потенциальное применение в управлении энергопотреблением на примере спортивного объекта - ледовой арены. Был проанализирован набор данных по энергопотреблению, собранный с реального объекта, представляющий собой многомерный временной ряд, а также рассмотрены исследования, посвященные применению нейросетевого моделирования временных рядов в управлении на основе прогноза. В совокупности эти исследования продемонстрировали потенциал ИИ в области теории управления. Большинство из них следует рассматривать как ранние пробные работы, демонстрирующие потенциал использования алгоритмов машинного обучения для решения прикладных проблем в энергопотреблении.

Ключевые слова: искусственный интеллект, глубокое обучение, машинное обучение, энергопотребление, управление на основе модельного прогнозирования

Конфликт интересов: автор заявляет об отсутствии конфликта интересов.

Для цитирования: Карманов А. А. Методы и алгоритмы глубокого обучения для управления энергопотреблением спортивных объектов // Современные информационные технологии и ИТ-образование. 2024. Т. 20, № 1. С. 101-111. <https://doi.org/10.25559/SITITO.020.202401.101-111>

© Карманов А. А., 2024



Контент доступен под лицензией Creative Commons Attribution 4.0 License.
The content is available under Creative Commons Attribution 4.0 License.



Methods and Algorithms for Predictive Analytics of Time Series in Energy Consumption

A. A. Karmanov

Financial University under the Government of the Russian Federation, Moscow, Russian Federation
Address: 49/2 Leningradsky Prospekt, Moscow 125167, Russian Federation
aleksandr.karmanov@outlook.com

Abstract

In the face of the climate crisis caused by global warming and large fluctuations in energy costs, urgent and proactive action on energy consumption is needed. States must minimize carbon dioxide emissions and businesses must optimize their energy costs. In this regard, improving energy efficiency plays a key role in solving the climate crisis and reducing costs for businesses. In most cases, energy efficiency improvements are proving to be the most cost-effective way to combat climate change, simultaneously reducing energy waste, saving money, and enabling affordable expansion of renewable energy. The active digitalization of the energy industry and the adoption of Internet of Things technologies create favorable conditions for the introduction of artificial intelligence in energy management. This paper presents an overview of Artificial Intelligence (AI) technologies and its potential application in energy management using an ice arena as an example. A dataset collected from a real-world facility representing a multidimensional time series was analyzed, and research on the application of deep learning in predictive model-based control was reviewed. Collectively, these studies demonstrated the potential of AI in the field of control theory. Most of them should be viewed as early exploratory work demonstrating the potential of using machine learning algorithms to solve applied problems in energy consumption.

Keywords: artificial intelligence, deep learning, machine learning, energy consumption, model predictive control

Conflict of interests: The author declares no conflict of interests.

For citation: Karmanov A.A. Methods and Algorithms for Predictive Analytics of Time Series in Energy Consumption. *Modern Information Technologies and IT-Education*. 2024;20(1):101-111. <https://doi.org/10.25559/SITITO.020.202401.101-111>



Введение

Согласно результатам проведенных исследований, доля затрат на электроэнергию для крупного и среднего бизнеса в Российской Федерации является значимой частью себестоимости производимых товаров и услуг и находится в диапазоне от 6% до 20%. Это касается и спортивных сооружений, имеющих большую долю затрат на электроэнергию, в связи с тем, что они представляют из себя открытые и закрытые помещения большой площади, предназначенные для различных видов деятельности в зависимости от вида спорта и бизнес-модели эксплуатируемых помещений объекта. Для их работы необходимы внушительная система освещения, высокопроизводительная система вентиляции и кондиционирования воздуха, система отопления и охлаждения. Следовательно эффективное управление и эксплуатация спортивного объекта может оказаться сложной задачей при необходимости поддерживать качество предоставляемых услуг. Спортивные сооружения включают в себя разные зоны с различными сценариями использования, разной архитектурой и непохожими схемами заполнения. Кроме того, прогнозирование энергопотребления и уровня комфорта в помещениях зависит от различных факторов, так как функции спортивных объектов и их использование могут варьироваться в зависимости от региона и климатических условий, а также других внешних факторов. Несмотря на сложность управления спортивными комплексами, было проведено сравнительно немного исследований, направленных на оптимизацию их работы. Используются два основных типа методик: основанные на физических моделях и на использовании моделирования на исторических данных. Первые из них базируются на физическом математическом представлении исследуемой системы. Вторые используют ранее собранные данные для решения текущей задачи управления. Стоит отметить, что решения на основе данных становятся все популярнее, так как опираются на технологии искусственного интеллекта и машинного обучения, что обусловлено сквозным внедрением цифровых технологий в том в числе и в область энергетики. В последнее время появляются все новые и новые достижения в области управления зданиями и автоматизации благодаря интеграции искусственного интеллекта, машинного обучения, интернета вещей и передовых облачных вычислений [1, 2].

Например, в работах [3, 4] исследователи использовали различные подходы для оптимизации управления энергопотреблением в спортивных сооружениях. В первой работе [3] авторы применяют основанную на физике модель для контроля теплового комфорта на футбольном стадионе, который спроектирован для жаркого и влажного климата и использует вычислительную гидродинамику. С другой стороны, во второй работе [4] предлагается модель, управляемая на основе прогноза, которая использует алгоритм многоцелевой генетической оптимизации для снижения потребления электроэнергии системами отопления, вентиляции и кондиционирования в бассейне. Эта модель также использует информационное моделирование зданий для создания исторических данных. Подходы, основанные на физических моделях, требуют создания надежных математических моделей. Этот процесс может быть сложным и трудоемким для сложных структур. Кроме того,

создание надежных моделей требует подробной информации о здании, такой как материалы, геометрия, размеры окон и так далее. С другой стороны, методы, основанные на данных, нуждаются в большом объеме обучающих данных, и могут требовать значительных вычислительных ресурсов. Тем не менее, интеллектуальные методы управления спортивными объектами, основанные на данных, вызывают растущий интерес со стороны научного сообщества и бизнеса благодаря их превосходству в производительности над подходами, основанными на физических моделях [5].

Достижения в области искусственного интеллекта и доступность технологий интернета вещей и обработки данных создают условия для формирования рынка решений по управлению энергопотреблением. Одной из таких компаний является «Индепендент Энерджи», деятельность которой направлена на оптимизацию энергопотребления на спортивных объектах. На одном из объектов компанией были произведены работы по установке системы мониторинга энергопотребления, климата и работы оборудования внутри существующей ледовой арены, а также вмонтированы частотные преобразователи на различные силовые агрегаты, которые позволяют внедрять алгоритмы управления. В рамках периода мониторинга была посчитана доля потребления энергии холодильной машины от всего объекта, составляющая от 60 до 80% в зависимости от времени года. Соответственно, оптимизация энергопотребления холодильной машины ледовой арены, приведет к значительному снижению энергопотребления всего объекта.

Цель исследования

Целью данного исследования является обзор возможных методов предиктивной аналитики с помощью моделей глубокого обучения для использования прогнозного значения целевого параметра в управлении энергопотреблением ледовой арены на примерах спортивных объектов.

Основная часть

Устройство холодильной машины ледовой арены

Ледовая арена является сложным инженерно-техническим сооружением, центральное место в которой уделяется устройству холодильной машине, работа которой нацелена на поддержание качества ледового покрытия в пределах целевого параметра. Подавляющее число процессов, потребляющих электроэнергию в ледовой арене, зависит от охлаждения.


Из холодильной установки подается охлажденный теплоноситель в охлаждающие трубы (рис. 1), скорость которого зависит от работы циркуляционного насоса. Установка частотного преобразователя на циркуляционный насос позволяет управлять процессом прокачки теплоносителя и косвенно оказывает влияние на скорость теплообмена и работу компрессоров холодильной машины. В процессе теплообмена теплоноситель отдает холод толщине ледового покрытия, что приводит к замораживанию льда и далее возвращается в контур испарителя холодильной машины.

В свою очередь холодильная машина состоит из различных компонентов (рис. 2), где ключевым функциональным элементом являются компрессоры, обеспечивающие непрерывное



сжатие охлаждающей жидкости (или хладагента) в рамках рабочего цикла системы. Сгенерированное компрессором давление обеспечивает транспортировку хладагента в конденсатор, где он подвергается конденсации и впоследствии подается в распределительное устройство (распылитель) и теплообмен-

ник (испаритель). На заключительной стадии этого процесса хладагент испаряется, абсорбируя тепло из окружающего рабочую камеру пространства. Впоследствии хладагент вновь подается в компрессорный блок, и цикл повторяется.

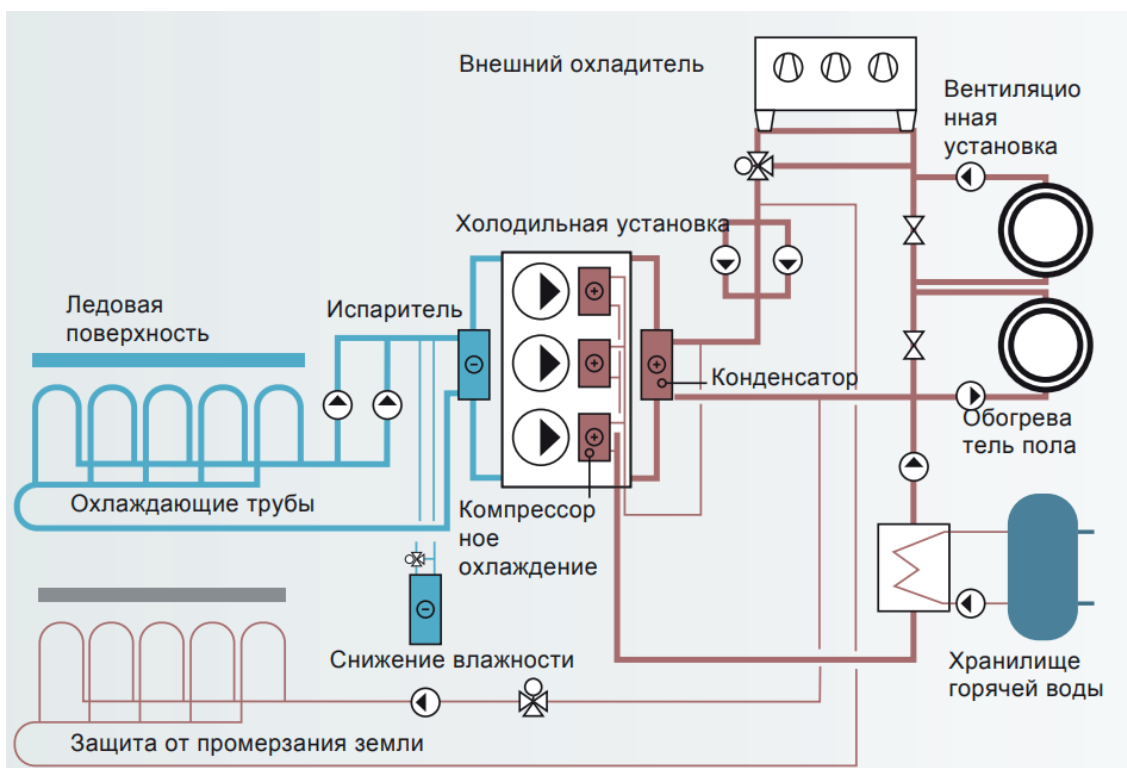


Р и с. 1. Холодильная установка с системой охлаждения льда

F i g. 1. Refrigeration unit with ice cooling system

Источник: здесь и далее в статье все таблицы и рисунки составлены автором.

Source: Hereinafter in this article all tables and figures were made by the author.



Р и с. 2. Устройство холодильной машины

F i g. 2. Refrigeration machine device



Передача энергии от холодильной установки до поверхности льда имеет непостоянный инерционный характер, обусловленный нелинейными взаимосвязями различных внутренних воздействий. К примеру, передача тепловой энергии от компрессоров до верхней точки толщи ледового покрытия может составлять от 20 до 40 минут в зависимости от скорости прокачки гликоля, уставки давления внутри компрессоров и скорости работы тепловентиляторов системы охлаждения. При этом на ледовое покрытие оказывают внешние воздействия такие как: теплообмен с воздухом арены, интенсивность движения спортсменов и их количество, объем и температура проводимой заливки, последняя в свою очередь является резким возмущающим фактором, который приводит к моментальному увеличению температуры льда и отклонению его от целевых параметров.

При ручном управлении холодильной машиной для того, чтобы держать ледовое покрытие в пределах целевых параметров, не допуская его до жидкообразного состояния и компенсируя внешние воздействия, необходимо промораживать лед с некоторым запасом прочности, что приводит к избытку потребления электроэнергии. Для того чтобы выделять оптимальное количество энергии, необходимо знать динамику тепловой среды.

Таким образом имея информацию о будущем состоянии ледового покрытия, можно выделить столько энергии сколько необходимо для его поддержания в пределах целевого значения, тем самым обеспечивая качество льда и снижая энергопотребление. Как было описано выше на температуру ледового покрытия воздействуют внешние и внутренние факторы с разной степенью влияния и с определенной нелинейной зависимостью.

Управление на основе предиктивной модели

В области науки управления наблюдается значительное внимание к моделированию и прогнозированию благодаря потенциалу метода в создании передовых систем контроля над процессами, особенно в многомерных случаях [6]. Этот интерес вызван способностью метода вычислять оптимальные действия по управлению на базе не только текущих данных о состоянии системы, но и предполагаемой реакции процесса на управление. Метод модели прогнозирования управления (MPC) базируется на своей встроенной линейной или нелинейной модели, описывающей динамическое поведение системы и прогнозирование ее реакции на определенный промежуток времени, с целью определения оптимальной траектории управления. В процессе решения задачи динамической оптимизации учитываются входные и выходные ограничения на каждом этапе.

Нейросети типа LSTM и RNN могут помочь решить эту задачу, предоставляя модели прогнозирования, которые могут использовать исторические данные для предсказания будущего поведения системы [7]. Эти модели могут быть обучены на основе прошлых данных, чтобы определить оптимальные управляющие действия, учитывая текущую информацию и прогнозируемую реакцию процесса.

CNN (сверточные нейронные сети) также могут быть использованы для решения этой задачи, поскольку они особенно хорошо подходят для обработки и анализа данных временных рядов. CNN могут быть использованы для извлечения важных характеристик из данных процесса, таких как тренды и сезонные компоненты, что может быть полезным для прогнозирования реакции процесса на управляющие действия [8].

В целом, использование нейросетей типа LSTM, RNN и CNN может улучшить эффективность решения задач управления процессами за счет более точного прогнозирования и анализа данных процесса.

Набор данных

Как сказано ранее, была реализована система мониторинга и добавлена возможность управлять холодильной машиной на существующей ледовой арене. Данные собираются с частотой несколько секунд и хранятся в СУБД Clickhouse¹. Предлагается, используя исторические данные о потреблении компрессоров холодильной машины, а также данные о внешних и внутренних воздействиях на ледовое поле, обучить модель прогноза температуры поверхности льда, реализовав концепцию управления на основе предиктивной модели.

Предлагается в качестве временного интервала наблюдений провести агрегацию сырых данных на отрезки по одной минуте (Табл. 1), обучив модель делать прогнозирование во временном окне 20-40 минут, для того, чтобы учесть, инерционность передачи энергии от холодильной машины до поверхности льда.

Описание набора данных:

- temp_ice - температура поверхности льда, °C
- consumption_compressors - потребление суммы компрессоров, кВт*ч
- power_pump - мощность работы циркуляционного насоса, Вт
- temp_outside - внешняя температура, °C
- hum_outside - относительная внешняя влажность, %
- temp_inside - внутренняя температура над помещением ледового поля, °C
- hum_inside - относительная внутренняя влажность над помещением ледового поля, %
- max_motion - уровень движения на ледовой арене, у.е.
- illuminance - уровень освещения на ледовой арене, у.е.
- CO2 - уровень углекислого газа на ледовой арене, ppm
- temp_condensation - температура фреона в испарителе, °C
- power_compressors - мощность работы компрессоров, Вт
- power_condensators - мощность работы конденсаторов, Вт
- temp_supply_glyc - температура подачи теплоносителя (гликоля) в контур охлаждающих труб
- temp_return_glyc - температура возвращаемого теплоносителя (гликоля) из контура охлаждающих труб

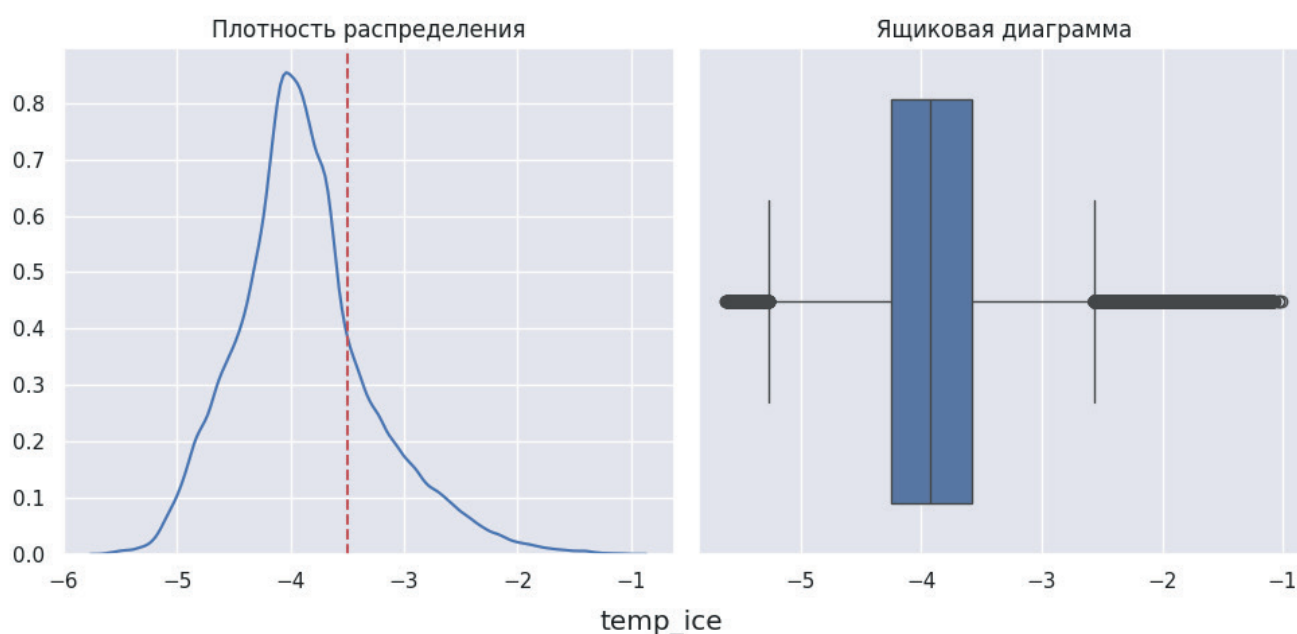
Из-за различных причин в наборе данных появляются пропуски и аномальные выбросы, поэтому необходимо проводить предобработку данных. К примеру, разрыв передачи данных приводит к накоплению энергии на счетчиках, что приводит к аномально большому значению потребления в момент восстановления связи. Подобные нюансы надо учитывать, для того чтобы улучшить качество обучения.

¹ Clickhouse: Documentation [Электронный ресурс]. URL: <https://clickhouse.com/docs/en/intro> (дата обращения: 16.11.2023).



Таблица 1. Агрегированный по минутам набор данных
Table 1. Aggregated minute-by-minute data set

	count	mean	std	min	max
temp_ice	545 417	-4,04	0,72	-7,06	-0,40
consumption_compressors	551 225	1,01	1,04	0,00	131,46
temp_outside	539 520	6,70	10,16	-25,00	30,90
hum_outside	539 520	74,25	18,64	16,02	100,00
temp_inside	536 766	8,63	1,74	2,31	13,49
hum_inside	547 838	55,84	6,58	17,27	100,90
max_motion	548 127	24,84	64,20	8,75	2 047,83
illuminance	455 332	102,39	351,24	0,00	11 445,77
CO2	368 578	561,41	149,67	0,00	1 458,75
temp_condensation	409 372	25,41	7,32	1,84	42,71
power_pump	549 008	9 656,19	4 546,10	7,89	24 578,69
power_compressors	551 225	61 065,36	33 910,82	0,00	161 121,34
power_condensators	551 225	6 168,88	5 388,78	-1,61	13 571,08
temp_supply_glycol	450 724	-8,29	1,47	-12,20	-3,03
temp_return_glycol	403 373	-5,62	0,94	-7,92	-1,75

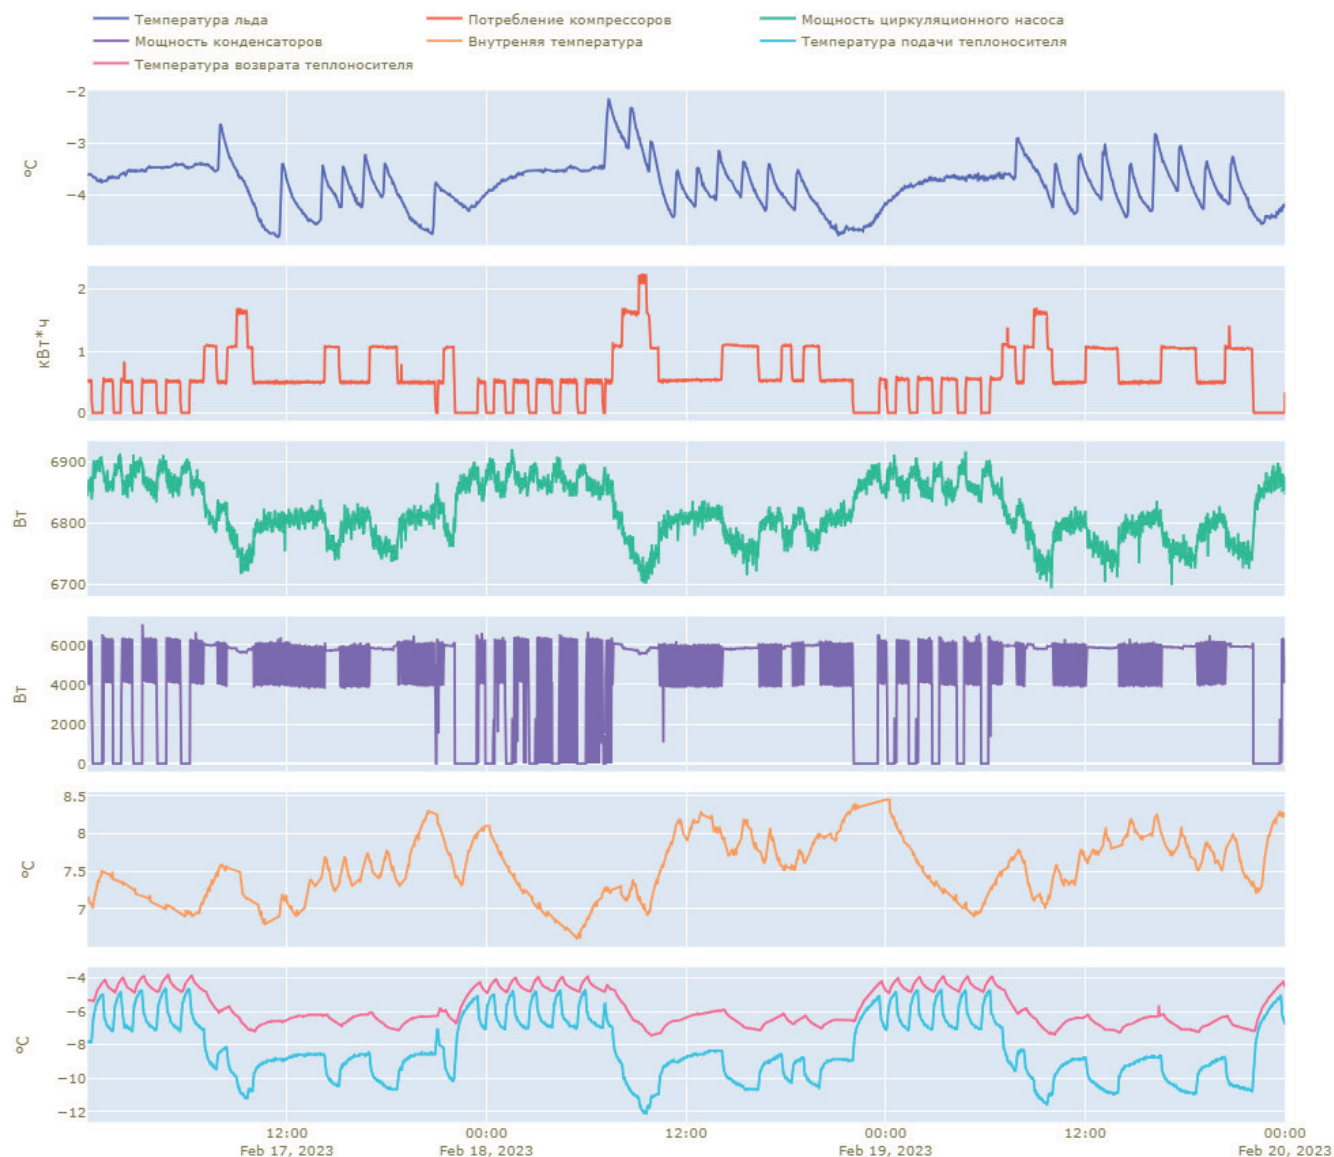


Р и с. 3. График распределения температуры поверхности льда
Fig. 3. Ice surface temperature distribution graph

Целевой уставкой температуры ледового покрытия для поддержания качества льда на рассматриваемой ледовой арене является значение в $-3.5\text{ }^{\circ}\text{C}$. На рисунке 3 представлено распределение температуры поверхности льда, из которого видно отклонение от целевого значения. Задачей управления холодильной машиной на основе прогноза температуры ледового покрытия является снижение дисперсии относительно значения температуры $-3.5\text{ }^{\circ}\text{C}$, что потенциально снизит энергопотребление и улучшит качество льда.

Как было ранее сказано на температуру поверхности льда оказывают как внутренние, так и внешние воздействия с разной инерционностью передачи энергии. Так на рисунке 4 видны резкие повышения температуры льда, с последующим плавным затуханием до значения близкого к целевому параметру, что свидетельствует о проведенных заливках, когда на лед выливается большой объем теплой воды, с целью выровнять лед и убрать борозды.






Р и с. 4. Внешние и внутренние факторы, воздействующие на динамику льда во времени
 F i g. 4. External and internal factors affecting ice dynamics over time


Из рисунка 4 видно, как работа холодильной машины компенсирует фактор заливки, увеличивая мощность работы компрессоров, конденсаторов и циркуляционного насоса. Стоит отметить, что компенсация внешних факторов воздействия происходит по факту, т. е. работа холодильной машины не учитывает динамику передачи энергии, а также будущее состояние льда. Из графика временного ряда наблюдается тенденция, что в дневные часы вероятность заливок и нагрузки на лед увеличивается, таким образом обученная предиктивная модель должна уметь находить эти взаимосвязи и выдавать прогноз с учетом всех факторов влияния. На данный момент собран набор данных при различных сценариях эксплуатации объекта, что показывает различное по-

ведение состояния льда. Так, к примеру на лед оказывает влияние интенсивность движения на льду, косвенно указывающая играют ли хоккеисты или проходит тренировка по фигурному катанию. Так как при этих сценариях уровень теплового воздействия, влажности, освещенности и нагрузки на лед варьируется, то все эти взаимосвязи надо учитывать модели. Стоит отметить и влияние температуры и влажности атмосферного воздуха, потому что эти параметры напрямую влияют на систему охлаждения компрессоров, что приводит к изменению кпд и холодопроизводительности всей холодильной машины. На рисунке 5 отображены распределения температурных признаков, которые свидетельствуют о разнообразии собранных данных при различных сценариях эксплуатации.





Р и с. 5. Ящичковые диаграммы распределения температурных показателей
F i g 5. Box diagrams of the distribution of temperature indicators



Р и с. 6. Потребление компрессоров по часам
F i g 6. Compressor consumption by hours

Управление компрессорами, которые состоят из 4 ступеней, осуществляется по температуре подаваемого теплоносителя, в данном случае гликоля, что характеризует, какую тепловую нагрузку охлаждающие трубы должны передать толщине льда. Компрессоры в зависимости от изменения температуры подаваемого теплоносителя изменяют количество работающих ступеней для того, чтобы достичь поставленной уставки. Соответственно, в момент активной эксплуатации объекта, температура возвращаемого теплоносителя будет выше, что приводит к большому потреблению компрессоров для того, чтобы достичь заданной уставки. Это видно из распределения потребления компрессоров по часам за всю историю наблюдения (рис. 6).

Таким образом реализовав динамическое изменение уставки подаваемого теплоносителя, привязанной к прогнозу температуры льда, можно добиться оптимизированного потребления всей холодильной установки и улучшить качество ледового покрытия.

Обзор исследований

Оптимизация использования энергии и максимальное улучшение качества внутренней атмосферы спортивных объектов имеет приоритетное значение, поскольку их высокая потребность в энергии обусловлена эксплуатационными требованиями и так как качество внутренней атмосферы существенно влияет на результативность спортсменов и комфорт зрителей. К примеру, обеспечение высокой влажности в помещении может быть недостаточным для обеспечения испарения пота при физической активности [9], что является важным при физических нагрузках. В связи с этим, в последнее время был предложен ряд исследовательских проектов по созданию моделей, основанных на анализе данных для управления потреблением энергии и качеством внутренней атмосферы в спортивных объектах. Например, авторы [10] предложили систему мониторинга и оценки нагрузок для прогнозирования потребления энергии в бассейнах, используя регрессионную модель взвешенной разницы в критических точках, тогда как в работе



[11] разработана интеллектуальная система энергетического менеджмента для полного контроля и управления электросистемой стадиона.

Нейросетевые алгоритмы применялись в ряде исследований, посвященных управлению и оптимизации потребления энергии и теплового комфорта на спортивных объектах. В исследовании [12] разработана модель, основанная на нейронных сетях, для оптимизации размеров элементов с использованием многокритериальной генетической оптимизации в системе отопления открытых бассейнов. Нейронные сети использованы в исследовании [13] для предсказания скорости испарения в закрытых бассейнах. А в статье [14] разработана тепловая модель для гибридного бассейна с сочетанием законов термодинамики и нейросетей. Также в работе [15] разработана нейросетевая модель прогнозирования теплового состояния стадиона с использованием детальной информации об условиях в здании и посетителях. В исследовании [16] разработана интеллектуальная система контроля спортивного объекта с использованием гибридной модели, включающей алгоритм обратного распространения (SVM-BP) на основе машинного обучения и нейронных сетей.

Кроме того, глубокое обучение в последнее время вызывает значительный интерес у исследователей спортивных объектов, так как оно может существенно помочь в прогнозировании потребления энергии или теплового комфорта, избегая при этом проблемы переобучения. Так, в исследовании [17] предложен подход к прогнозированию обслуживания, основанный на неконтролируемом обнаружении аномалий с использованием глубоких автоэнкодеров (DAE). Этот подход позволяет выявлять неисправности системы кондиционирования в спортивном объекте путем анализа разницы между фактическим и прогнозируемым потреблением энергии. После сбора данных с использованием устройств интернета вещей и имитационного моделирования они обрабатываются перед тем, как вводятся в базу данных для прогнозирования сбоев. Несмотря на то, что эта схема довольно проста в реализации благодаря обучению без учителя, общая работа имеет ограничение в виде отсутствия оценки точности обнаружения аномалий и частоты ложных срабатываний.

Возможности нейросетевых алгоритмов, могут быть расширены путем их комбинирования с другими подходами, такими как модель прогнозирующего контроля на основе нейросетевой модели (MPC), предложенная в [6]. MPC выгодно отличается тем, что учитывает будущее поведение системы уже на этапе разработки системы управления, соблюдая при этом эксплуатационные требования к системе [18]. В работе [19] представлен обзор, посвященный применению MPC-систем в зданиях, благодаря их большому потенциалу в области улучшения энергоэффективности и производительности. Это было продемонстрировано в [20], где MPC использовалась для управления климатическими системами в университетских зданиях. Для повышения эффективности системы в условиях неопределенного прогноза погоды была использована модель ошибок. В работе [21] разработана MPC-стратегия для систем подогрева пола в офисных зданиях. И, наконец, в [22] предложено MPC-решение для оптимизации систем отопления и охлаждения в зданиях.

В отличие от традиционных MPC-систем, нейросетевая MPC не требует предварительных знаний о динамике системы

или определенных условиях эксплуатации. Вместо этого она использует разработанную на основе исторических данных систему черного ящика. Эта модель, которая фиксирует динамику системы, чтобы предсказать ее будущее поведение, может быть создана с использованием других алгоритмов искусственного интеллекта и машинного обучения. Обычно она используется для моделирования нелинейных систем с целью прогнозирования и анализа их поведения. Примеры такого использования можно найти в работах [23, 24] (с использованием опорных векторов, SVR), [25] (с применением k-ближайших соседей, kNN) и [26] (деревья решений, DT).

В работе [27] авторы предложили систему прогнозирующего управления на основе искусственного интеллекта для оптимизации потребления природного газа в системах отопления. Система была протестирована на нескольких зданиях и доказала свою эффективность в управлении температурой.

В исследовании [28] авторы использовали машинное обучение для разработки системы прогнозирующего управления для управления климатом. Был проведен сравнительный анализ различных моделей машинного обучения и выбраны наиболее эффективные.

Нейросетевые алгоритмы широко используются для моделирования сложных систем и процессов. В работе [29] нейронные сети использовались для оптимизации работы климатической системы общественного здания с целью минимизации потребления энергии и обеспечения комфортного микроклимата. В исследовании [30] нейросетевые алгоритмы применялись для управления системами кондиционирования воздуха с целью определения оптимального решения по энергосбережению. Авторы работы [31] предложили использовать нейросети для оптимизации энергопотребления и микроклимата в многозональных зданиях с помощью системы прогнозирующего управления.

Перспективы

Управление холодильной машиной на основе прогноза на ледовых аренах имеет большие перспективы, поскольку это помогает снизить затраты на электроэнергию и уменьшить воздействие на окружающую среду. Использование модели прогнозирующего контроля, основанной на нейронных сетях, позволит поддерживать качество ледового покрытия, при этом снижая энергопотребление. Это достигается за счет использования исторических данных и алгоритмов машинного обучения для создания модели, которая может предсказывать будущее состояние ледового покрытия в зависимости от различных факторов внешнего и внутреннего воздействия.

Одним из преимуществ такого подхода является то, что он позволяет управлять в режиме реального времени без необходимости моделирования тепловой динамики физических процессов, автоматически регулируя работу холодильной установкой. Кроме того, использование нейросетей позволяет создавать более точные и адаптивные модели, которые могут учитывать различные сценарии и адаптироваться к изменениям в условиях эксплуатации с учетом постоянного дообучения модели.

Однако для полного внедрения такой системы необходимо решить ряд технических и организационных проблем. Во-пер-



вых, необходимо обеспечить сбор и обработку большого объема данных о потреблении энергии и условиях эксплуатации. Во-вторых, необходимо обучить и внедрить в промышленную эксплуатацию алгоритмы машинного обучения, которые будут эффективно обрабатывать эти данные и создавать оптимальные управляющие решения.

Заключение

Спортивные сооружения могут быть оборудованы сложными системами, которые непрерывно регистрируют данные изменений, сигналы приводов и другие параметры. Накопление таких данных требует использования моделей, основанных на данных. Динамическая модель на основе нейросетей является оптимальным решением, так как она сочетает в себе точ-

ность и надежность с возможностью учета изменяющихся во времени факторов. Модели, основанные только на физических принципах или только на статистических данных, не могут обеспечить такой уровень гибкости и эффективности.

В данной работе рассматривается система оптимизированного управления на основе модели прогнозирующего контроллера (МРС), использующей нейросети. Эта система позволяет минимизировать потребление энергии и максимизировать качество параметров эксплуатации спортивных сооружений. Она разработана таким образом, чтобы дополнять существующую систему управления, не требуя значительных изменений. Предлагаемый подход представляет собой гибкое и эффективное решение для оптимизации управления спортивными сооружениями, в частности ледовой ареной.

References

- [1] Rudin A.R.A., Audah L., Jamil A., Abdullah J. Occupancy monitoring system for campus sports facilities using the internet of things (IoT). In: 2016 IEEE Conference on Wireless Sensors (ICWISE). IEEE Computer Society; 2016. p. 100-105. <https://doi.org/10.1109/ICWISE.2016.8188550>
- [2] 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;287:116601. <https://doi.org/10.1016/j.apenergy.2021.116601>
- [3] Losi G., Bonzanini A., Aquino A., Poesio P. Analysis of thermal comfort in a football stadium designed for hot and humid climates by CFD. *Journal of Building Engineering*. 2021;33:101599. <https://doi.org/10.1016/j.jobe.2020.101599>
- [4] Petri L., 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):1167. <https://doi.org/10.3390/en10081167>
- [5] 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;206:108357. <https://doi.org/10.1016/j.buildenv.2021.108357>
- [6] Åkesson B.M., Toivonen H.T. A neural network model predictive controller. *Journal of Process Control*. 2006;16(9):937-946. <https://doi.org/10.1016/j.jprocont.2006.06.001>
- [7] Amalou I., Mouhni N., Abdali A. Multivariate time series prediction by RNN architectures for energy consumption forecasting. *Energy Reports*. 2022;8(9):1084-1091. <https://doi.org/10.1016/j.egy.2022.07.139>
- [8] Rick R., Berton L. Energy forecasting model based on CNN-LSTM-AE for many time series with unequal lengths. *Engineering Applications of Artificial Intelligence*. 2022;113:104998. <https://doi.org/10.1016/j.engappai.2022.104998>
- [9] Kusdinar Y., Cahyani D., Mardiana R. Objective Thermal Comfort of Sport Facilities. In: Proceedings of the 3rd International Conference on Sport Science, Health, and Physical Education (ICSSHPE 2018). *Advances in Health Sciences Research*. Atlantis Press; 2019. p. 51-55. <https://doi.org/10.2991/icsshpe-18.2019.14>
- [10] Song C., Jing W., Zeng P., Yu H., Rosenberg C. Energy consumption analysis of residential swimming pools for peak load shaving. *Applied Energy*. 2018;220:176-191. <https://doi.org/10.1016/j.apenergy.2018.03.094>
- [11] Refaat S.S., Abu-Rub H., Kezunovic O.E.M. A novel smart energy management system in sports stadiums. In: 2016 18th European Conference on Power Electronics and Applications (EPE'16 ECCE Europe). Karlsruhe, Germany: IEEE Computer Society; 2016. p. 1-8. <https://doi.org/10.1109/EPE.2016.7695647>
- [12] Li Y., Nord N., Zhang N., Zhou C. An ANN-based optimization approach of building energy systems: Case study of swimming pool. *Journal of Cleaner Production*. 2020;277:124029. <https://doi.org/10.1016/j.jclepro.2020.124029>
- [13] Lu T., Lü X., Viljanen M. Prediction of water evaporation rate for indoor swimming hall using neural networks. *Energy and Buildings*. 2014;81:268-280. <https://doi.org/10.1016/j.enbuild.2014.06.027>
- [14] Santos E.T., Zárata I.E., Pereira E.M. Hybrid thermal model for swimming pools based on artificial neural networks for southeast region of Brazil. *Expert Systems with Applications*. 2013;40(8):3106-3120. <https://doi.org/10.1016/j.eswa.2012.12.026>
- [15] Yoon H.-J., Lee D.-S., Cho H., Jo J.-H. Prediction of Thermal Environment in a Large Space Using Artificial Neural Network. *Energies*. 2018;11(2):418. <https://doi.org/10.3390/en11020418>
- [16] Xiao-wei X. Study on the intelligent system of sports culture centers by combining machine learning with big data. *Personal and Ubiquitous Computing*. 2020;24:151-163. <https://doi.org/10.1007/s00779-019-01307-z>
- [17] Bouabdallaoui Y., Lafhaj Z., Yim P., Ducoulombier L., Bennadji B. Predictive Maintenance in Building Facilities: A Machine Learning-Based Approach. *Sensors*. 2021;21(4):1044. <https://doi.org/10.3390/s21041044>



- [18] Camacho E.F., Bordons C. Model Predictive Control. *Advanced Textbooks in Control and Signal Processing*. Springer Science & Business Media; 2013. 405 p. <https://doi.org/10.1007/978-0-85729-398-5>
- [19] Zhan S., Chong A. Data requirements and performance evaluation of model predictive control in buildings: A modeling perspective. *Renewable and Sustainable Energy Reviews*. 2021;142:110835. <https://doi.org/10.1016/j.rser.2021.110835>
- [20] Hou J., Li H., Nord N., Huang G. Model predictive control under weather forecast uncertainty for HVAC systems in university buildings. *Energy and Buildings*. 2022;257:111793. <https://doi.org/10.1016/j.enbuild.2021.111793>
- [21] Joe J., Karava P. A model predictive control strategy to optimize the performance of radiant floor heating and cooling systems in office buildings. *Applied Energy*. 2019;245:65-77. <https://doi.org/10.1016/j.apenergy.2019.03.209>
- [22] Fotopoulou M.C., Drosatos P., Petridis S., Rakopoulos D., Stergiopoulos F., Nikolopoulos N. Model predictive control for the energy management in a district of buildings equipped with building integrated photovoltaic systems and batteries. *Energies*. 2021;14(12):3369. <https://doi.org/10.3390/en14123369>
- [23] Li W., Xie L., Wang Z. Two-loop covert attacks against constant value control of industrial control systems. *IEEE Transactions on Industrial Informatics*. 2019;15:663-676. <https://doi.org/10.1109/TII.2018.2819677>
- [24] Feng X., Weng C., He X., Han X., Lu L., Ren D., Ouyang M. Online state-of-health estimation for Li-Ion battery using partial charging segment based on support vector machine. *IEEE Transactions on Vehicular Technology*. 2019;68:8583-8592. <https://doi.org/10.1109/TVT.2019.2927120>
- [25] Martínez F., Frías M.P., Pérez M.D., Rivera A.J. A methodology for applying k-nearest neighbor to time series forecasting. *Artificial Intelligence Review*. 2019;52:2019-2037. <https://doi.org/10.1007/s10462-017-9593-z>
- [26] Yu Z., Haghighat F., Fung B.C., Yoshino H. A decision tree method for building energy demand modeling. *Energy and Buildings*. 2010;42(10):1637-1646. <https://doi.org/10.1016/j.enbuild.2010.04.006>
- [27] Cotrufo N., Saloux E., Hardy J., Candanedo J., Platon R. A practical artificial intelligence-based approach for predictive control in commercial and institutional buildings. *Energy and Buildings*. 2020;206:109563. <https://doi.org/10.1016/j.enbuild.2019.109563>
- [28] Wang J., Li S., Chen H., Yuan Y., Huang Y. Data-driven model predictive control for building climate control: Three case studies on different buildings. *Building and Environment*. 2019;160:106204. <https://doi.org/10.1016/j.buildenv.2019.106204>
- [29] Ferreira P., Ruano A., Silva S., Conceicao E. Neural networks based predictive control for thermal comfort and energy savings in public buildings. *Energy and Buildings*. 2012;55:238-251. <https://doi.org/10.1016/j.enbuild.2012.08.002>
- [30] Privara S., Široky J., Ferkl L., Cigler J. Model predictive control of a building heating system: The first experience. *Energy and Buildings*. 2011;43(2-3):564-572. <https://doi.org/10.1016/j.enbuild.2010.10.022>
- [31] Mtibaa F., Nguyen K.-K., Dermardiros V., Cheriet M. A Model Predictive Control for Heat Supply at Building Thermal Inlet Based on Data-Driven Model. *Buildings*. 2022;12(11):1879. <https://doi.org/10.3390/buildings12111879>

Поступила 16.11.2023; одобрена после рецензирования 14.01.2024; принята к публикации 20.02.2024.
Submitted 16.11.2023; approved after reviewing 14.01.2024; accepted for publication 20.02.2024.

Об авторе:

Карманов Александр Арсланович, аспирант Департамента анализа данных и машинного обучения, ФГБОУ ВО «Финансовый университет при Правительстве Российской Федерации» (125167, Российская Федерация, г. Москва, Ленинградский проспект, д. 49/2), ORCID: <https://orcid.org/0009-0002-4533-1092>, aleksandr.karmanov@outlook.com

Автор прочитал и одобрил окончательный вариант рукописи.

About the author:

Aleksandr A. Karmanov, Postgraduate student of the Department of Data Analysis and Machine Learning, Financial University under the Government of the Russian Federation (49/2 Leningradsky Prospekt, Moscow 125167, Russian Federation), ORCID: <https://orcid.org/0009-0002-4533-1092>, aleksandr.karmanov@outlook.com

The author has read and approved the final manuscript.

