

НЕЙРОСЕТЕВАЯ МОДЕЛЬ ВРЕМЕННЫХ РЯДОВ ДЛЯ ПРОГНОЗИРОВАНИЯ УРОВНЯ УГЛЕКИСЛОГО ГАЗА В АТМОСФЕРЕ ЦЕНТРАЛЬНОЙ СИБИРИ

О. С. Володько^{1,a}, Н. А. Буряк^{2,b}

¹ *Институт вычислительного моделирования Сибирского отделения Российской академии наук — обособленное подразделение ФИЦ КНЦ СО РАН, г. Красноярск, Российская Федерация*

² *Федеральный исследовательский центр «Красноярский научный центр Сибирского отделения Российской академии наук», г. Красноярск, Российская Федерация*

^a ORCID: <http://orcid.org/0000-0002-0580-9103>, osv@icm.krasn.ru

^b ORCID: <http://orcid.org/0009-0004-6831-9613>, buryakna98@gmail.com

Аннотация: рост концентрации углекислого газа в атмосфере, обусловленный как природными, так и антропогенными воздействиями, является одной из ключевых причин изменения климата, что делает проблему точного долгосрочного прогнозирования выбросов принципиально важным вопросом современной науки. В работе выполнен сравнительный анализ эффективности различных методов машинного обучения для прогнозирования временных рядов концентрации углекислого газа на основе данных научной обсерватории «Станция высотной мачты» в Центральной Сибири за период 2009–2022 гг. Рассмотрены ансамблевые модели: случайный лес, градиентный бустинг — и рекуррентная нейронная сеть с архитектурой долгой краткосрочной памяти. В качестве предикторов использованы интенсивность пожаров, лаговая переменная (количество дней от начала наблюдений) и метеорологические параметры: температура воздуха, максимальная и минимальная температура за день, температура точки росы, относительная влажность, скорость ветра, атмосферное давление, количество осадков. Показано, что архитектура нейронной сети долгой краткосрочной памяти обеспечивает более высокую точность прогноза на валидационной выборке по сравнению с ансамблевыми методами (средняя абсолютная ошибка: 2,87, среднеквадратичная ошибка: 3,91, коэффициент детерминации: 0,83). Установлено, что наиболее значимыми предикторами являются температура воздуха, относительная влажность, температура точки росы и скорость ветра.

Ключевые слова: прогнозирование, углекислый газ, изменение климата, случайный лес, градиентный бустинг, нейросетевая модель долгой краткосрочной памяти.

Благодарности: авторы выражают благодарность к.б.н. Алексею Васильевичу Панову, с.н.с. Института леса им. В.Н. Сукачева СО РАН — обособленного подразделения ФИЦ КНЦ СО РАН, за предоставление данных измерений концентрации CO₂ со станции ZOTTO.

Для цитирования: Володько О. С., Буряк Н. А. Нейросетевая модель временных рядов для прогнозирования уровня углекислого газа в атмосфере Центральной Сибири. *Успехи кибернетики*. 2026;7(2):102–108.

Поступила в редакцию: 10.04.2026.

В окончательном варианте: 30.04.2026.

A NEURAL NETWORK TIME SERIES MODEL TO FORECAST ATMOSPHERIC CARBON DIOXIDE CONCENTRATIONS IN CENTRAL SIBERIA

O. S. Volodko^{1,a}, N. A. Buryak^{2,b}

¹ *Institute of Computational Modeling, Siberian Branch of the Russian Academy of Sciences, Krasnoyarsk, Russian Federation*

² *Federal Research Center Krasnoyarsk Science Center of the Siberian Branch of the Russian Academy of Sciences, Krasnoyarsk, Russian Federation*

^a ORCID: <http://orcid.org/0000-0002-0580-9103>, osv@icm.krasn.ru

^b ORCID: <http://orcid.org/0009-0004-6831-9613>, buryakna98@gmail.com

Abstract: the rise in atmospheric carbon dioxide concentrations driven by natural and anthropogenic factors is one of the main causes of climate change, making accurate long-term forecasting of atmospheric carbon dioxide concentrations an important scientific challenge. In this study, we compared the performance of several machine learning methods for forecasting atmospheric carbon dioxide concentrations using time series data collected at the ZOTTO Station in Central Siberia in

2009–2022. We evaluated ensemble methods, including random forest and gradient boosting, together with a recurrent neural network based on the Long Short-Term Memory architecture. The predictor variables included fire intensity, a lag variable representing the number of days since the beginning of the observation period, and meteorological parameters, including air temperature, daily maximum and minimum temperatures, dew point temperature, relative humidity, wind speed, atmospheric pressure, and precipitation. The results showed that the Long Short-Term Memory model achieved higher forecasting accuracy on the validation dataset than the ensemble methods, with a 2.87 mean absolute error, .91 RMS error, and 0.83 coefficient of determination. We found that air temperature, relative humidity, dew point temperature, and wind speed were the most important predictors of atmospheric carbon dioxide concentrations.

Keywords: forecasting, carbon dioxide, climate change, random forest, gradient boosting, LSTM.

Acknowledgements: the authors are grateful to Dr. Alexei V. Panov, Senior Researcher at the Sukachev Institute of Forest, Siberian Branch, Russian Academy of Sciences, a division of Federal Research Center Krasnoyarsk Science Center of the Siberian Branch of the Russian Academy of Sciences, for providing atmospheric CO₂ concentration measurement data from the ZOTTO Station.

Cite this article: Volodko O. S., Buryak N. A. A Neural Network Time Series Model to Forecast Atmospheric Carbon Dioxide Concentrations in Central Siberia. *Russian Journal of Cybernetics*. 2026;7(2):102–108.

Original article submitted: 10.04.2026.

Revision submitted: 30.04.2026.

Введение

Концентрация углекислого газа CO₂ в атмосфере с 1958 года выросла более чем на 30%. Углекислый газ является основным парниковым газом, ответственным за глобальное потепление, таяние ледников, повышение уровня моря, закисление океана и увеличение частоты возникновения экстремальных погодных явлений.

Экосистема Сибири играет ключевую роль в глобальном углеродном цикле, однако ее динамика изучена недостаточно из-за удаленности региона и ограниченной сети наземных наблюдений. Научная обсерватория «Станция высотной мачты» (ZOTTO) с 2009 года обеспечивает непрерывные высокоточные измерения концентраций парниковых газов на шести высотах (до 301 м), что позволяет получать репрезентативные данные о фоновом состоянии атмосферы над Сибирью [1].

В мировой практике для прогнозирования CO₂ применяются различные подходы: от классических статистических моделей до современных методов машинного обучения и нейросетевых моделей. Исследование [2] в пригороде Китая продемонстрировало, что случайный лес и градиентный бустинг позволяют строить прогнозы и выделять ключевые метеорологические факторы, влияющие на сезонную динамику CO₂. В работе [3] для прогнозирования применяются нейросетевые модели, в том числе рекуррентная нейронная сеть с архитектурой долгой краткосрочной памяти.

Однако большинство работ либо ориентированы на глобальный масштаб, либо используют данные за короткие периоды. Задача долгосрочного прогнозирования CO₂ с применением нейросетевых архитектур остается недостаточно изученной, особенно для сибирского региона.

Цель настоящей работы — сравнительный анализ эффективности прогноза нейросетевой моделью долгой краткосрочной памяти и ансамблевыми методами (случайный лес и градиентный бустинг) ежедневной концентрации CO₂ в атмосфере Центральной Сибири на основе метеорологических параметров.

Материалы и методы

В работе использованы данные ежедневных измерений концентрации CO₂ на станции ZOTTO за период 2009–2022 гг. [4], выполняемые Институтом леса им. В.Н. Сукачева СО РАН (обособленное подразделение ФИЦ КНЦ СО РАН) совместно с Институтом биогеохимии Макса Планка. В качестве параметров для прогноза использованы следующие характеристики: интенсивность пожаров (данные системы управления ресурсами информации о пожарах (FIRMS) [5]),

лаговая переменная (количество дней от начала наблюдений), метеорологические параметры: температура воздуха, максимальная и минимальная температура за день, температура точки росы, относительная влажность, скорость ветра, атмосферное давление, количество осадков (данные с сайта Национального управления по авиации и исследованию космического пространства (NASA) [6]).

Для сравнительного анализа были реализованы ансамблевые модели машинного обучения: случайный лес [7], градиентный бустинг [8] — и нейросетевая модель долгой краткосрочной памяти [9]. В настоящей работе случайный лес представляет собой ансамбль из 100 решающих деревьев, каждое из которых обучалось на случайной подвыборке данных. Итоговый прогноз получен усреднением предсказаний по всем деревьям. Градиентный бустинг — метод последовательного построения деревьев, где каждое следующее дерево исправляет ошибки предыдущего. Использовалась стандартная реализация с регуляризацией для предотвращения переобучения.

Нейросетевая модель долгой краткосрочной памяти — рекуррентная нейронная сеть, способная учитывать долгосрочные зависимости во временных рядах благодаря механизму вентилей. Данный механизм включает регулирующие элементы, описываемые формулами (1)–(4):

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f), \quad (1)$$

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (2)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o), \quad (3)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tanh(W_c x_t + U_c h_{t-1} + b_c), \quad (4)$$

где σ — сигмоида, x_t — вход блока t , h_{t-1} — выход блока $t-1$, c_{t-1} — внутреннее состояние блока $t-1$, $\odot$ — поэлементное произведение, $W_f, W_i, W_o, W_c, U_f, U_i, U_o, U_c, b_f, b_i, b_o, b_c$ — параметры модели, которые необходимо оценить. Вентиль забывания (1) определяет, какую информацию из предыдущего состояния ячейки следует удалить. Вентиль входного состояния (2) решает, какую новую информацию добавить. Вентиль выходного состояния (3) определяет, какая часть обновленного состояния ячейки будет передана на выход. Внутреннее состояние ячейки (4) выступает в роли долговременной памяти, сохраняя ключевую информацию на протяжении многих шагов.

Архитектура нейросетевой модели включала два слоя (128 и 32 нейрона) с вероятностью отключения нейронов, равной 0,3, для регуляризации, функция потерь — среднеквадратичная ошибка. Обучение останавливалось досрочно при отсутствии улучшения на валидационной выборке в течение семи эпох, дополнительно создавалось окно истории в размере 30 дней для прогноза следующего дня. Для всех данных применялась нормализация методом минимакс [10], приводящая значения признаков к диапазону [0;1]. Это необходимо для корректной работы нейросетевых моделей, чувствительных к масштабу входных величин.

Выборка была разделена на обучающую (60%), валидационную (15%) и тестовую (25%) части с сохранением хронологического порядка. Качество прогнозов оценивалось на валидационной выборке по трем стандартным метрикам [11]: средняя абсолютная ошибка (MAE), среднеквадратичная ошибка ($RMSE$), коэффициент детерминации (R^2):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2},$$

где y_i — истинное значение, $\hat{y}_i$ — прогнозируемое значение, $\bar{y}$ — среднее значение в выборке, n — количество объектов выборки.

Для оценки качества прогнозирования нейросетевой моделью проверка проводилась в два этапа. Первый этап: стандартное разделение на обучающую и валидационную выборку. Второй этап: модель обучалась на периоде с 2009 по 2018 год, после чего ее веса были сохранены, далее она была протестирована на новом периоде с 2019 по 2022 год (тестовая выборка) без дообучения. Это позволило оценить способность модели к прогнозированию на будущих данных в условиях, максимально приближенных к реальному применению.

Результаты и анализ

В таблице приведены оценки точности прогнозирования, полученные на первом этапе.

Таблица

Сравнение качества прогноза ансамблевых моделей и нейросетевой модели долгой краткосрочной памяти

Модель	MAE	RMSE	R^2
Случайный лес	5,23	7,06	0,42
Градиентный бустинг	4,74	6,23	0,55
Нейросетевая модель долгой краткосрочной памяти	2,87	3,91	0,83

Архитектура нейросетевой модели долгой краткосрочной памяти продемонстрировала лучшее качество прогноза, превосходя ансамблевые методы по всем метрикам. Высокий коэффициент детерминации ($R^2 = 0,83$) свидетельствует о том, что модель объясняет 83% дисперсии исходного ряда CO_2 . Близость значений MAE и $RMSE$ (2,87 и 3,91 соответственно) указывает на отсутствие крупных выбросов в прогнозах.

Для оценки модели долгой краткосрочной памяти в максимально приближенных к реальности условиях был проведен второй этап проверки. Результаты второго этапа со следующими оценками: $MAE = 4,39$, $RMSE = 4,45$, $R^2 = 0,66$ — представлены на рисунке 1.




Рис. 1. Сравнение результатов прогноза нейросетевой моделью долгой краткосрочной памяти с натурными измерениями CO_2

Также был проведен анализ важности признаков, который показал, что наибольший вклад в прогноз вносят температура воздуха, скорость ветра, температура точки росы и относительная влажность. Для анализа применялись коэффициенты корреляции Пирсона [12] и Спирмена [13], результаты представлены на рисунках 2–3 соответственно.

На следующем этапе для оценки долгосрочной динамики CO_2 на период с 2026 по 2029 год были сформированы прогнозные значения ключевых метеорологических параметров: температура воздуха, температура точки росы, относительная влажность, скорость ветра — с помощью отдельной модели долгой краткосрочной памяти, обученной на многолетнем ряде наблюдений. Полученные прогнозные метеоанализы подавались на вход ранее обученной модели. В результате получен прогноз среднесуточной концентрации CO_2 на 2026–2029 годы (рисунок 4).

Полученные результаты подтверждают эффективность применения рекуррентных нейросетей для долгосрочного прогнозирования концентрации углекислого газа в атмосфере. Преимущество рекуррентной нейронной сети долгой краткосрочной памяти перед ансамблевыми ме-




Рис. 2. Матрица корреляций признаков, коэффициент Пирсона

тодами машинного обучения объясняется способностью архитектуры учитывать долгосрочные зависимости благодаря механизму вентиляей, тогда как случайный лес и градиентный бустинг оперируют только фиксированным набором признаков без учета последовательной структуры данных.

Выявленная высокая значимость температуры, влажности и скорости ветра как предикторов согласуется с физикой процесса: температура воздуха контролирует интенсивность дыхания экосистем (выделение углекислого газа), влажность — активность фотосинтеза (поглощение углекислого газа), а скорость ветра отвечает за рассеивание частиц в воздухе.

Сформированный прогноз на три года вперед: с 2026 по 2029 год — демонстрирует продолжение тренда роста концентрации углекислого газа в атмосфере над Центральной Сибирью, что согласуется с глобальными наблюдениями и подтверждает устойчивость выявленных закономерностей.

Заключение

Проведен сравнительный анализ трех методов машинного обучения для прогнозирования ежедневной концентрации углекислого газа в Центральной Сибири. Показано, что модель нейронной сети долгой краткосрочной памяти превосходит ансамблевые методы (случайный лес и градиентный бустинг) по точности прогноза.

Установлено, что ключевыми метеорологическими предикторами для прогноза углекислого газа являются температура воздуха, относительная влажность и скорость ветра, что соответствует физическим представлениям о функционировании наземных экосистем.

Выполнено прогнозирование ежедневной величины концентрации углекислого газа в атмосфере Центральной Сибири на период с 2026 по 2029 год с помощью модели нейронной сети долгой краткосрочной памяти.

В дальнейших исследованиях предполагается оценить вклад антропогенных источников (промышленные выбросы, энергетика, транспорт) в общий баланс углекислого газа.




Рис. 3. Матрица корреляций признаков, коэффициент Спирмена




Рис. 4. Прогноз ежедневной величины концентрации CO_2 в атмосфере Центральной Сибири нейросетевой моделью долгой краткосрочной памяти на три года вперед: с 2026 по 2029 год

ЛИТЕРАТУРА

1. Timokhina A. V., Prokushkin A. S., Panov A. V., Kolosov R. A., Sidenko N. V., Lavric J., Heimann M. Interannual Variability of Atmospheric CO_2 Concentrations over Central Siberia from ZOTTO Data for 2009–2015. *Russian Meteorology and Hydrology*. 2018;43(5):288-294. DOI: 10.3103/S1068373918050023.
2. Liu W., Niu Z., Feng X., Zhou W., Liang D., Wang G., Liu L. Determining the Key Meteorological Factors Affecting Atmospheric CO_2 and CH_4 Using Machine Learning Algorithms at a Suburban

- Site in China. *Urban Climate*. 2025;59:102312. DOI: 10.1016/j.uclim.2025.102312.
3. Rezaei Z., Samghabadi S. S., Amini M. A., Shi D., Banad Y. M. Predicting Climate Change: A Comparative Analysis of Time Series Models for CO_2 Concentrations and Temperature Anomalies. *Environmental Modelling & Software*. 2025;192:106533. DOI: 10.1016/j.envsoft.2025.106533.
 4. Dieu Anh T., Gerbig C., Rödenbeck C., Panov A., Prokushkin A., Winderlich J., Lavrič J., Heimann M., Seifert T., Schultz U., Schmidt S., Zaehle S. Zotino Tall Tower Observatory (ZOTTO) Hourly CO_2 Measurement Dataset. *Edmond*. Режим доступа: <https://doi.org/doi:10.17617/3.YBPFG2>.
 5. NASA FIRMS: Fire Information for Resource Management System. Режим доступа: <https://firms.modaps.eosdis.nasa.gov/>.
 6. NASA POWER: Prediction of Worldwide Energy Resources. Режим доступа: <https://power.larc.nasa.gov/>.
 7. Biau G., Scornet E. A Random Forest Guided Tour. *Test*. 2016;25(2):197–227. DOI: 10.1007/s11749-016-0481-7.
 8. Xie Y., Tummala S. P. Machine Learning for Sensor Analytics: A Comprehensive Review and Benchmark of Boosting Algorithms in Healthcare, Environmental, and Energy Applications. *Sensors*. 2025;25(23):7294. DOI: 10.3390/s25237294.
 9. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation*. 1997;9(8):1735–1780.
 10. Старовойтов В. В., Голуб Ю. И. Нормализация данных в машинном обучении. *Информатика*. 2021;18(3):83–96. DOI: 10.37661/1816-0301-2021-18-3-83-96.
 11. Brassington G. Mean Absolute Error and Root Mean Square Error: Which Is the Better Metric for Assessing Model Performance? *EGU General Assembly Conference Abstracts*. 2017;19:3574.
 12. Pearson K. On Lines and Planes of Closest Fit to Systems of Points in Space. *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science*. 1901;2(11):559–572. DOI: 10.1080/14786440109462720.
 13. Hauke J., Kossowski T. Comparison of Values of Pearson's and Spearman's Correlation Coefficients on the Same Sets of Data. *Quaestiones Geographicae*. 2011;30(2):87–93. DOI: 10.2478/v10117-011-0021-1.