



Всероссийская конференция с международным участием «Обработка пространственных данных в задачах мониторинга природных и антропогенных процессов», посвященная памяти академика Ю.И. Шокина
г. Белокуриха, Алтайский край, Россия, 2025

НЕЙРОСЕТЕВАЯ МОДЕЛЬ ВРЕМЕННЫХ РЯДОВ ДЛЯ ПРОГНОЗИРОВАНИЯ КОНЦЕНТРАЦИИ ЗАГРЯЗНЯЮЩИХ ВЕЩЕСТВ В АТМОСФЕРЕ Г. КРАСНОЯРСКА

Володько Ольга Станиславовна, к.ф.-м.н.,
Лев Никита Андреевич², Полянчикова Дарья Витальевна²



¹Институт Вычислительного Моделирования СО РАН, г. Красноярск



Федеральный исследовательский центр КНЦ СО РАН, г. Красноярск



²Сибирский Федеральный Университет, г. Красноярск

Метеоусловия и РМ

- Stafoggia, M. et al. Estimation of daily PM10 and PM2.5 concentrations in Italy 2013–2015, using a spatiotemporal land-use random-forest model // Environment international. – 2019. – № 124. – p. 170–179.
- Liu, X. et al. Air pollution in Germany: Spatio-temporal variations and their driving factors based on continuous data from 2008 to 2018 // Environmental Pollution. 2021. – № 276. – p. 116–732.
- Toro, R. et al. Exploring atmospheric stagnation during a severe particulate matter air pollution episode over complex terrain in Santiago // Environmental pollution. 2019. – № 244. – p. 705–714.
- Du, H. et al. Assessment of the effect of meteorological and emission variations on winter PM2.5 over the North China Plain in the three-year action plan against air pollution in 2018–2020 // Atmospheric Research. 2022. – № 280. – p. 106–395.

Модели машинного обучения для прогноза уровня РМ

Модели регрессии

- Abdullah S., et al. Development of multiple linear regression for particulate matter (PM10) forecasting during episodic transboundary haze event in Malaysia / S. Abdullah // Atmosphere. – 2020. – Vol. 11. – P. 289.

Модели прогнозирования временных рядов

ARIMA и ARIMAX

- Agarwal, P. A Study on Time Series Forecasting using Hybridization of Time Series Models and Neural Networks / P. Agarwal // Recent Advances in Computer Science and Communications. – 2020. – Vol. 13. – P. 827-832.

Ансамблевые модели

Случайный лес

- Hui Liu. Intelligent modeling strategies for forecasting air quality time series: A review / Liu Hui // Applied Soft Computing Journal – 2021. – Vol. 102. – P. 106957.

Градиентный бустинг

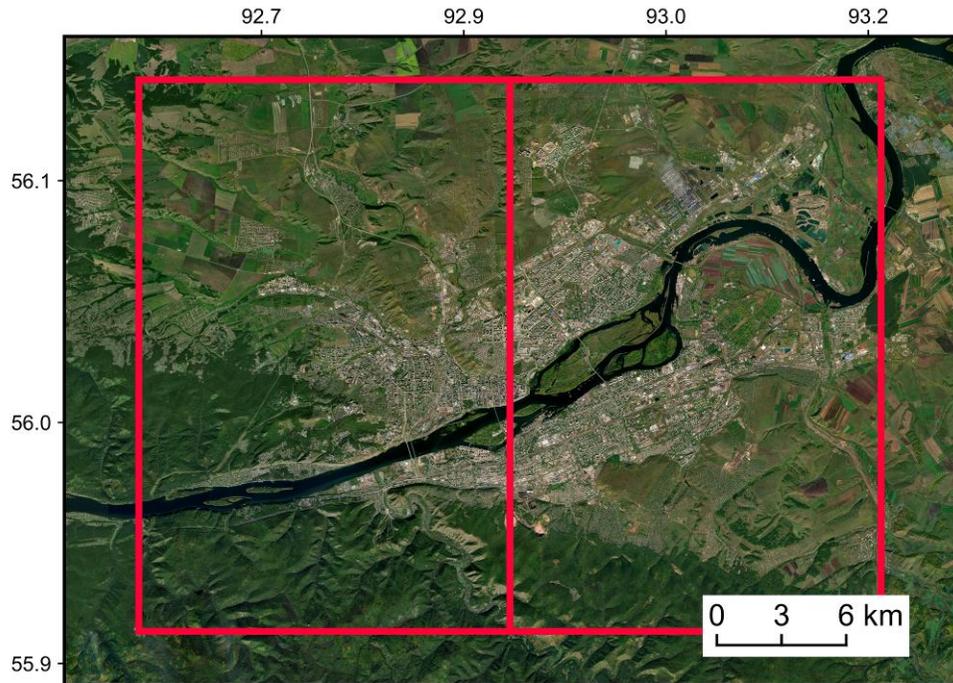
- Das R., Middy A. I., Roy S. High granular and short-term time series forecasting of PM2.5 air pollutant – a comparative review / R. Das, A. Middy, S. Roy // Artif. Intell. Rev. – 2022. – Vol. 55. – P. 1253-1287.

Нейросетевые модели прогнозирования временных рядов

LSTM

- Lin, M.D., Liu, P.Y., Huang, C.W. and Lin, Y.H. The application of strategy based on LSTM for the short-term prediction of PM2.5 in city. *Science of The Total Environment*, V.906, P. 167892 (2024).
- Das R., Middy A. I., Roy S., High granular and short-term time series forecasting of PM2.5 air pollutant – a comparative review. *Artif. Intell. Rev*, V.55, P. 1253-1287 (2022).
- Agarwal, P. A Study on Time Series Forecasting using Hybridization of Time Series Models and Neural Networks. *Recent Advances in Computer Science and Communications*, V.13, P. 827-832 (2020).

Район исследования



Красными рамками обозначены две ячейки регулярной сетки модели GFS

Данные метеоусловий получены:

- 1) Наземные станции мониторинга [2]
- 2) Метеоинформации модели реанализа National Centers for Environmental Prediction Global Forecast System (NCEP GFS) [3]

Период: 2019 - 2024 гг.

[2] Геопортал – данные оперативного мониторинга: сайт. – URL: <http://sensor.krasn.ru/sc/> (дата обращения 14.04.2024)

[3] The Global Forecast System (GFS): сайт. – URL:

https://www.emc.ncep.noaa.gov/emc/pages/numerical_forecast_systems/gfs.php (дата обращения: 21.06.2023)

Данные для анализа

Пример данных NCEP GFS

Название	Расшифровка
DT1	Разность температур на изобарических слоях 1000 мбар – 925 мбар
DT2	Разность температур на изобарических слоях 925 мбар – 850 мбар
DT3	Разность температур на изобарических слоях 1000 мбар – 850 мбар
APTMP	Ощущаемая температура (К)
GUST	Скорость ветра (м/с)
POT	Потенциальная температура (К)
RH_m_2	Относительная влажность при 2м над землёй (%)
RH_mb_70	Относительная влажность на 700mb (%)
SOILW_g_0	Влажность почвы на 0-0.1 м над землёй (доля)
TMP_m_2	Температура на 2м над землёй (К)
TMP_m_80	Температура на 80м над землёй (К)
TMP_mb_750	Температура на 750mb (К)
TOZNE	Общий озон (DU)
UGRD_m_10	U-компонента ветра на высоте 10 м (м/с)
UGRD_m_80	U-компонента ветра на высоте 80 м (м/с)

Данные для анализа

Наземные станции мониторинга	Модель реанализа NCEP GFS
Температура воздуха	Разность температур на изобарических слоях 1000 мбар – 925 мбар
Влажность воздуха	Разность температур на изобарических слоях 925 мбар – 850 мбар
Атмосферное давление	Разность температур на изобарических слоях 1000 мбар – 850 мбар
Скорость ветра	
Направление ветра	
Концентрация частиц PM _{2.5}	

ФИЦ КНЦ: Николаевка, Овинный, Песчанка, Телевизорный и Ветлужанка.

Министерство: Кировский, Северный, Покровский, Черёмушки, Солнечный, Свердловский, Ветлужанка.

Модели регрессии

- Линейная регрессия

$$\tilde{y}(x) = w_0 + \sum_{i=1}^n w_i x_i$$

- Функция ошибки

$$Q(y, x) = \frac{1}{n} \sum_{i=1}^n (\tilde{y}(x_i) - y_i)^2 \rightarrow \min$$

- Lasso-регрессия (L1-регуляризация)

$$Q_{lasso}(y, x) = \frac{1}{n} \sum_{i=1}^n (\tilde{y}(x_i) - y_i)^2 + \lambda |w_i|$$

- Ridge-регрессия (L2-регуляризация)

$$Q_{ridge}(y, x) = \frac{1}{n} \sum_{i=1}^n (\tilde{y}(x_i) - y_i)^2 + \lambda w_i^2$$

- Полиномиальная регрессия степени P :

$$\tilde{y}(x) = w_0 + \sum_{k=1}^P \sum_{i=1}^n w_i x_i^k,$$

x_i – признаки,

w_i – параметры модели,

$\tilde{y}(x_i)$ – прогнозируемые значения целевой переменной для признака x_i ,

y_i – истинные значения целевой переменной,

n – количество используемых признаков,

λ – коэффициент регуляризации,

P – степень регрессии.

Модель ARIMAX (p, d, q)

- Состоит из трёх частей: авторегрессионной (AR) части, скользящего среднего (MA) и экзогенных переменных (X):

$$y_t = c + \sum_{i=1}^p a_i y_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \sum_{k=1}^r \beta_k x_{k_t} + \varepsilon_t,$$

y_t – значение временного ряда в момент времени t ,

ε_t – шумовая компонента в момент времени t ,

p – количество предыдущих значений временного ряда, используемых в модели,

q – количество предыдущих ошибок прогноза авторегрессии,

r – количество экзогенных признаков,

x_{k_t} – значение экзогенного признака k в момент времени t ,

$a_i, \beta_j, \theta_j, c$ – параметры модели, которые необходимо оценить.

[4] Володько О. С., Лев Н. А. Методы прогнозирования временных рядов в задаче анализа уровня концентрации загрязняющих веществ в атмосфере г. Красноярска / О. С. Володько, Н. А. Лев // Безопасность и мониторинг природных и техногенных систем. – 2023. – Р. 205-208.

Модель случайного леса

$$\tilde{y}(X) = \frac{1}{k} * (b_1(X) + \dots + b_n(X)),$$

$\tilde{y}(X)$ – прогноз модели на выборке X ,

$b(X)$ – модель решающего дерева,

k – количество решающих деревьев в лесу.

Критерий ошибки в каждом узле дерева:

$$Q(X_m) = \frac{|X_l|}{|X_m|} H(X_l) + \frac{|X_r|}{|X_m|} H(X_r) \rightarrow \min$$

$$H(X) = \frac{1}{|X|} \sum_{i \in X} (y_i - \bar{y}(X))^2,$$

X – обучающая выборка,

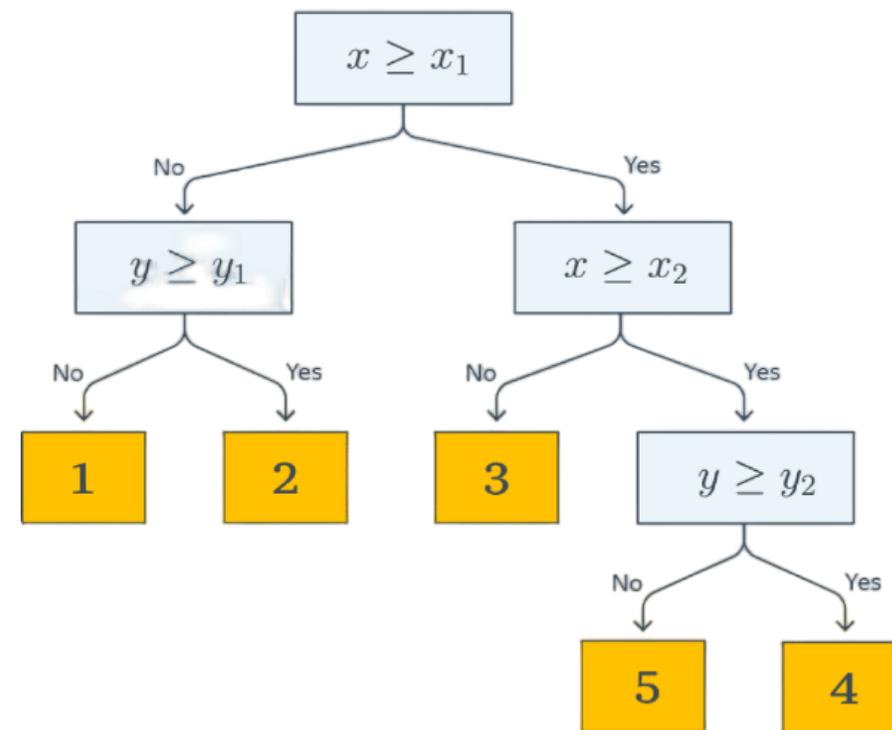
$X_{m, l, r}$ – обучающая выборка в текущей (m),

левой (l), правой (r) вершине,

y_i – значение целевой переменной,

\bar{y} – среднее значение целевой переменной.

Решающее дерево



Решающие деревья — Учебник по машинному обучению: сайт. – URL:

<https://education.yandex.ru/handbook/ml/article/reschayushchiye-derevya> (дата обращения: 08.07.2024).

Модель градиентного бустинга

$$a_N(X) = \sum_{n=1}^N b_n(X),$$

$b_n(X)$ – базовый алгоритм, X – выборка, N – количество базовых алгоритмов,

- Ошибка композиции моделей:

$$F(b) = \sum_{i=1}^l L(y_i, a_{N-1}(x_i) + b(x_i)) \rightarrow \min_b,$$

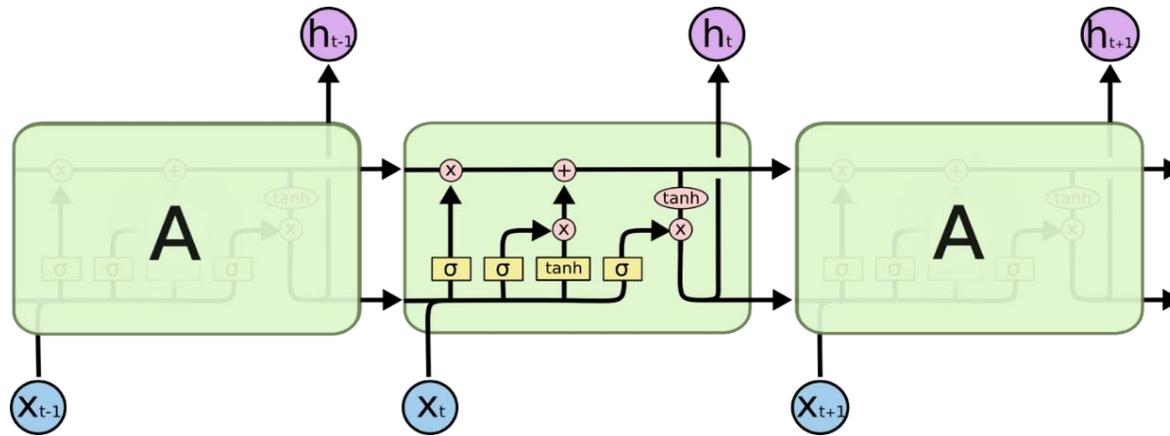
L – функция потерь (MSE), l – количество объектов обучающей выборки, b – произвольное дерево решений, y_i – значение целевой переменной.

b представим как вектор сдвигов $s = (s_1 \dots s_n)$, тогда

$$s = -\nabla F = \begin{pmatrix} -L'_{a_{N-1}(x_1)}(y_1, a_{N-1}(x_1)) \\ \dots \\ -L'_{a_{N-1}(x_l)}(y_l, a_{N-1}(x_l)) \end{pmatrix}$$

Оптимальный алгоритм $b_N(x) = \operatorname{argmin}_b L(s, b(x))$.

Модель рекуррентной нейронной сети LSTM



LSTM из трёх блоков

- Вентиль забывания: $f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f)$
- Вентиль входного состояния: $i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i)$
- Вентиль выходного состояния: $o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o)$
- Внутреннее состояние: $c_t = f_t \odot c_{t-1} + i_t \odot \tanh(W_c x_t + U_c h_{t-1} + b_c)$

σ – сигмоида, x_t – вход блока t , h_{t-1} – выход блока $t - 1$, c_t – внутреннее состояние блока t , \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.

Understanding LSTM Networks [Электронный ресурс]. URL:

<https://colah.github.io/posts/2015-08-Understanding-LSTMs/> (дата обращения: 14.08.2025)

Метрики качества моделей

- MAE – средняя абсолютная ошибка

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

- $MAPE$ – средняя абсолютная процентная ошибка

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

- MSE – средняя квадратичная ошибка

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

- R^2 – коэффициент детерминации

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

y_i – истинное значение,

\hat{y}_i – прогнозируемое значение,

\bar{y} – среднее значение в выборке,

n – количество объектов выборки.

Построение регрессионных моделей

Обучающая выборка разделялась на временные периоды в зависимости от значений концентрации $PM_{2.5}$:

- Зимний период: ноябрь – февраль.
- Весенний период: март, апрель.
- Летний период: май – июль.
- Осенний период: август – октябрь.

Вариации признаков обучающей выборки:

A: 8 главных компонент;

B: 8 главных компонент с отбором по корреляции с $PM_{2.5}$;

C: признаки, входящие в главные компоненты с наибольшими весами;

D: исходные данные метеоусловий NCEP GFS + данные станций мониторинга;

E: исходные данные метеоусловий NCEP GFS + данные станций мониторинга, коррелирующие с $PM_{2.5}$.

Сравнение регрессионных моделей на тестовой выборке

MSE на тестовой выборке

Период	A	B	C	D	E
Зимний	582.64	496,1	572.02	349,67	310.24
Весенний	35,01	26.9	37,7	27.25	26,18
Летний	35.86	37,83	38.23	35,1	33.4
Осенний	53,41	54.01	54,01	45.02	48.96

Лучшие модели для каждого временного периода:

- Зимний период – полиномиальная регрессия 2 степени.
- Весенний период – полиномиальная регрессия 2 степени.
- Летний период – Lasso регрессия.
- Осенний период – градиентный бустинг.

Сравнение качества моделей ARIMA и ARIMAX

Значения MAE на тестовой выборке

Временной период	ARIMA	ARIMAX
2019-03-12 — 2019-05-10	4.89	5.63
2019-05-10 — 2019-07-08	4.17	3.89
2019-08-28 — 2019-11-10	10.74	8.16
2019-11-25 — 2020-02-25	5.52	10.99
2020-03-15 — 2020-05-15	5.37	3.46
2020-05-01 — 2020-08-01	0.85	0.73
2020-08-01 — 2020-10-28	2.66	2.56
2020-12-15 — 2021-02-25	48.82	13.60
2021-04-01 — 2021-07-15	3.20	2.49
2021-08-15 — 2021-10-15	8.11	7.22
2022-03-01 — 2022-05-12	8.22	7.22
2022-04-01 — 2022-06-15	4.33	1.97
2022-07-16 — 2022-10-01	3.53	2.79
2022-12-01 — 2023-02-25	38.34	29.67
2023-02-25 — 2023-04-06	5.90	5.12

Построение моделей случайного леса

Гиперпараметры:

- Количество деревьев в лесу (`n_estimators`).
- Доля признаков в каждом узле (`max_features`).

Обучающая выборка разделялась двумя способами:

- По годам: 2019-2024, 2020-2024, 2021-2024, 2022-2024, 2019, 2020, 2021, 2022, 2023.
- По величине концентрации PM2.5 [5]:
 - зима (ноябрь - февраль);
 - весна (март, апрель);
 - лето (май - июль);
 - осень (август - октябрь).

[5] Volodko O., Yakubailik O., Lapo T., Dergunov A. Influences of meteorological conditions in PM 2.5 levels in Krasnoyarsk city atmosphere / O. Volodko, O. Yakubailik, T. Lapo, A. Dergunov // E3S Web of Conf.– 2023 – Vol. 392. – P. 02022.

Построение моделей градиентного бустинга

Гиперпараметры подбирались при помощи поиска по сетке:

- Шаг спуска (`learning_rate`).
- Количество деревьев (`n_estimators`).
- Глубина дерева (`max_depth`).
- Доля объектов в узле (`subsample`).

Оценка качества модели проводилась по кросс-валидации (5-fold).

Сравнение моделей градиентного бустинга и случайного леса

Значения MSE

Временной период	Бустинг	Случайный лес
Зима	444.17	450.19
Весна	51.32	63.01
Лето	71.43	74.19
Осень	27.29	27.94

Значения R^2

Временной период	Бустинг	Случайный лес
Зима	0.79	0.77
Весна	0.70	0.63
Лето	0.16	0.14
Осень	0.64	0.63

Сравнение моделей бустинга регрессий с ARIMAX

MSE на тестовой выборке

Сезон	Градиентный бустинг регрессий	ARIMAX
Зима	251.46	302.67
Весна	15.74	14.66
Лето	6.75	1.24
Осень	1.9	0.87

[5] Володько О. С., Лев Н. А. Методы прогнозирования временных рядов в задаче анализа уровня концентрации загрязняющих веществ в атмосфере г. Красноярска. Безопасность и мониторинг природных и техногенных систем, Р. 205-208 (2023)

Построение моделей LSTM

Гиперпараметры подбирались при помощи поиска по сетке:

- Количество нейронов (units).
- Количество эпох (epochs).
- Доля прореживания нейронов (dropout).
- Количество шагов во времени в прошлое (n_steps).

Сравнение моделей LSTM по способу разделения выборки

Значения MSE

Временной период	Срез 1-2 месяца	Сезонная модель
Зима	366.82	247.87
Весна	103.12	64.27
Лето	35.35	35.07
Осень	29.89	29.64

Значения MAE

Временной период	Срез 1-2 месяца	Сезонная модель
Зима	14.04	10.30
Весна	6.81	5.09
Лето	4.01	2.62
Осень	3.46	3.07

Сравнение моделей LSTM и ARIMAX

Значения MAE на тестовой выборке

Период прогнозирования		ARIMAX	LSTM
20 – 22 декабря	2022	8.34	1.63
20 – 22 июля	2022	2.53	0.35
12 – 14 августа	2022	3.09	1.61
10 – 12 марта	2023	5.43	4.05
10 – 12 апреля	2023	3.81	0.72
10 – 12 мая	2023	5.07	0.77
10 – 12 июля	2023	0.29	0.87
23 – 25 сентября	2023	4.77	0.84
23 – 25 октября	2023	5.26	0.82
10 – 12 января	2024	11.83	3.11
10 – 12 февраля	2024	13.21	0.93
17 – 19 марта	2024	7.01	0.48

Прогноз модель LSTM Срез зимнего периода

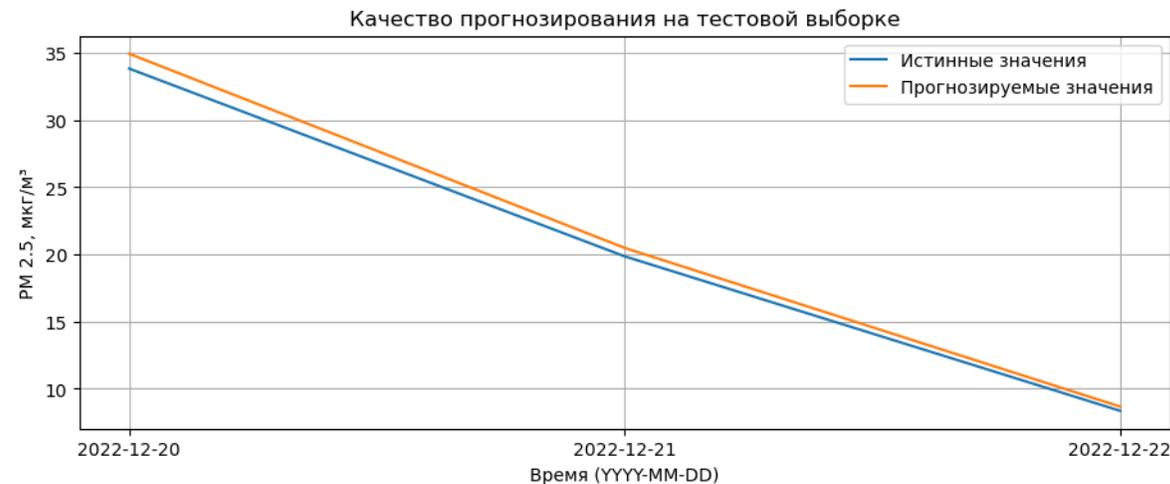
Период прогноза 3 дня: с 20 по 22 декабря 2022 г.

Почасовой прогноз



MAE = 4.44; $R^2 = 0.89$

Среднесуточный

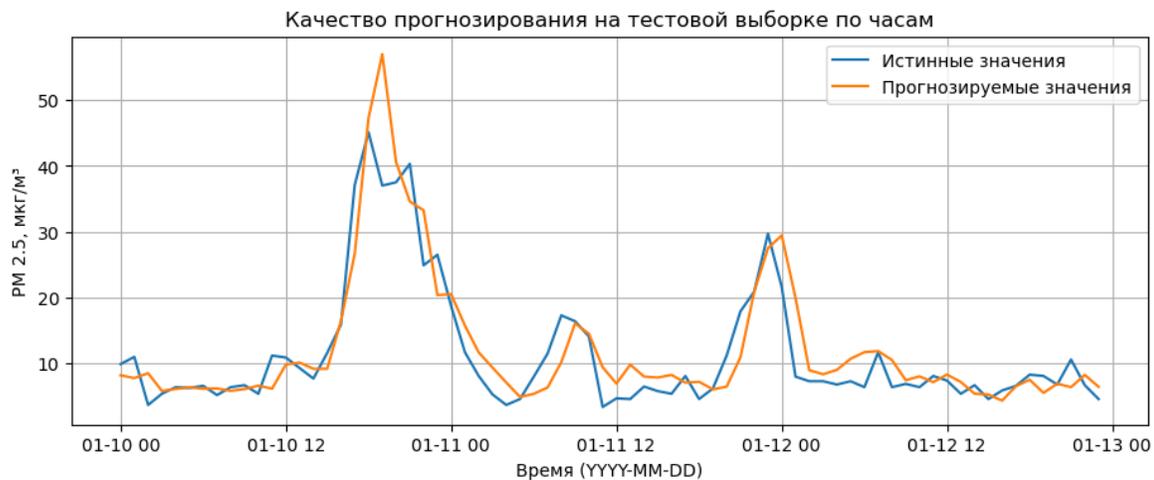


MAE = 0.68; $R^2 = 0.99$

Прогноз модель LSTM Срез зимнего периода

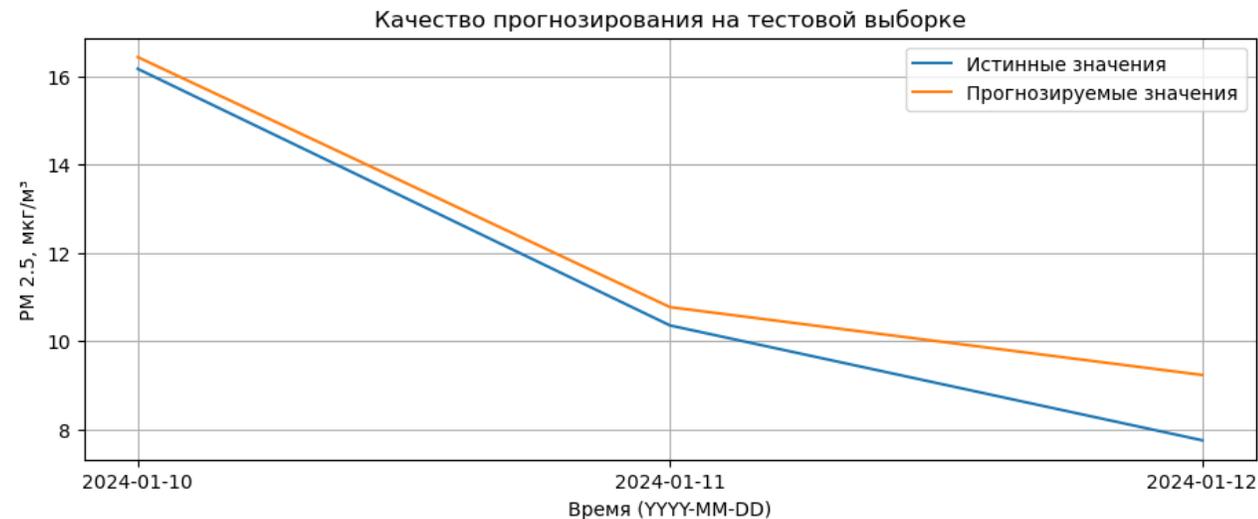
Период прогноза 3 дня: с 10 по 11 января 2024 г.

Почасовой прогноз



MAE = 2.92; $R^2 = 0.79$

Среднесуточный

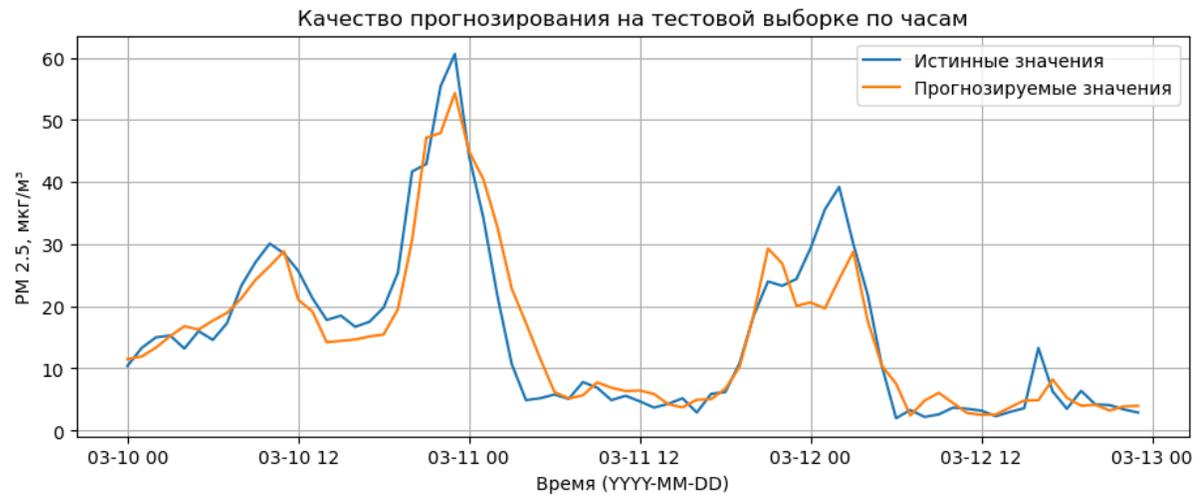


MAE = 0.72; $R^2 = 0.93$

Прогноз модель LSTM Срез весеннего периода

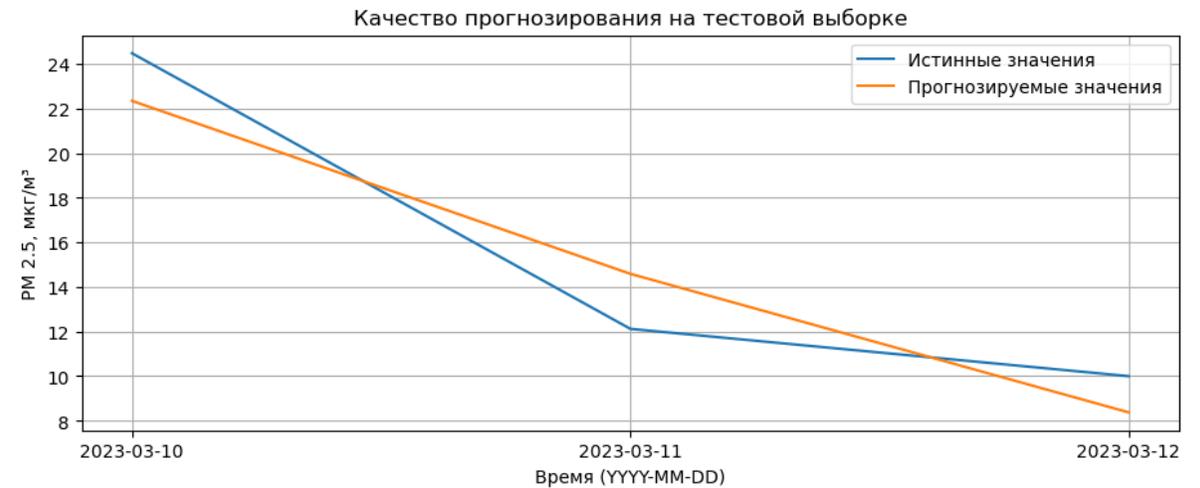
Период прогноза 3 дня: с 10 по 12 марта 2023 г.

Почасовой прогноз



MAE = 3.29; $R^2 = 0.87$

Среднесуточный



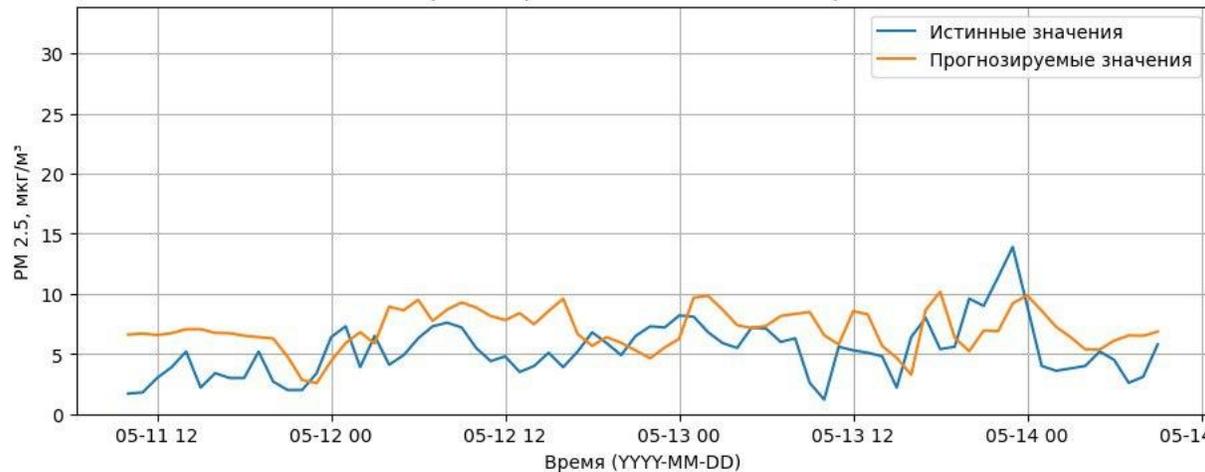
MAE = 2.07; $R^2 = 0.89$

Прогноз модель LSTM Срез весеннего периода

Период прогноза 3 дня: с 11 по 13 мая 2025 г.

Почасовой прогноз

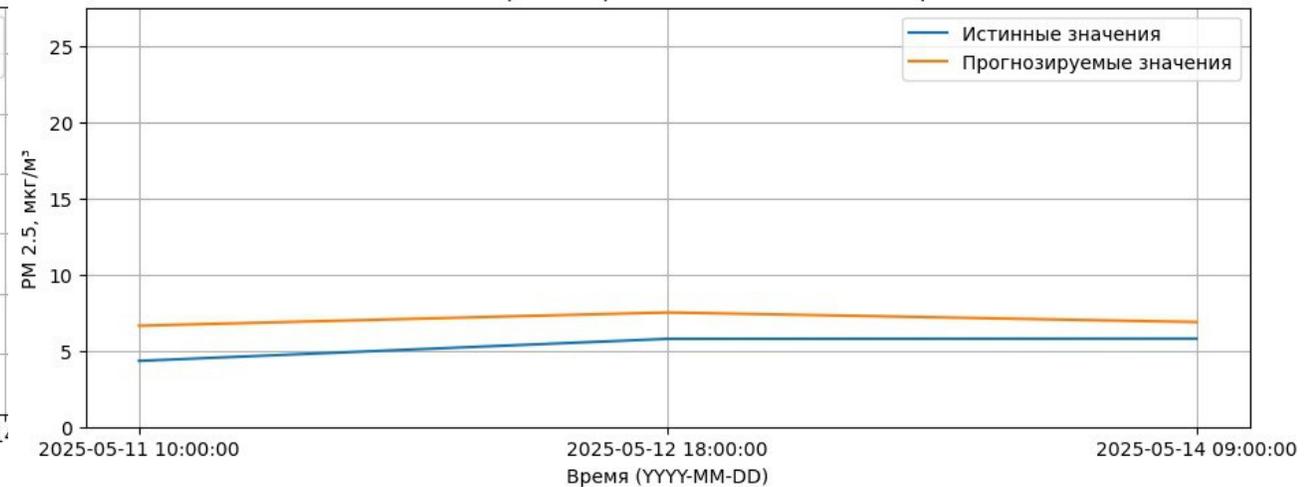
Качество прогнозирования на тестовой выборке по часам



MAE = 2.60; $R^2 = 0.82$

Среднесуточный

Качество прогнозирования на тестовой выборке



MAE = 1.48; $R^2 = 0.90$

Прогноз модель LSTM Срез летнего периода

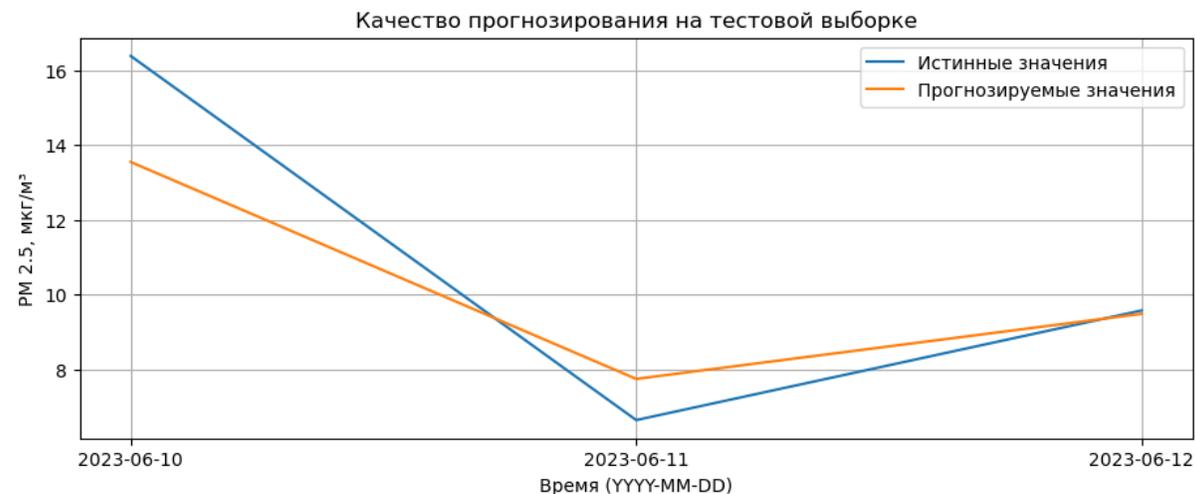
Период прогноза 3 дня: с 10 по 12 июня 2023 г.

Почасовой прогноз



MAE = 2.26; $R^2 = 0.74$

Среднесуточный



MAE = 1.34; $R^2 = 0.81$

Прогноз модель LSTM

Срез осеннего периода

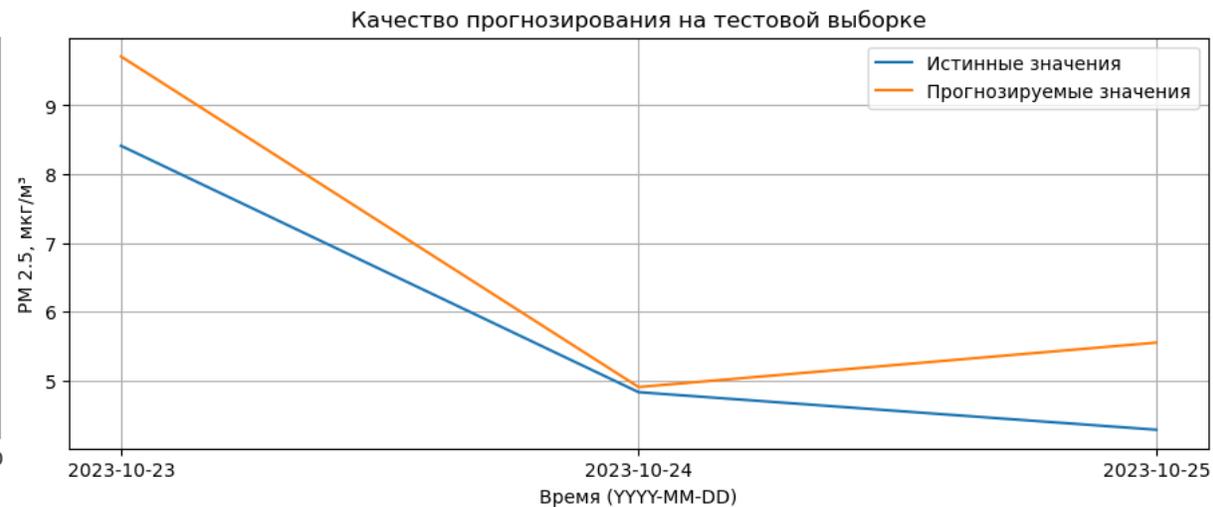
Период прогноза 3 дня: с 23 по 25 октября 2023 г.

Почасовой прогноз



MAE = 1.80; $R^2 = 0.76$

Среднесуточный



MAE = 0.88; $R^2 = 0.83$

Заключение

- Сравнение качества прогноза нейросетевой моделью LSTM с построенными ранее моделями машинного обучения, показало преимущество нейросетевых моделей LSTM по сравнению с лучшими моделями машинного обучения ARIMAX.
- Нейросетевую модель LSTM планируется использовать для прогноза величины концентрации PM 2.5 в г. Красноярске в рамках задач экологического мониторинга качества атмосферного воздуха.

Спасибо за внимание!

Володько Ольга Станиславовна
к.ф.-м.н., н.с. ИВМ СО РАН
E-mail: olga.pitalskaya@gmail.com

