

Прогнозирование температуры поверхности льда с использованием больших языковых моделей в задачах предиктивного управления холодильными системами

А. А. Карманов

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

Адрес: 125167, Российская Федерация, г. Москва, пр. Ленинградский, д. 49/2

aleksandr.karmanov@outlook.com

Аннотация

В работе представлен подход к прогнозированию температуры поверхности льда на основе метода перепрограммирования предобученных языковых моделей (*patch-reprogramming LLM*). Объектом исследования является ледовая арена, оснащённая системой цифрового мониторинга холодильного оборудования и микроклимата. Задача прогнозирования формулируется как аппроксимация зависимости между многомерным окном наблюдений и будущим состоянием системы с горизонтом 30 минут. Используются минутные данные более чем за три месяца наблюдений, включающие температурные, энергетические и микроклиматические параметры. Проведено сравнительное моделирование с использованием статистических (ARIMA), машинных (XGBoost) и нейросетевых (LSTM, CNN, PatchTST) методов. Предложенный метод LLM с перепрограммированием патчей, основанный на замороженном ядре LLaMA-3.2-3B с добавлением адаптивных слоёв, показал наилучшие результаты: средняя абсолютная ошибка (MAE) составила 0.22 °C, а коэффициент детерминации R^2 достиг 0.94. Модель устойчиво воспроизводит переходные режимы и фазовые сдвиги температуры после заливок, корректно сглаживая шумовые пики и кратковременные возмущения. Результаты показывают, что механизм *patch-reprogramming* позволяет использовать большие языковые модели для анализа физических временных рядов без необходимости длительного дообучения. Такой подход обеспечивает баланс между точностью и устойчивостью, что делает его перспективным инструментом для внедрения в контуры предиктивного управления (MPC) холодильными системами и оптимизации энергопотребления спортивных объектов.

Ключевые слова: большие языковые модели, временные ряды, прогнозирование, *patch-reprogramming*, предиктивное управление

Конфликт интересов: автор заявляет об отсутствии конфликта интересов.

Для цитирования: Карманов А. А. Прогнозирование температуры поверхности льда с использованием больших языковых моделей в задачах предиктивного управления холодильными системами // Современные информационные технологии и ИТ-образование. 2026. Т. 22, № 1. С. 117-125. <https://doi.org/10.25559/SITITO.022.202601.117-125>

© Карманов А. А., 2026



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



Forecasting of Ice Surface Temperature Using Large Language Models in Model Predictive Control of Refrigeration Systems

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

This paper presents an approach to short-term ice surface temperature forecasting based on the patch-reprogramming of pretrained large language models (LLMs). The object of study is an ice arena equipped with a digital monitoring system for refrigeration equipment and microclimate parameters. The forecasting problem is formulated as the approximation of the dependence between a multidimensional observation window and the future system state with a 30-minute prediction horizon. The dataset consists of minute-level measurements over more than three months, including thermal, energy, and environmental variables. Comparative modeling was performed using statistical (ARIMA), machine learning (XGBoost), and deep learning (LSTM, CNN, PatchTST) methods. The proposed LLM patch-reprogramming model, based on a frozen LLaMA-3.2-3B core with additional lightweight adaptive layers, achieved the best performance: the mean absolute error (MAE) reached 0.22 °C, and the coefficient of determination $R^2 = 0.94$. The model robustly reproduces transitional dynamics and phase shifts in surface temperature following resurfacing events, while effectively smoothing short-term fluctuations and noise. The results demonstrate that the patch-reprogramming mechanism enables the application of large language models to the analysis of physical time series without extensive retraining. This approach provides a balance between accuracy and robustness, making it a promising tool for integration into Model Predictive Control (MPC) loops of refrigeration systems and for optimizing the energy efficiency of sports facilities.

Keywords: large language models, time series forecasting, patch-reprogramming, predictive control

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

For citation: Karmanov A.A. Forecasting of Ice Surface Temperature Using Large Language Models in Model Predictive Control of Refrigeration Systems. *Modern Information Technologies and IT-Education*. 2026;22(1):117-125. <https://doi.org/10.25559/SITITO.022.202601.117-125>



Введение

Современные спортивные сооружения характеризуются высокой энергоёмкостью и сложной структурой инженерных систем, обеспечивающих микроклимат и эксплуатационную безопасность. Особое место среди них занимают ледовые арены, для которых поддержание стабильного температурного режима поверхности льда является ключевым фактором качества и долговечности покрытия. По данным практических наблюдений, до 70–80 % суммарных энергозатрат арены приходится на систему холодильного оборудования, а колебания температуры поверхности даже в пределах ± 2 °C заметно влияют на физические свойства льда и качество катания [1]. Таким образом, обеспечение точного краткосрочного прогноза температуры поверхности льда представляет собой важнейший элемент интеллектуального управления энергопотреблением арены.

Задача прогнозирования температуры и энергопотребления систем охлаждения относится к классу задач анализа временных рядов с нелинейной динамикой, сезонными колебаниями и стохастическими возмущениями [2], [17]. В последние годы в данной области наблюдается переход от традиционных моделей (ARIMA, экспоненциальное сглаживание, рекуррентные нейронные сети) к универсальным предобученным архитектурам, способным выявлять общие закономерности в данных различной природы [3]. К ним относятся так называемые большие языковые модели (*Large Language Models, LLM*), изначально разработанные для обработки текстовой информации, но продемонстрировавшие высокую способность к переносу знаний на задачи временного прогнозирования [4]. В трудах исследователей Google, Amazon и других компаний представлены универсальные модели анализа временных рядов (TimesFM, Chronos, Time-LLM), которые способны формировать прогноз без дополнительного обучения на новых данных и показывают точность, сопоставимую с лучшими специализированными методами [5].

Особое развитие получила идея перепрограммирования модели на патчах (*patch-reprogramming*), предложенная в работах по Time-LLM [6]. Данный подход позволяет использовать уже обученную языковую модель без изменения её параметров, представляя числовой временной ряд в виде последовательности «патчей» — небольших фрагментов данных. Эти фрагменты преобразуются в скрытое пространство модели с помощью механизма перекрёстного внимания и набора прототипов, что обеспечивает гибкую адаптацию к новым типам сигналов при минимальных вычислительных затратах [7]. Дополнительный компонент — метод префикс-подсказки (Prompt-as-Prefix) — используется для ввода контекстной информации о задаче и статистике данных, что повышает точность предсказаний без дообучения самой модели. В совокупности эти механизмы реализуют концепцию лёгкой адаптации универсальной модели к прикладным инженерным задачам.

Настоящая работа посвящена применению подхода с использованием больших языковых моделей (LLM) и механизма перепрограммирования к задаче прогнозирования температуры поверхности льда на горизонте 30 минут для реального объекта — ледовой арены, оснащённой системой цифрового мониторинга [1], [22]. В данном исследовании рассматривается выборка более чем из 600 тыс. наблюдений с минутным шагом, содержащая параметры температур, давлений, мощ-

ностей компрессоров, характеристик теплоносителя и микроклиматических условий.

Целью исследования является оценка эффективности применения метода перепрограммирования на уровне патчей (*patch-reprogramming*) на основе больших языковых моделей для прогнозирования температуры поверхности льда.

Обзор исследований

В последние годы в задачах прогнозирования временных рядов наблюдается активное развитие подходов, основанных на архитектурах, изначально созданных для обработки естественного языка [8]. Переход от специализированных моделей к универсальным предобученным системам анализа последовательностей обусловлен их способностью выявлять сложные закономерности, переносить знания между доменами и работать в условиях ограниченного количества обучающих данных. Ключевую роль в этом направлении сыграли так называемые большие языковые модели, продемонстрировавшие универсальность при решении задач, выходящих за рамки обработки текста [4].

Одной из первых работ, заложивших основу этого подхода, стала модель **TimesNet**, предложившая концепцию «фундаментальной» модели для временных рядов [9]. Архитектура TimesNet реализует извлечение признаков через многомасштабные двумерные преобразования, что позволяет единообразно решать различные типы задач — прогнозирование, классификацию и восстановление пропусков. Эксперименты показали, что единая архитектура способна достигать точности, сопоставимой с узкоспециализированными методами, что подтвердило перспективность идеи универсального представления временных данных.

Развитие концепции универсальных моделей получило продолжение в исследовании **TimesFM**, где была реализована модель авторегрессионного декодера, обученная на сотнях миллиардов точек временных рядов, включая реальные и синтетические данные [10]. В отличие от классических подходов, TimesFM применяет предобучение на широком множестве задач и типов сигналов, что позволяет использовать её без дополнительного обучения на новых наборах данных [11]. Авторы показали, что такая модель способна воспроизводить сезонные и стохастические закономерности не хуже специализированных архитектур, демонстрируя сопоставимую точность прогнозов при значительно меньших вычислительных затратах на адаптацию.

Параллельно с этим Amazon представила семейство моделей **Chronos**, в которых временные ряды преобразуются в последовательности токенов через масштабирование и квантование значений [5]. В основе Chronos лежит архитектура трансформера, обученная на миллиардах последовательностей разнородных временных рядов. Эксперименты показали, что предварительное обучение на обширных данных позволяет существенно улучшить качество прогнозирования даже в условиях отсутствия информации о структуре конкретного сигнала. Модель Chronos продемонстрировала устойчивость к шумам и способность обобщать закономерности, присущие реальным инженерным процессам.

Следующим шагом стало исследование Time-LLM, предложившее метод перепрограммирования на уровне патчей (*patch-*




reprogramming) [6]. Его суть заключается в том, что уже обученная языковая модель используется как неизменное ядро, а входные временные данные преобразуются в короткие фрагменты — патчи, подаваемые в модель в виде «псевдотекстовых» последовательностей. При этом встраивается небольшое количество дополнительных обучаемых блоков: линейные преобразования, кросс-аттеншен с прототипами и модуль «префикс-подсказок», позволяющий учесть статистику конкретного ряда. Такой подход позволяет использовать преимущества обобщающей способности языковых моделей при значительно меньших объёмах данных и времени обучения. Экспериментальные результаты показали, что метод перепрограммирования на уровне патчей обеспечивает высокую точность прогнозов даже без изменения параметров базовой модели. По ряду задач временного прогнозирования TimeLLM превзошла специализированные архитектуры (Informer, Autoformer, PatchTST), демонстрируя лучшую устойчивость к шумам и выбросам [6]. Таким образом, была продемонстрирована возможность переноса универсальных языковых моделей в область физико-технических процессов, где структура сигналов часто неизвестна заранее и требует адаптивных подходов. Для систем управления климатом и охлаждением, включая ледовые арены, важной особенностью является наличие сложных взаимосвязей между температурными, энергетическими и физическими параметрами [1]. В исследовании рассматривались методы глубокого обучения в контуре предиктивного управления, где прогноз температуры служил входом для

оптимизации уставок холодильного оборудования. Однако такие модели требовали значительного объёма данных и подстройки гиперпараметров для каждого объекта. Применение универсальных моделей с перепрограммированием на уровне патчей позволяет устранить это ограничение, обеспечивая переносимость модели между различными аренами без повторного обучения.

В результате совмещение принципов универсального представления данных и лёгкой адаптации открывает новые возможности для построения интеллектуальных систем управления энергопотреблением спортивных объектов [17, 18]. В контексте данного исследования метод перепрограммирования на уровне патчей рассматривается как потенциальная альтернатива традиционным архитектурам прогнозирования и как инструмент снижения вычислительной и эксплуатационной сложности систем управления [20, 21].

Объект исследования и набор данных

Объектом исследования является ледовая арена, оснащённая системой цифрового мониторинга холодильного оборудования и микроклимата. Основная цель функционирования системы заключается в поддержании стабильной температуры поверхности льда при минимальных энергозатратах. Арена характеризуется высокой тепловой инерционностью (рис. 1) и сложными взаимосвязями между температурными, энергетическими и внешними параметрами, что делает задачу прогнозирования особенно чувствительной к качеству данных.



Р и с. 1. Динамика температуры поверхности льда и суммарной мощности компрессоров в течение трёх суток наблюдения

Fig. 1. Dynamics of ice surface temperature and total compressor power over a three-day observation period

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.




Исследование основано на архиве наблюдений за период с января 2024 по март 2025 года с минутной частотой измерений. Набор данных включает более 600 тыс. записей и около 40 признаков, объединяющих температуры, давления, мощности компрессоров, параметры гликоля и микроклиматические показатели. Целевой переменной является температура поверхности льда, прогнозируемая на горизонт 30 минут вперёд.

Перед обучением модели данные были очищены от аномальных и физически невозможных значений, пропуски скорректированы методами интерполяции и прямого заполнения, а признаки нормализованы с учётом сезонных колебаний. Подробное описание структуры набора данных, его статистиче-

ских характеристик и процедур предобработки представлено в работе [1].

На рисунке 2 показана корреляционная структура части исходных признаков. Отмечается сильная положительная зависимость между температурами различных зон (поверхность льда, ледовая толща, подача гликоля) и отрицательная связь между температурой воды и температурой подачи гликоля, что отражает баланс тепловых потоков в системе охлаждения. Небольшая корреляция температуры льда с работой агрегатов холодильной машины свидетельствует о сложных нелинейных связях между ними.



Р и с. 2. Корреляционная матрица признаков, характеризующих взаимосвязь температурных, энергетических и микроклиматических параметров ледовой арены

Fig. 2. Correlation matrix of features characterizing the relationships between thermal, energy, and microclimatic parameters of the ice arena

Методология исследования

В данном разделе описываются методы и архитектуры, использованные для построения моделей краткосрочного прогнозирования температуры поверхности льда на основе данных ледовой арены. Задача прогнозирования температуры поверхности льда формулируется как задача аппроксимации зависимости между многомерным окном наблюдений и бу-

дущим состоянием системы. На вход подаётся последовательность измерений длиной 360 минут с шагом дискретизации 1 минута, включающая температурные, энергетические и микроклиматические признаки. Целевой переменной является температура поверхности льда на горизонте 30 минут вперёд. Каждое наблюдение представлено матрицей признаков размерности $(T \times d)$, где $T = 360$ — длина временного окна, $d \approx 40$



— число параметров, характеризующих состояние системы. Для всех моделей использовались единые процедуры масштабирования, интерполяции пропусков и формирования обучающих выборок.

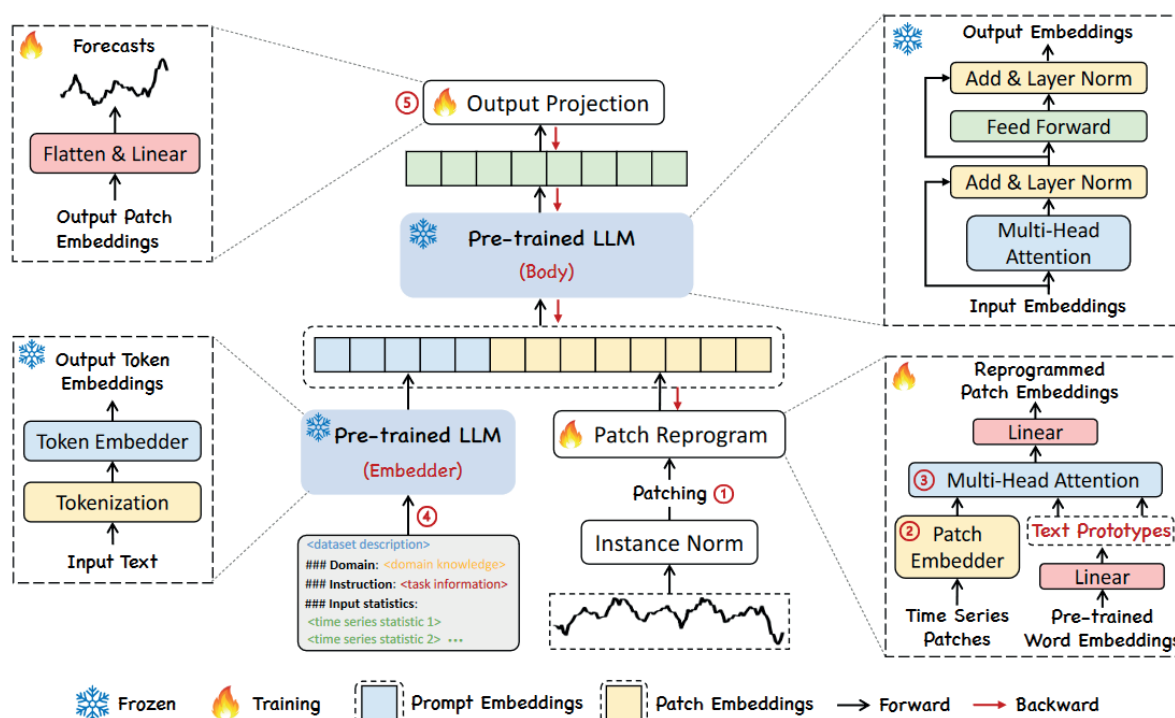
Для сопоставления эффективности прогнозирования рассматривались три группы методов:

Статистическая модель SARIMA, как параметрический ориентир, позволяющий выразить зависимость между текущими и прошлыми состояниями через авторегрессионные и интегрирующие члены. Оптимальные порядки (p , d , q) определялись по критерию Акаике [12], [24];

Модель классического машинного обучения — градиентный бустинг (XGBoost). Для XGBoost параметры (глубина деревьев, шаг обучения, количество итераций) подбирались методом байесовской оптимизации с целью минимизации среднеквадратической ошибки [13], [19];

Нейросетевые и трансформерные архитектуры — LSTM, CNN, PatchTST и модель на основе перепрограммирования предобученной языковой модели (*patch-reprogramming LLM*) [6], [14], [17].

Предложенный подход основан на использовании замороженного ядра большой языковой модели (*LLaMA-3.2-3B*), к которому добавлены два адаптивных слоя: модуль перепрограммирования и регрессионная проекция (рис. 3) [6, 15]. Исходная последовательность временных данных разбивается на перекрывающиеся фрагменты — патчи фиксированной длины. Каждый патч преобразуется в векторное представление и передается в языковую модель для извлечения скрытых признаков [6]. Затем модуль перепрограммирования осуществляет перекрёстное внимание (*cross-attention*) между эмбедами патчей и набором обучаемых прототипов, после чего линейный слой формирует прогноз.



Р и с. 3. Схематическое представление подхода patch-reprogramming и его интеграции в предобученную языковую модель [6]

F i g. 3. Schematic representation of the patch-reprogramming approach and its integration into a pre-trained language model [6]


Для всех моделей применялись единые параметры окна и горизонта прогноза: $T = 360$ мин, $H = 30$ мин, $L = 30$ мин, $\Delta L = 15$ мин. Данные делились во временном порядке: 80 % — обучение, 20 % — валидация.

Обучение нейросетевых моделей выполнялось с использованием оптимизатора Adam (скорость обучения 10^{-3} , размер батча 128, 30 эпох) [16]. Критерием сходимости служила минимизация среднеквадратической ошибки (MSE) на валидационной подвыборке. Дополнительно оценивались метрики MAE и коэффициент детерминации R^2 .

Результаты исследования

Результаты численных экспериментов демонстрируют различия в динамике обучения, точности прогноза и устойчивости моделей к физическим возмущениям. На рисунке 4 представлена динамика функции потерь (MSE) при обучении моделей LSTM, CNN, XGBoost и LLM с перепрограммированием патчей. Видно, что нейросетевые модели характеризуются более плавной сходимостью по сравнению с XGBoost, однако LSTM склонна к переобучению после 15-й эпохи. Предложенный метод patch-reprogramming достигает стабильного минимума MSE уже к 10-й эпохе и сохраняет его на протяжении обучения, что указывает на устойчивость и хорошую обобщающую способность модели.





Р и с. 4. Динамика функции потерь (MSE) при обучении различных моделей прогнозирования температуры поверхности льда

F i g. 4. Dynamics of the loss function (MSE) during the training of different models for ice surface temperature forecasting


Количественное сравнение точности моделей на тестовой выборке приведено в таблице 1. Наилучшие показатели продемонстрировала модель LLM с перепрограммированием патчей: средняя абсолютная ошибка — 0.22, а коэффициент детерминации R^2 достиг 0.94. Для сравнения, ближайшие по качеству модели PatchTST и LSTM показали $R^2 = 0.92$ и 0.90 соответственно.

Т а б л и ц а 1. Сравнение точности прогнозирования температуры поверхности льда различными моделями

T a b l e 1. Comparison of ice surface temperature forecasting accuracy across different models

Модель	MAE, °C	R^2
Naive ($\hat{y}_{t+h} = y_t$)	0.96	0.62
SARIMA	1.21	0.84
XGBoost	0.77	0.89
LSTM	0.32	0.90
CNN	0.65	0.89
PatchTST	0.29	0.92
LLM (patch-reprogramming)	0.22	0.94

На рисунке 5 показано сопоставление фактической и прогнозной температуры поверхности льда на суточном интервале тестовой выборки (горизонт 30 минут). Модель на основе перепрограммирования LLM в целом воспроизводит динамику изменения температуры, корректно отражая основные тренды и периоды восстановления после заливок. При этом прогноз характеризуется сглаживанием резких пиков и наличием умеренного шума, что указывает на тенденцию модели к генерализации и подавлению кратковременных возмущений. В стационарных участках отклонение прогноза не превышает порядка ± 0.3 °C, а в переходных режимах сохраняется физически обоснованная форма траектории без значительного запаздывания. Наивная модель, напротив, демонстрирует запаздывание и систематические ошибки при резких изменениях температуры.



Р и с. 5. Сравнение фактической и прогнозируемой температуры поверхности льда (Naive, LLM) на тестовом интервале

F i g. 5. Comparison of actual and predicted ice surface temperature (Naive, LLM) over the test interval

Следует отметить, что использование ядра LLaMA-3.2-3B в LLM модели обеспечивает высокую устойчивость к возмущениям, однако обучение и инференс такой модели требуют значительных вычислительных ресурсов. Для практических внедрений целесообразно рассматривать упрощённые или квантизированные варианты модели, позволяющие сократить энергопотребление и время отклика при минимальной потере точности.

Обсуждение результатов

Полученные результаты подтверждают эффективность подхода на основе перепрограммирования предобученных языковых моделей для прогнозирования физико-технических процессов. Модель LLM (*patch-reprogramming*) продемонстрировала не только наилучшие количественные показатели, но и устойчивость к шуму и резким переходам, характерным для работы холодильной системы арены. В отличие от классических методов (ARIMA, XGBoost) и специализированных нейросетевых архитектур (LSTM, CNN), LLM не требует длительной оптимизации гиперпараметров и способна адаптироваться к данным за счёт универсальных представлений, сформированных на этапе предобучения.

Отмеченное сглаживание пиков в прогнозах LLM может рассматриваться как положительное свойство в инженерных приложениях, где избыточная реакция на кратковременные возмущения приводит к перерасходу энергии. При этом общая форма траектории и фазовые сдвиги сохраняют физическую интерпретируемость. Таким образом, применение механизма перепрограммирования на уровне патчей позволяет использовать языковые модели как надёжное ядро предсказательных систем в условиях ограниченных данных и высокой вариативности технологических режимов.

Несмотря на вычислительные издержки, связанные с использованием LLaMA-3.2-3B, предложенный подход открывает перспективы для внедрения в интеллектуальные системы управления микроклиматом, где высокая точность прогноза непосредственно влияет на энергетическую эффективность и качество эксплуатации ледовой поверхности.



Заключение

В работе проведено исследование применения метода пере-программирования больших языковых моделей (*LLM patch-reprogramming*) к задаче краткосрочного прогнозирования температуры поверхности льда на реальной арене. Показано, что использование предобученного ядра LLaMA-3.2-3B с добавлением лёгких адаптивных слоёв обеспечивает высокую точность и устойчивость прогноза при существенно меньших объёмах обучающих данных по сравнению с традиционными подходами.

Модель LLM корректно воспроизводит как стационарные, так и переходные режимы, удерживая среднюю ошибку на уровне 0.2–0.3 °C и демонстрируя наилучшие значения R^2 среди всех

протестированных методов. При этом сглаживание кратковременных пиков и подавление шумовых компонентов делают прогноз физически интерпретируемым и пригодным для последующего использования в контуре управления.

Результаты подтверждают, что метод *patch-reprogramming* может рассматриваться как универсальный инструмент адаптации предобученных языковых моделей к инженерным задачам временного прогнозирования. В дальнейшем планируется интеграция разработанного прогностического модуля в систему предиктивного управления (МРС) для оптимизации энергопотребления и поддержания стабильных термодинамических условий ледовой поверхности [23, 25].

References

- [1] 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. (In Russ., abstract in Eng.) <https://doi.org/10.25559/SITITO.020.202401.101-111>
- [2] Uremović N., et al. A new framework for multivariate time series forecasting in energy management system. *IEEE Transactions on Smart Grid*. 2022;14(4):2934-2947. <https://doi.org/10.1109/TSG.2022.3224559>
- [3] Gruver N., et al. Large language models are zero-shot time series forecasters. *Advances in Neural Information Processing Systems*. 2023;36:19622-19635. <https://doi.org/10.48550/arXiv.2310.07820>
- [4] Ma Q., et al. A survey on time-series pre-trained models. *IEEE Transactions on Knowledge and Data Engineering*. 2024;36(12):7536-7555. <https://doi.org/10.1109/TKDE.2024.3475809>
- [5] Ansari A.F., et al. Chronos: Learning the language of time series. *arXiv:2403.07815*. 2024. <https://doi.org/10.48550/arXiv.2403.07815>
- [6] Jin M., et al. Time-LLM: Time series forecasting by reprogramming large language models. *arXiv:2310.01728*. 2023. <https://doi.org/10.48550/arXiv.2310.01728>
- [7] Wang J., et al. Dual cross-attention transformer networks for temporal predictive modeling of industrial process. *IEEE Transactions on Instrumentation and Measurement*. 2024;73:1-11. <https://doi.org/10.1109/TIM.2024.3385820>
- [8] Nadkarni P.M., Ohno-Machado L., Chapman W.W. Natural language processing: an introduction. *Journal of the American Medical Informatics Association*. 2011;18(5):544-551. <https://doi.org/10.1136/amiajnl-2011-000464>
- [9] Wu H., et al. TimesNet: Temporal 2D-variation modeling for general time series analysis. *arXiv:2210.02186*. 2022. <https://doi.org/10.48550/arXiv.2210.02186>
- [10] Das A., et al. A decoder-only foundation model for time-series forecasting. In: Proceedings of the 41st International Conference on Machine Learning (ICML). 2024. <https://doi.org/10.48550/arXiv.2310.10688>
- [11] Pourpanah F., et al. A review of generalized zero-shot learning methods. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2022;45(4):4051-4070. <https://doi.org/10.1109/TPAMI.2022.3191696>
- [12] Chen P., et al. Time series forecasting of temperatures using SARIMA: An example from Nanjing. *IOP Conference Series: Materials Science and Engineering*. 2018;394(5):052024. <https://doi.org/10.1088/1757-899X/394/5/052024>
- [13] Chen T., Guestrin C. XGBoost: A scalable tree boosting system. In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '16). New York, NY, USA: Association for Computing Machinery; 2016. p. 785-794. <https://doi.org/10.1145/2939672.2939785>
- [14] Livieris I.E., Pintelas E., Pintelas P. A CNN-LSTM model for gold price time-series forecasting. *Neural Computing and Applications*. 2020;32(23):17351-17360. <https://doi.org/10.1007/s00521-020-04867-x>
- [15] Inan H., et al. Llama Guard: LLM-based input-output safeguard for human-AI conversations. *arXiv:2312.06674*. 2023. <https://doi.org/10.48550/arXiv.2312.06674>
- [16] Zhang Z. Improved Adam optimizer for deep neural networks. In: IEEE/ACM 26th International Symposium on Quality of Service (IWQoS). Banff, AB, Canada: IEEE Press; 2018. p. 1-2. <https://doi.org/10.1109/IWQoS.2018.8624183>
- [17] 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>
- [18] 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>
- [19] 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>
- [20] Camacho E.F., Alba C.B. Model predictive control. *Springer science & business media*. 2007. 405 p. <https://doi.org/10.1007/978-0-85729-398-5>



- [21] 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>
- [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;14:3369. <https://doi.org/10.3390/en14123369>
- [23] 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>
- [24] 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>
- [25] Yu Z., Haghighat F., Fung B.C., Yoshino H. A decision tree method for building energy demand modeling. *Energy and Buildings*. 2010;42:1637-1646. <https://doi.org/10.1016/j.enbuild.2010.04.006>

Поступила 11.12.2025; одобрена после рецензирования 20.02.2026; принята к публикации 27.03.2026.

Submitted 11.12.2025; approved after reviewing 20.02.2026; accepted for publication 27.03.2026.

Об авторе:

Карманов Александр Арсланович, аспирант кафедры искусственного интеллекта, ФГБОУ ВО «Финансовый университет при Правительстве Российской Федерации» (125167, Российская Федерация, г. Москва, пр. Ленинградский, 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 Artificial Intelligence, 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.

