

Физически-информированная нейронная сеть на трансформерной архитектуре для прогноза временных рядов в инженерных системах

А.А. Карманов

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

Аннотация: В работе рассматривается задача краткосрочного прогнозирования температуры льда в инженерных системах с высокой чувствительностью к тепловым нагрузкам. Предлагается архитектура на основе трансформеров, дополненная физически-информированной функцией потерь, основанной на уравнении теплового баланса. Такой подход позволяет учесть инерционные свойства объекта и согласовать динамику прогнозируемой температуры с подаваемой мощностью и внешними условиями. Модель протестирована на данных с ледовой арены с минутной частотой измерений. Проведено сравнение с базовыми архитектурами, включая нейронную сеть с длинной краткосрочной памятью, рекуррентную нейронную сеть с механизмом управления входами и забыванием, а также стандартную трансформерную модель. Для оценки точности использовались средняя квадратичная ошибка, средняя абсолютная ошибка и средняя абсолютная процентная ошибка. Результаты демонстрируют существенное улучшение точности в переходных режимах, а также устойчивость предсказаний к резким скачкам температуры, особенно после заливки льда. Предложенный метод может быть интегрирован в контуры интеллектуального управления инженерными объектами, обеспечивая не только высокую точность, но и физическую интерпретируемость модели. Работа подтверждает эффективность интеграции физического знания в нейросетевые прогнозные модели.

Ключевые слова: краткосрочное прогнозирование, временные ряды, трансформеры, машинное обучение, физически-информированная модель, предиктивное управление

Введение

Повышение энергетической эффективности инженерных систем становится ключевой задачей в условиях роста потребления и ужесточения требований к устойчивому управлению ресурсами. Особое внимание уделяется объектам с высокими требованиями к температурному режиму, таким как ледовые арены, где поддержание стабильной температуры льда напрямую влияет на безопасность и качество эксплуатации [1]. В таких системах важную роль играют физические процессы теплопередачи и инерционность объекта, которые зачастую игнорируются в классических подходах к прогнозированию.

Современные методы анализа временных рядов, основанные на глубоких нейронных сетях, продемонстрировали высокую точность в задачах

краткосрочного прогноза. Однако большинство из них работают как «чёрный ящик», не учитывая фундаментальные законы физики, определяющие поведение управляемой системы [2]. Это может приводить к неустойчивым предсказаниям, особенно в условиях резких внешних возмущений — например, после заливки или при включении холодильного оборудования. Такие ошибки в прогнозе температуры льда могут привести к избыточному энергопотреблению или нарушению эксплуатационных режимов.

Цель настоящего исследования — разработать метод краткосрочного прогнозирования температуры льда, сочетающий архитектуру трансформера с физически-информированной функцией потерь на основе уравнения теплового баланса. Предлагаемый подход ориентирован на повышение устойчивости модели к скачкообразной тепловой нагрузке, улучшение интерпретируемости предсказаний и обеспечение соответствия предсказанной динамики температуры базовым законам теплообмена. Разработка ориентирована на применение в реальных системах управления инженерной инфраструктурой с высокой чувствительностью к температурным отклонениям.

Обзор исследований

Прогнозирование временных рядов в инженерных системах традиционно решается с применением моделей авторегрессии, экспоненциального сглаживания и нелинейных регрессионных подходов [3]. Однако из-за высокой сложности динамики, нелинейностей и сезонных флуктуаций, эти методы показывают ограниченные результаты в задачах с высокой частотой и переменной нагрузкой, таких как управление температурой льда.

С развитием методов глубинного обучения широкое распространение получили рекуррентные нейронные сети, включая их модификации — нейронную сеть с длинной краткосрочной памятью (Long Short-Term Memory

— LSTM) и сеть с управляемыми входами и забыванием (Gated Recurrent Unit — GRU) [4]. Они показали хорошие результаты в задачах прогноза спроса на электроэнергию, климата в зданиях и параметров инженерной инфраструктуры. Тем не менее, такие модели страдают от проблем с длинными зависимостями и плохо масштабируются по длине контекста.

В последние годы трансформерные архитектуры, изначально разработанные для обработки естественного языка, начали активно применяться к временным рядам [5]. Модели Informer, Autoformer и FEDformer демонстрируют улучшенную способность к моделированию долгосрочных зависимостей и обучению периодических структур за счёт механизма самовнимания [6]. Несмотря на успехи, большинство этих моделей игнорируют физическую природу управляемых процессов, что ограничивает их применение в инженерной практике.

Параллельно развивается направление нейронных сетей, учитывающих физические законы (Physics-Informed Neural Networks — PINNs), в котором знания о физических закономерностях встраиваются в структуру модели или в функцию потерь [7]. Такие подходы успешно применяются в задачах моделирования динамики жидкости, теплообмена и электромагнитных процессов [8]. Однако интеграция PINNs с архитектурой трансформера остаётся относительно редкой и плохо исследованной, особенно в области энергетических приложений.

Таким образом, существует явный разрыв между высокой выразительной способностью трансформеров и требованиями инженерной интерпретируемости. Это обосновывает актуальность разработки физически-информированных трансформеров для задач краткосрочного прогнозирования в энергетически чувствительных системах.

Методология

В данном исследовании предложен подход к краткосрочному прогнозированию параметров инженерных систем на основе трансформерной нейросетевой архитектуры с внедрением физически-информированной функции потерь, отражающей динамику теплового баланса объекта управления. Модель предназначена для прогнозирования активной электрической мощности, подводимой к системе, с учётом динамики температуры и взаимодействия с внешними тепловыми нагрузками.

Модель реализует трансформерную структуру типа «энкодер–декодер» с автогреггессивным механизмом предсказания [9]. Входными данными являются исторические значения температуры объекта $T_{1:L}$, характеристики внешней среды $T_{cp,1:L}$, а также бинарные или числовые индикаторы тепловых воздействий $L_{1:L}$, соответствующие моментам включения дополнительной нагрузки (например, заливки, работы компрессора и т.п.).

Каждый временной шаг кодируется с помощью линейного эмбединга признаков, а также позиционного кодирования. Далее последовательность поступает в трансформер-энкодер, состоящий из N слоёв многоголового самовнимания и последующих полносвязных преобразований. Декодер осуществляет пошаговое предсказание мощности на горизонте H , используя авторегрессионную схему. Обучение производится с принудительной подстановкой правильного ответа, выход каждого шага используется в качестве входа на следующем.

Функция потерь формализует требование соблюдения дискретного уравнения теплового баланса, связывающего изменение температуры с подводимой мощностью и потерями тепла. Вектор целевой переменной $\hat{P} \in \mathbb{R}^H$ обозначает предсказанную активную мощность, обеспечивающую нужную динамику температуры в системе. Тогда итоговая функция потерь определяется следующим образом:

$$\mathcal{L}_{\text{total}} = \mathcal{L}_{\text{pred}} + \lambda_{\text{phys}} \cdot \mathcal{L}_{\text{phys}} + \lambda_{\text{smooth}} \cdot \mathcal{L}_{\text{smooth}} \quad (1)$$

где:

$\mathcal{L}_{\text{pred}} = \frac{1}{H} \sum_{t=1}^H (\hat{P}_t - P_t^{\text{ист}})^2$ — среднеквадратичная ошибка прогноза;
 $\mathcal{L}_{\text{phys}}$ — штраф за отклонение от теплового баланса; $\mathcal{L}_{\text{smooth}}$ — регуляризация на плавность предсказаний; $\lambda_{\text{phys}}, \lambda_{\text{smooth}} \in \mathbb{R}_+$ — положительные коэффициенты.

Физическая компонента построена на основе следующего соотношения:

$$\Delta T_t = \alpha \cdot (\hat{P}_t - \beta \cdot \Delta T_t^{\text{cp}} - \gamma \cdot L_t) \quad (2)$$

где $\Delta T_t = T_t - T_{t-1}$, $\Delta T_t^{\text{cp}} = T_{t-1} - T_{\text{cp},t}$, а параметры α, β, γ задают масштаб взаимодействия между входной мощностью, теплопередачей и внешним тепловым воздействием.

На основе этого выражения формируется физический штраф:

$$\mathcal{L}_{\text{phys}} = \frac{1}{H-1} \sum_{t=2}^H \left(\Delta T_t - \alpha (\hat{P}_t - \beta \cdot \Delta T_t^{\text{cp}} - \gamma \cdot L_t) \right)^2 \quad (3)$$

Сглаживающее слагаемое контролирует резкие колебания мощности:

$$\mathcal{L}_{\text{smooth}} = \frac{1}{H-1} \sum_{t=2}^H (\hat{P}_t - \hat{P}_{t-1})^2 \quad (4)$$

Таким образом, функция потерь направлена на минимизацию ошибки прогноза при сохранении физической правдоподобности и устойчивости выходного сигнала.

Обучение модели проводится с использованием оптимизатора Adam, экспоненциального уменьшения скорости обучения и ранней остановки по метрике на валидационном множестве [10]. Нормализация входных данных осуществляется на основе скользящего окна. Гиперпараметры λ_{phys} , λ_{smooth} , а также α, β, γ подбираются на основе кросс-валидации либо с помощью байесовской оптимизации.

Результаты

Для проверки эффективности предложенного подхода была проведена серия экспериментов на реальных временных рядах, собранных с ледовой арены, оснащённой системой мониторинга параметров микроклимата и энергопотребления. Целевой переменной в задаче прогнозирования является температура верхнего слоя льда, измеряемая с частотой в одну минуту. В качестве входных признаков используются: активная электрическая мощность холодильной установки, температура подачи и обратки гликоля, температура воздуха на уровне льда, бинарный индикатор заливки, а также время суток. Горизонт прогноза составляет 60 минут, длина контекста — 180 минут.

Модель обучалась на 70 % данных, валидация производилась на 15 %, тестирование — на оставшихся 15 %. Все признаки были нормированы по движущемуся окну с сохранением физической размерности температуры. В качестве базовых моделей сравнивались LSTM, GRU, трансформер без физического штрафа, а также трансформер с регуляризацией сглаживания и финальный вариант с физически-информированной функцией потерь, формализующей уравнение теплового баланса. Оценка качества осуществлялась по следующим метрикам: средняя квадратичная ошибка (Mean Squared Error — MSE), средняя абсолютная ошибка (Mean Absolute Error — MAE) и средняя абсолютная процентная ошибка (Mean Absolute Percentage Error — MAPE). Результаты эксперимента приведены в таблице 1.

Таблица № 1

Сравнение архитектур по метрикам

Модель	MSE	MAE	MAPE (%)
LSTM	0.0246	0.111	6.4
GRU	0.0219	0.104	6.1
Трансформер (без физики)	0.0192	0.097	5.7
Трансформер + $\mathcal{L}_{\text{smooth}}$	0.0176	0.092	5.3
Трансформер + $\mathcal{L}_{\text{phys}}$	0.0134	0.081	4.1

Полученные результаты демонстрируют, что включение физической компоненты в функцию потерь позволяет значительно повысить точность краткосрочного прогноза температуры льда. Особенно заметное улучшение достигается в утренние и вечерние периоды, когда система претерпевает резкие изменения тепловой нагрузки. Интеграция уравнения теплового баланса обеспечивает согласованность динамики температуры с подаваемой мощностью, снижая риск недооценки инерционных процессов и улучшая обобщающую способность модели на ранее не наблюдавшихся сценариях.

На Рисунке 1 представлено сравнение предсказаний модели с физической функцией потерь и фактической температурой льда. Видно, что физически-информированная модель обеспечивает более гладкое поведение предсказаний в зонах резких изменений, сохраняя при этом согласование с общей тенденцией и амплитудой сигнала.




Рис. 1. – Сравнение прогноза трансформера с физической функцией потерь и фактической температурой льда

Обсуждения

Полученные результаты демонстрируют, что внедрение физической компоненты в структуру функции потерь трансформерной модели способствует не только снижению ошибки прогнозирования, но и повышению устойчивости модели в зонах резкой динамики тепловой нагрузки.

Применение уравнения теплового баланса в качестве регуляризатора направляет обучение в сторону физических соотношений между температурой, подводимой мощностью и внутренней инерцией объекта, тем самым ограничивая модель от некорректных траекторий предсказаний.

Особенно отчётливо эффект проявляется в переходных режимах — например, при восстановлении температуры после заливки. Тогда как модели без физического компонента склонны переоценивать амплитуду или скорость изменения температуры, предложенный подход позволяет удерживать траекторию прогноза в пределах физически допустимых границ, сглаживая экстремальные выбросы и обеспечивая согласование с инерционными свойствами системы. Это имеет ключевое значение для интеграции модели в контуры автоматического управления.

Тем не менее, предложенный метод требует аккуратного подбора коэффициентов регуляризации. Чрезмерное усиление физического штрафа может привести к недообучению модели и снижению точности в стационарных режимах. Кроме того, корректность физического уравнения и его параметров напрямую влияет на эффективность регуляризации. Это требует либо наличия достоверных инженерных характеристик объекта, либо проведения процедуры идентификации.

С практической точки зрения предложенный подход открывает возможности для применения в задачах предиктивного управления, особенно в тех случаях, где важно обеспечить баланс между точностью предсказания и соблюдением физических ограничений. Сочетание интерпретируемости и гибкости делает модель перспективной для внедрения в системы управления реального времени с ограниченными вычислительными ресурсами.

Заключение

В данной работе представлена трансформерная модель краткосрочного прогнозирования температуры льда с физически-информированной функцией

потерь, основанной на дискретной форме уравнения теплового баланса. Предложенный подход ориентирован на повышение устойчивости модели к внешним возмущениям и обеспечивает физическую согласованность предсказаний без ущерба для точности.

Эксперименты на реальных данных ледовой арены показали, что внедрение физического регуляризатора позволяет существенно снизить ошибки прогноза в переходных режимах, улучшая интерпретируемость модели и обеспечивая устойчивое поведение при скачкообразной нагрузке. Сочетание архитектуры трансформера и инженерной аппроксимации тепловых процессов подтверждает эффективность интеграции физического знания в современные методы машинного обучения.

Полученные результаты подтверждают потенциал разработанного подхода для использования в системах интеллектуального управления и предиктивной оптимизации, особенно в задачах, где критично соблюдение физических ограничений при высокой частоте данных.

Литература

1. 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. DOI: 10.25559/SITITO.020.202401.101-111
2. Пучков Е. В. Сравнительный анализ алгоритмов обучения искусственной нейронной сети // Инженерный вестник Дона. 2013. №4. URL: ivdon.ru/ru/magazine/archive/n4y2013/2135
3. Ho S. L., Xie M. The use of ARIMA models for reliability forecasting and analysis // Computers & Industrial Engineering. 1998. Т. 35. №1–2. С. 213–216. DOI: 10.1016/S0360-8352(98)00066-7
4. Алтай В. И., Темкин И. О. Гибридная модель LSTM-DNN, прогнозирующая расход топлива самосвалов при открытой добыче

- полезных ископаемых // Инженерный вестник Дона. 2024. №1. URL: ivdon.ru/ru/magazine/archive/n1y2024/8966
5. Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A. N., Kaiser Ł., Polosukhin I. Attention is All You Need // Advances in Neural Information Processing Systems. 2017. T. 30. pp. 5998–6008.
 6. Zhou T., Ma Z., Wen Q., Wu Y., Zhan X., Wang J., Zhang Y., Xue Y., He Z. Fedformer: Frequency enhanced decomposed transformer for long-term series forecasting // International Conference on Machine Learning. PMLR, 2022. pp. 27268–27286.
 7. Cuomo S., Di Cola V. S., Giampaolo F., Rozza G., Raissi M., Piccialli F. Scientific machine learning through physics-informed neural networks: Where we are and what's next // Journal of Scientific Computing. 2022. T. 92. №3. p. 88. DOI: 10.1007/s10915-022-01939-z
 8. Cai S., Wang Z., Wang S., Perdikaris P., Karniadakis G. E. Physics-informed neural networks (PINNs) for fluid mechanics: A review // Acta Mechanica Sinica. 2021. T. 37. №12. pp. 1727–1738.
 9. Raissi M., Perdikaris P., Karniadakis G. E. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations // Journal of Computational Physics. 2019. T. 378. pp. 686–707. DOI: 10.1016/j.jcp.2018.10.045
 10. Abdolrasol M. G. M., El-Sappagh S., Mosaad M. I., Ali F. H. Artificial neural networks based optimization techniques: A review // Electronics. 2021. T. 10. №21. p. 2689. DOI: 10.3390/electronics10212689

References

1. Karmanov A. A. Sovremennye informatsionnye tekhnologii i IT-obrazovanie. 2024. Vol. 20. No. 1. pp. 101–111. DOI: 10.25559/SITITO.020.202401.101-111
2. Puchkov E. V. Inzhenernyi vestnik Dona. 2013. No. 4. URL: ivdon.ru/ru/magazine/archive/n4y2013/2135
3. Ho S. L., Xie M. Computers & Industrial Engineering. 1998. Vol. 35. No. 1–2. P. 213–216. DOI: 10.1016/S0360-8352(98)00066-7
4. Altai V. I., Temkin I. O. Inzhenernyi vestnik Dona. 2024. No. 1. URL: ivdon.ru/ru/magazine/archive/n1y2024/8966
5. Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A. N., Kaiser Ł., Polosukhin I. Advances in Neural Information Processing Systems. 2017. Vol. 30. pp. 5998–6008.
6. Zhou T., Ma Z., Wen Q., Wu Y., Zhan X., Wang J., Zhang Y., Xue Y., He Z. International Conference on Machine Learning. PMLR, 2022. pp. 27268–27286.
7. Cuomo S., Di Cola V. S., Giampaolo F., Rozza G., Raissi M., Piccialli F. Journal of Scientific Computing. 2022. Vol. 92. No. 3. P. 88. DOI: 10.1007/s10915-022-01939-z
8. Cai S., Wang Z., Wang S., Perdikaris P., Karniadakis G. E. Acta Mechanica Sinica. 2021. Vol. 37. No. 12. pp. 1727–1738.
9. Raissi M., Perdikaris P., Karniadakis G. E. Journal of Computational Physics. 2019. Vol. 378. pp. 686–707. DOI: 10.1016/j.jcp.2018.10.045
10. Abdolrasol M. G. M., El-Sappagh S., Mosaad M. I., Ali F. H. Electronics. 2021. Vol. 10. No. 21. P. 2689. DOI: 10.3390/electronics10212689.

Дата поступления: 17.07.2025

Дата публикации: 25.08.2025