

УДК:371.693

НЕЙРОСЕТЕВЫЕ МЕТОДЫ ПРОГНОЗИРОВАНИЯ КЛИМАТИЧЕСКИХ ВРЕМЕННЫХ РЯДОВ (НА ПРИМЕРЕ КЫРГЫЗСКОЙ РЕСПУБЛИКИ)

Сулайманова¹ С.М., Ишенбек кызы² М., Имирова³ М.

¹КНУ им. Ж.Баласагына, ² Министерство просвещения КР, ³Школа-комплекс «Давха»

Рассматриваются нейросетевые методы прогнозирования климатических временных рядов, включающих среднюю температуру воздуха, атмосферные осадки и выбросы CO₂, на примере Кыргызской Республики. Для прогнозирования использованы модели LSTM, GRNN, а также алгоритм XGBoost в целях сравнительного анализа. Построены прогнозы климатических показателей до 2050 года и выполнено сопоставление сценариев, формируемых различными моделями.

Ключевые слова: климатические временные ряды, нейросетевые методы, прогнозирование климата, LSTM, GRNN, XGBoost.

КЛИМАТТЫК УБАКЫТ КАТАРЛАРЫН НЕЙРОНДУК ТОРЧОЛОР МЕТОДДОРУ АРКЫЛУУ БОЛЖОЛДОО (КЫРГЫЗ РЕСПУБЛИКАСЫНЫН МИСАЛЫНДА)

Сулайманова¹ С.М., Ишенбек кызы² М., Имирова³ М.

¹Ж.Баласагын атындагы КУУ, ² КР Агартуу министирлиги, ³«Давха» комплекс-мектеби

Кыргыз Республикасынын мисалында абанын орточо температурасын, атмосфералык жаан-чачынын көлөмүн жана CO₂ эмиссиясын камтыган климаттык убакыт катарларын болжолдоо үчүн нейрондук торчолор методдору каралат. Болжолдоо үчүн LSTM, GRNN моделдери, ошондой эле салыштырмалуу талдоо максатында XGBoost алгоритми колдонулган. Климаттык көрсөткүчтөрдүн 2050-жылга чейинки

болжолдоолору түзүлүп, ар кандай моделдер тарабынан түзүлгөн сценарийлер салыштырылды.

Баштапкы сөздөр: климаттык убакыт катарлары, нейрондук тармак ыкмалары, климатты болжолдоо, LSTM, GRNN, XGBoost.

NEURAL NETWORK METHODS FOR FORECASTING CLIMATE TIME SERIES (CASE STUDY OF THE KYRGYZ REPUBLIC)

Sulaimanova¹ S.M., Ishenbek² k M., Imirova³ M.

¹Kyrgyz National University named of J.Balasagyn, Ministry of Education of the Kyrgyz Republic, Davkha School Complex

Neural network methods for forecasting climate time series are examined using the Kyrgyz Republic as a case study. The study focuses on time series of mean air temperature, atmospheric precipitation, and CO₂ emissions. LSTM and GRNN models, as well as the XGBoost algorithm, are applied for comparative analysis. Forecasts of climate indicators up to 2050 are obtained, and the scenarios produced by different models are compared.

Keywords: climate time series, neural network methods, climate forecasting, LSTM, GRNN, XGBoost.

I. Изменение климата является одной из наиболее актуальных глобальных проблем, оказывающих существенное влияние на природные и социально-экономические системы. Для стран Центральной Азии, включая Кыргызскую Республику, характерна высокая климатическая чувствительность, проявляющаяся в росте средней температуры воздуха, изменении режимов атмосферных осадков и усилении климатической изменчивости.

Прогнозирование климатических временных рядов представляет собой сложную научную задачу вследствие их нелинейного характера, наличия структурных сдвигов и высокой межгодовой вариабельности. Традиционные статистические методы нередко оказываются недостаточно эффективными при моделировании таких процессов. В этой связи всё более широкое распространение получают нейросетевые и машинно-обучающие подходы, способные выявлять скрытые зависимости в данных без явного задания физической модели.

Настоящая работа направлена на исследование возможностей нейросетевых методов прогнозирования климатических временных рядов

на примере Кыргызской Республики. В рамках исследования выполнено построение и сравнение прогнозов средней температуры воздуха, атмосферных осадков и выбросов CO₂ с использованием моделей LSTM, GRNN и XGBoost, а также проведён анализ различий между полученными сценариями.

Вопросы анализа и прогнозирования климатических временных рядов, включая среднюю температуру воздуха, атмосферные осадки и выбросы парниковых газов, широко представлены в отечественных и зарубежных исследованиях. В фундаментальных работах по проблематике изменения климата отмечается устойчивая тенденция роста температуры воздуха и трансформация режимов осадков в условиях глобального потепления [1,2].

Ряд исследований посвящён анализу климатических изменений в регионах Центральной Азии, в том числе на территории Кыргызской Республики. В этих работах подчёркивается повышение среднегодовой температуры, рост климатической изменчивости и наличие региональных особенностей атмосферных осадков, что существенно осложняет задачи долгосрочного прогнозирования [3,4].

Отдельное направление исследований связано с анализом динамики выбросов CO₂ и их роли в формировании климатических изменений. В работах [5,6] показано, что временные ряды выбросов характеризуются структурными сдвигами, обусловленными социально-экономическими факторами, что требует применения методов, устойчивых к нестационарности данных.

В последние годы активно развиваются методы машинного обучения для прогнозирования климатических временных рядов. В исследованиях [6–8] показана эффективность алгоритмов градиентного бустинга и нейросетевых моделей при анализе нелинейных зависимостей временных рядов. Отмечается, что такие методы позволяют повысить точность прогноза по сравнению с традиционными статистическими подходами.

Обобщённые регрессионные нейронные сети (GRNN) рассматриваются как инструмент построения сглаженных прогнозов и оценки инерционной динамики временных рядов [8]. Преимуществом GRNN является отсутствие итеративного обучения и высокая устойчивость к шуму, однако данные модели обладают ограниченными возможностями экстраполяции долгосрочных трендов.

Таким образом, анализ существующих публикаций показывает, что, несмотря на значительное количество исследований, остаётся актуальной задача сравнительного анализа различных методов машинного обучения

применительно к региональным климатическим данным. Это определяет целесообразность использования и сопоставления моделей XGBoost, LSTM и GRNN для формирования альтернативных сценариев изменения климатических показателей, что и реализовано в настоящей работе.

Целью настоящей работы является построение и сравнение прогнозов средней температуры воздуха, атмосферных осадков и выбросов CO₂ с использованием алгоритмов XGBoost, LSTM и GRNN, а также анализ различий между полученными сценариями.

II. В работе использованы временные ряды средней температуры воздуха, годовых сумм атмосферных осадков и выбросов CO₂. Данные охватывают период длительностью около 100 лет для температуры и осадков и период с конца 1970-х годов для выбросов CO₂.

На этапе предварительной обработки выполнены:

- проверка данных на пропуски и аномальные значения;
- приведение данных к единому временному шагу;
- агрегация помесечных значений в среднегодовые показатели;
- нормализация данных для нейросетевых моделей.

Для прогнозирования временных рядов использован лаговый подход, при котором входной вектор формируется из нескольких предыдущих значений ряда.

III. Алгоритм XGBoost. XGBoost относится к классу ансамблевых методов градиентного бустинга над деревьями решений. Модель строится в виде суммы базовых моделей:

$$\hat{y} = \sum_{k=1}^K f_k(x_i),$$

где $f_k \in F$ — отдельные деревья решений.

Для повышения устойчивости долгосрочного прогноза выбросов CO₂ применён аддитивный подход, при котором временной ряд разлагается на трендовую и остаточную компоненты. Линейный тренд рассчитывается по последнему периоду наблюдений, а модель XGBoost используется для прогнозирования остаточной составляющей.

Модель LSTM. Долгая краткосрочная память (Long Short-Term Memory, LSTM) представляет собой рекуррентную нейронную сеть, предназначенную для работы с последовательными данными. Архитектура LSTM включает управляющие элементы (входные, выходные и забывающие ворота), что позволяет учитывать долгосрочные зависимости во временных рядах.

LSTM применяется для прогнозирования температурных рядов и позволяет моделировать нелинейные зависимости, однако чувствительна к объёму данных и параметрам обучения.

Обобщённая регрессионная нейронная сеть (GRNN). GRNN основана на методе ядерной регрессии и аппроксимирует условное математическое ожидание выходной переменной:

$$\hat{y}(x) = \frac{\sum_{i=1}^N y_i \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right)}{\sum_{i=1}^N \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right)},$$

где σ — параметр сглаживания (ширина ядра).

GRNN не требует итеративного обучения и формирует сглаженные прогнозы, отражающие инерционную динамику системы.



Рис. 1 – Прогноз средней годовой температуры воздуха в Кыргызской Республике по модели XGBoost с линейной трендовой составляющей

IV. Рисунок 1 иллюстрирует динамику средней температуры воздуха и её прогноз до 2050 года. Полученные результаты свидетельствуют об устойчивом росте температуры, что согласуется с глобальными климатическими тенденциями.

Рисунок 2 показывает прогноз температуры, полученный моделью LSTM. Прогнозная кривая отражает нелинейный характер изменения температуры и демонстрирует более сглаженную динамику по сравнению с линейными методами.




Рис. 2 – Прогноз средней годовой температуры воздуха в Кыргызской Республике по модели LSTM

На рисунке 3 представлено сопоставление прогнозных оценок средней годовой температуры воздуха, полученных с использованием моделей XGBoost и LSTM. Сравнение моделей показывает, что обе методики подтверждают сохранение повышенного температурного уровня в будущем, при этом XGBoost воспроизводит более выраженную межгодовую вариабельность, тогда как LSTM формирует более сглаженный прогноз.




Рис. 3 – Сравнение прогнозов средней годовой температуры воздуха в Кыргызской Республике, полученных с использованием моделей XGBoost и LSTM

На рисунках 4,5 показаны динамика средней годовой температуры воздуха в городе Бишкек за исторический период наблюдений и прогноз до середины XXI века, полученный с использованием моделей **XGBoost** и **LSTM**.

Полученные результаты демонстрируют сохранение повышенного температурного уровня в прогнозируемом интервале при сглаженной межгодовой вариабельности.



Рис. 4 – Прогноз средней годовой температуры воздуха в городе Бишкек по модели XGBoost с линейной трендовой составляющей




Рис. 5 – Прогноз средней годовой температуры воздуха в городе Бишкек по модели LSTM с корректировкой трендовой составляющей

На рисунках 6,7 представлены динамика годовой суммы атмосферных осадков в городе Бишкек за период наблюдений и прогноз до середины XXI века, полученный с использованием моделей XGBoost и **LSTM**. Прогноз LSTM демонстрирует сглаженный характер изменения осадков и тенденцию к увеличению годовых сумм в прогнозируемом интервале, что отражает особенности работы рекуррентной нейронной

сети при долгосрочной экстраполяции временных рядов. Полученные результаты указывают на сохранение выраженной межгодовой изменчивости осадков в будущем при отсутствии устойчивого долгосрочного тренда роста или снижения.



Рис. 6 – Прогноз годовой суммы атмосферных осадков в городе Бишкек по модели XGBoost



Рис. 7 – Прогноз годовой суммы атмосферных осадков в городе Бишкек по модели LSTM

Сопоставление прогнозов годовой суммы атмосферных осадков в городе Бишкек, рассчитанных с использованием моделей XGBoost и LSTM. Сравнение моделей показывает различие в характере прогнозов: XGBoost воспроизводит колебательный режим осадков без выраженного долгосрочного тренда, тогда как LSTM формирует более сглаженный

прогноз с тенденцией к увеличению годовых сумм осадков, что отражает особенности экстраполяции рекуррентной нейронной сети.

В целом анализ свидетельствует о том, что в Бишкеке наблюдается **устойчивое потепление климата**, которое в последние десятилетия **не сопровождается компенсирующим ростом атмосферных осадков**. Это приводит к усилению климатической контрастности и потенциальному росту засушливости региона, что требует учёта при долгосрочном планировании водных и природных ресурсов.

Согласно результатам моделирования с использованием LSTM, среднегодовая температура воздуха на территории Кыргызской Республики к 2050 году может увеличиться примерно на **0.5 °C** по сравнению с уровнем начала 2020-х годов. Средний темп роста температуры составляет порядка **0.15–0.2 °C за десятилетие**, что указывает на устойчивый, но умеренный тренд потепления.

Прогнозирование временного ряда выбросов CO₂ до 2050 года с использованием XGBoost и GRNN

На рисунке 8 представлена динамика фактических выбросов CO₂, линейный тренд, рассчитанный по последним 20 годам наблюдений, а также прогноз до 2050 года, полученный методом XGBoost с аддитивным учётом трендовой компоненты.




Рис. 8 — Прогноз выбросов CO₂ до 2050 года с использованием XGBoost и линейного тренда последних лет

Использование тренда, рассчитанного по актуальному периоду, позволяет устранить влияние структурного разрыва начала 1990-х годов и сформировать реалистичный сценарий дальнейшего роста выбросов. Прогноз XGBoost демонстрирует устойчивую возрастающую траекторию,

отражающую сохранение текущей тенденции при отсутствии радикальных структурных изменений.

На рисунке 9 показан прогноз выбросов CO_2 , полученный с помощью обобщённой регрессионной нейронной сети (GRNN). После 2022 года прогнозная кривая стабилизируется и колеблется вблизи средних значений последних лет. Такое поведение обусловлено особенностями GRNN, которая аппроксимирует локальные закономерности временного ряда и стремится к сглаживанию, а не к экстраполяции тренда. Полученный прогноз может интерпретироваться как инерционный сценарий, предполагающий отсутствие существенного ускорения роста выбросов.



Рис. 9 — Прогноз выбросов CO_2 до 2050 года с использованием GRNN

Сравнительный анализ показал, что модели машинного обучения формируют различные сценарии развития климатических показателей. XGBoost с учётом тренда ориентирован на продолжение выявленных тенденций и формирует более «жёсткий» сценарий. GRNN, напротив, сглаживает динамику и отражает инерционное развитие системы. LSTM занимает промежуточное положение, учитывая нелинейные зависимости во временных рядах.

Совместное использование нескольких моделей позволяет оценить диапазон возможных изменений климатических параметров и повысить надёжность выводов.

В работе показана эффективность применения методов машинного обучения для прогнозирования климатических временных рядов. Полученные результаты свидетельствуют о продолжающемся росте средней температуры воздуха и выбросов CO_2 , а также о высокой вариабельности атмосферных осадков. Использование ансамбля моделей XGBoost, LSTM и GRNN позволяет сформировать

альтернативные сценарии и может быть рекомендовано для задач оценки климатических рисков и разработки адаптационных мер.

ЛИТЕРАТУРА

1. Подрезов О.А. Изменение современного климата Северного, Северо-Западного Кыргызстана (температура и осадки 1930–2010 гг.) / О.А. Подрезов, А.О. Подрезов. Бишкек: Изд-во КРСУ, 2017. 324 с.
2. Ю.А. Подрезова, О.А. Подрезов. Изменения климата Бишкека за столетие 1930–2030 гг. /Вестник КРСУ. 2021. Том 21. № 12. С.192-198.
3. Сулайманова С.М., Абдрасакова А.Б. Анализ климатических данных с помощью нейронных сетей / Вестник КГУСТА, Вып. 77 (3), Бишкек, 2022г. – С.1217 – 1222. То же: [Электронный ресурс]. – Режим доступа: <https://www.elibrary.ru/item.asp?id=49803702>
4. Абдрасакова А.Б., Сулайманова С.М. Применения рекуррентных нейронных сетей LSTM для прогнозирования временных рядов среднемесячной температуры воздуха /МУИТ. Наука и инновационные технологии. №4, 2023г. – С.5 – 7. То же: [Электронный ресурс]. – Режим доступа: <https://elibrary.ru/item.asp?id=61486574>
5. Определяемый на национальном уровне вклад Кыргызской Республики ОНУВ3.0, г.Бишкек, 2025 г. 99 стр. Подготовлено при поддержке Программы развития ООН в Кыргызской Республике в рамках проекта ПРООН «Климатическая перспектива». https://unfccc.int/sites/default/files/2025-10/NDC3.0_Kyrgyzstan_Russian_30-09-2025.pdf
6. A Hybrid ARIMA-LSTM-XGBoost Model with Linear Constraints for Transformer Oil Temperature Forecasting (2025, Energies MDPI)
7. Li, Z. Extracting spatial effects from machine learning model using local interpretation method: An example of shap and xgboost. Comput. Environ. Urban Syst. 96, 101845. <https://doi.org/10.1016/j.compenvurbsys.2022.101845> (2022).
8. Liu, W., Liu, W. D. & Gu, J. Predictive model for water absorption in sublayers using a joint distribution adaption based xgboost transfer learning method. J. Petrol. Sci. Eng. 188, 106937. <https://doi.org/10.1016/j.petrol.2020.106937> (2020).