

Строитель Донбасса. 2025. Выпуск 2-2025 С. 85-93. ISSN 2617–1848 (print)
The Builder of Donbass. 2025. Issue 2-2025. P. 85-93. ISSN 2617–1848 (print)

Научная статья

УДК 504.3.054

doi: 10.71536/sd.2025.2c31.12

ПРИМЕНЕНИЕ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ ПРИ ПРОГНОЗИРОВАНИИ ЗАГРЯЗНЕНИЯ РМ2.5 В СТРОИТЕЛЬСТВЕ

Светлана Евгеньевна Манжилевская¹, Дмитрий Рафаэлович Маилян²

^{1,2}Донской государственный технический университет, Ростов-на-Дону, Россия,

¹smanzhilevskaya@yandex.ru, ²dmailyan868@mail.ru

Аннотация. В настоящее время строительная отрасль активно внедряет передовые цифровые технологии, что открывает новые возможности для изучения потенциала прогностических инструментов в области контроля загрязнения воздуха мелкодисперсной пылью с целью повышения экологической безопасности городских территорий. С использованием существующих алгоритмов искусственного интеллекта можно эффективно отслеживать концентрацию пылевых частиц в атмосфере. Для подтверждения возможности долгосрочного прогнозирования пылевого загрязнения во время строительных работ были протестированы семь моделей машинного обучения: ARIMA, EMA, Prophet, нейронные сети NARX и NNAR, Random Forest, SVM и XGBoost.

Целью работы была оценка эффективности прогнозирования уровня пылевого загрязнения с использованием различных моделей машинного обучения. С использованием программного обеспечения «Modeltime» был проведен детальный анализ корреляционных связей между метеопараметрами и концентрациями мелкодисперсных частиц. Результаты исследования показывают, что использование ансамблевого моделирования дает эффективные прогнозы уровня атмосферного загрязнения. Среди семи протестированных алгоритмов машинного обучения были выделены наиболее точные в прогнозировании концентрации мелкодисперсных частиц – ARIMA, Random Forest и XGBoost.

Ключевые слова: мелкодисперсная пыль, загрязнение воздушной среды, искусственный интеллект, пылевое загрязнение, экологическая безопасность городских территорий

Original article

APPLICATION OF MACHINE LEARNING ALGORITHMS FOR PREDICTING PM2.5 POLLUTION IN CONSTRUCTION

Svetlana E. Manzhilevskaya¹, Dmitrii R. Mailyan²

^{1,2}Don State Technical University, Rostov-on-Don, Russia

¹smanzhilevskaya@yandex.ru, ²dmailyan868@mail.ru

Abstract. Currently, the construction industry is actively implementing advanced digital technologies, which opens up new opportunities for studying the potential of predictive tools in the field of air pollution control with fine dust in order to improve the environmental safety of urban areas. Using existing artificial intelligence algorithms, it is possible to effectively track the concentration of dust particles in the Earth's atmosphere. To confirm the possibility of long-term forecasting of dust pollution during construction work, seven machine learning models were tested: ARIMA, EMA, Prophet, NARX and NNAR neural networks, Random Forest, SVM and XGBoost.

The aim of the research was to evaluate the effectiveness of predicting the level of dust pollution using various machine learning models. Using the Modeltime software, a detailed analysis of correlations between meteorological parameters and concentrations of fine particles was carried out. The results of the study show that the use of ensemble modeling provides effective forecasts of the level of atmospheric air pollution. Among the seven tested machine learning algorithms, the most accurate in predicting the concentration of fine particles were identified – ARIMA, Random Forest and XGBoost.

Keywords: fine dust, air pollution, artificial intelligence, dust pollution, environmental safety of urban areas



Манжилевская
Светлана Евгеньевна



Маилян
Дмитрий Рафаэлович

ФОРМУЛИРОВКА ПРОБЛЕМЫ

Строительная отрасль вносит существенный вклад в загрязнение воздуха городов пылевыми частицами, что подтверждается данными наблюдений [1-4]. Это вызывает особую тревогу на фоне активной урбанизации России: согласно прогнозам, к 2050 году подавляющее большинство россиян, около 84 %, будет сконцентрировано в городских агломерациях [5]. Такая концентрация населения в городах усугубляет экологические проблемы, особенно в связи с интенсификацией строительства. Сложившаяся ситуация требует срочной разработки комплекса мер по минимизации выбросов строительной пыли в городскую атмосферу. В современных реалиях растущие масштабы строительной отрасли приводят к увеличению загрязнения воздуха пылью, что требует более совершенных способов мониторинга. Хотя регрессионный анализ остается традиционным методом оценки пылевого загрязнения атмосферы, его возможностей становится недостаточно [6-8]. Цифровая трансформация открывает новые перспективы для повышения точности прогнозов концентрации пыли в воздухе [9, 10]. Искусственный интеллект, включая технологии машинного обучения, нейросетевые алгоритмы и библиотеку Prophet, может стать эффективным инструментом для решения этой задачи. Также перспективным направлением является применение метода опорных векторов, который позволит систематизировать процесс анализа данных о пылевом загрязнении [11].

АНАЛИЗ ПОСЛЕДНИХ ИССЛЕДОВАНИЙ И ПУБЛИКАЦИЙ

В ходе изучения прогностических возможностей различных моделей К. Ю. Богачев выявил превосходство нелинейных систем, в частности нейросетей, над линейными аналогами [12]. Несмотря на определенные ограничения, нейронные сети демонстрируют впечатляющие результаты в области переобучения и поиска локальных минимумов [13].

Современное строительство активно интегрирует передовые технологии, что создает потребность в оценке эффективности цифровых инструментов для мониторинга загрязнений атмосферы. Особый интерес представляет прогнозирование концентрации

мелкодисперсной пыли, которая признана одним из наиболее серьезных факторов риска для человеческого здоровья в настоящее время [14-17]. Исследования, проведенные за рубежом, показывают особую эффективность ансамблевых моделей (ensemble models) в сфере машинного обучения [18, 19]. Эти комплексные системы объединяют различные самостоятельные прогностические алгоритмы, обеспечивая максимальную точность прогноза [20].

Изучение динамики снижения загрязнителей в городской воздушной среде возможно через применение моделирования. Такой подход позволяет выявлять территории или временные интервалы строительных работ с различными уровнями концентрации вредных веществ. При анализе работ на строительных объектах модели помогают идентифицировать ключевые факторы, влияющие на содержание мелкодисперсных частиц PM2.5 – от метеорологических условий (скорость и направление воздушных потоков, уровень влажности в воздухе, температурный режим) до других существенных параметров.

Актуальность данного исследования состоит в том, что доказательство возможности применения алгоритмов машинного обучения в прогнозировании PM2.5 при реализации строительных работ даст участникам инвестиционно-строительных объектов точечной застройки актуальные данные концентрации PM2.5 на строительной площадке в период производства работ на строительной площадке с учетом метеорологических факторов для контроля уровней ПДК (предельно допустимых концентраций) PM2.5, что минимизирует пылевое загрязнение и его негативное влияние на жителей прилегающих территорий.

Цель данного исследования – оценка возможности результирующего использования как одиночных алгоритмов искусственного интеллекта, так и их ансамблевых комбинаций для прогнозирования уровня мелкодисперсных частиц PM2.5 в воздухе на участках строительства.

ОСНОВНОЙ МАТЕРИАЛ ИССЛЕДОВАНИЯ

Для прогнозирования уровня загрязнения PM2.5 в зоне строительных работ были выбраны различные алгоритмы. В качестве основных инструментов анализа использовались как классические статистические методы, так и современные алгоритмы машинного обучения. Среди них: метод случайного леса (Random forest – RF), технология нейросетевого моделирования (Neural network – NN), библиотека Prophet, а также традиционные подходы – алгоритм экспоненциального сглаживания (Exponential moving average – EMA) и ARIMA-модель (autoregressive integrated moving average), основанная на авторегрессии и скользящем среднем значении, также открытая библиотека XGBoost и алгоритм SVM (Support Vector Machine). Применение этих алгоритмов позволит решить поставленную задачу по оценке концентрации пылевых частиц на объекте строительства. Разработанные модели прогнозирования мелкодисперсной пыли PM2.5 представлены на рисунке 1. Точность

1. ARIMA. Авторегрессионная интегрированная модель скользящего среднего (autoregressive integrated moving average)

$$y_t^* = c + y_{t-1} \mathcal{O}_1 + \dots + \mathcal{O}_p y_{t-p} + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t$$

где y_t^* – разностные данные временных рядов для концентрации PM2.5, c – константа, ε – значение ошибки, d – порядок разностных данных временных рядов.

Предикторы правой части модели включают запаздывающие значения концентрации PM2.5 и ошибки. Элементы p , d и q модели ARIMA определяются автоматически с использованием варианта алгоритма Хайдмана-Хандакара.



1. Не способна фиксировать нелинейные взаимосвязи между переменными, которые включены в процесс обучения.
2. Требует поочередно включать переменные в моделирование и по средствам сравнения полученных данных с реальными значениями концентрации определять

2. EMA. Модель экспоненциального сглаживания (exponential moving average)

$$y_{t+1} = F_t + \alpha(y_t - F_t)$$

где y_{t+1} – прогноз концентрации PM2.5 на следующий период времени,

F_t – прогноз концентрации частиц PM2.5 на момент времени (t),

y_t – фактическое значение концентрации PM2.5 на момент времени (t),

α – вес, называемый константой экспоненциального сглаживания ($0 \leq \alpha \leq 1$).

Данная модель присваивает меньше веса более ранним по времени наблюдениям (y_{t-6}), чем приближенным к моменту расчета (y_{t-1}).



1. Применяется для прогнозирования в нескольких областях.
2. Взвешивает одинаково средние значения ряда подмножеств.
3. Учитывает фактор времени, сглаживая значения и уменьшая их вес с течением времени.

3. Модель Prophet. Алгоритм можно использовать для прогнозирования пылевыделения PM2.5 от строительных работ в теплое время и холодное время года.

$$y_t = g(t) + s(t) + h(t) + \varepsilon_t$$



1. Можно включать переменную, которая характеризует показатели «сезонности» концентрации.

где $g(t)$ – кусочно-линейная функция, определяющая динамику,

$s(t)$ – различные сезонные закономерности,

$h(t)$ – эффект «праздничного дня»;

ε_t – ошибки типа белый шум, не учтена моделью.

4. Модель нейросети. Моделируют информацию, имитируя человеческое мышление и отражают нелинейные взаимосвязи.

NARX (Nonlinear autoregressive exogenous model) модель нелинейной авторегрессии с внешними входами.

$$y_t = F(y_{t-1}, y_{t-2}, y_{t-3}, \dots, u_t, u_{t-1}, u_{t-2}, u_{t-3}, \dots) + \varepsilon_t$$

y – представляющая интерес переменная (температура воздуха, показатель влажности, концентрация PM2.5)

u – переменная, определяемая извне (день исследования).

ε – ошибки типа белый шум, не учтена моделью.

NNAR (Nonlinear network autoregressive model) модель нейронной сети, основанная на нескольких переменных.

$$y_t = (y_{t-1}, y_{t-2}, y_{t-pm}, \dots, y_{t-pm}, y_{t-m}, y_{t-pm} \dots) + \varepsilon_t$$

y – представляющая интерес переменная (температура воздуха, показатель влажности, концентрация PM2.5)

m – уровень концентрации разное время дня,

p – запаздывающие входные данные (фоновая концентрация).

ε – ошибки типа белый шум, не учтена моделью.

5. Алгоритм Random forest. Генерация большого количества деревьев решений.

$$P = \frac{1}{N} \sum_{n=1}^N N$$



Загрузка всех данных, включая переменные (температура влажность концентрация, генерирует уникальные деревья решений. Результаты прогнозирования по средствам данной модели определяются средними значениями выходных данных каждого дерева.

где P – прогноз алгоритма случайного леса,

N – количество прогонов по деревьям в случайном лесу (случайным выборкам) переменных температуры, влажности, концентрации.

6. Модель SVM. Метод опорных векторов (support-vector machine)

Основной целью алгоритма SVM является определение оптимальной гиперплоскости, которая линейно разделяет собранные данные на две группы.

$$w^T x + b = 0$$

где w – весовой вектор,

x – входной вектор (температура, показатель влажности, концентрация),

b – смещение.

7. Алгоритм XGBoost. Алгоритм решений с градиентным усилением, т.е. посредством расчета одной модели, алгоритм убирает ошибки при создании следующих моделей, что повышает точность прогнозов.

$$\hat{y} = \sum_{n=1}^N f_n(x_i)$$

где x_i – тестовая выборка,
 i – количество выборок,
 f_n – n -я древовидная модель,
 n – количество всех деревьев в модели.

Rис. 1. Разработанные модели для прогнозирования пылевого загрязнения воздушной среды на строительной площадке частицами PM2.5.

Таблица 1.

Экспериментальные данные значений концентрации PM2.5 на строительной площадке для моделирования

Концентрация пылевого загрязнения PM2.5, мкг/м ³			Относительная влажность воздуха, %			Температура, °C		
Диапазон	Средн. значен.	Отклон.	Диапазон	Средн. значен.	Отклон.	Диапазон	Средн. значен.	Отклон.
10.7-185.5	88.1	11.9	40-60	45	14	25-33	28	4

прогнозирования загрязнения воздуха критически важна, поскольку эти данные будут использоваться для оптимизации строительного процесса. На основе реалистичных прогнозов можно будет своевременно корректировать график работ с учетом метеорологических условий и внедрять защитные меры от пылевого воздействия. Это позволит минимизировать негативное влияние пылевого загрязнения как на рабочих, так и на жителей прилегающих территорий. Ансамблевое моделирование поможет получить более надежные прогнозы концентрации PM2.5, что необходимо для эффективного управления экологическими рисками на строительной площадке многоквартирного жилого дома. При помощи моделирования можно выявить ключевые факторы окружающей среды – скорость и направление воздушных потоков, показатели влажности и температуры, которые влияют на распространение частиц PM2.5 в процессе строительных работ. Математические модели позволяют отследить изменение уровня вредных веществ во времени и пространстве, выделяя участки городской территории и временные промежутки с критическими показателями загрязнения воздуха при проведении строительных мероприятий.

В ходе строительства многоквартирного жилого дома на ул. Магнитогорская 2А в Ростове-на-Дону, характерного для точечной застройки, были проведены измерения концентрации мелкодисперсных частиц PM2.5 в процессе проведения работ нулевого цикла. Замеры осуществлялись в первую неделю июня 2021 года с использованием специального оборудования – счетчика Handheld 3016 IAQ на границе строительной площадки и жилой зоны, где развернуто строительное производство. В процессе измерений на строительной площадке проводились работы по разработке котлована для фундамента здания, как наиболее пылящие согласно графику удельных

выбросов строительно-монтажных работ, разработанному для данного проекта. Следует отметить, что основной пик пыления процесса пришелся на 3-4 июня, когда снимался верхний сухой слой грунта. По мере заглубления нижние слои грунта были увлажнены, что снизило концентрацию PM2.5 в воздушной среде. В рамках исследования были проведены измерения температуры и относительной влажности – ключевых метеорологических параметров, необходимых для повышения точности прогнозирования. Собранные данные легли в основу для прогноза как для одномерных, так и многомерных прогностических моделей концентрации PM2.5. Дополнительные замеры концентрации PM2.5 были выполнены в течение двух дней (8-9 июня) с целью верификации точности прогнозов, полученных с помощью применяемых ансамблевых моделей. В таблице 1 отражены результаты замеров уровня PM2.5, проведенных в зоне строительства, которые впоследствии были применены как входные параметры при обучении моделей машинного обучения.

Для анализа данных был выбран язык программирования для статистической обработки данных «R» в сочетании с пакетом прогнозирования Modeltime, обеспечивающий комплексную среду моделирования. Временные ряды, отображенные на рисунке 2, демонстрируют динамику концентрации PM2.5. Интеграция метеорологических показателей (температура, относительная влажность) с измерениями мелкодисперсной пыли PM2.5 была осуществлена посредством пакета Modeltime, который преобразовал разрозненные данные в единый почасовой массив. Этот программный комплекс позволил не только объединить различные параметры, но и создать эффективную основу для последующего статистического анализа и построения моделей.

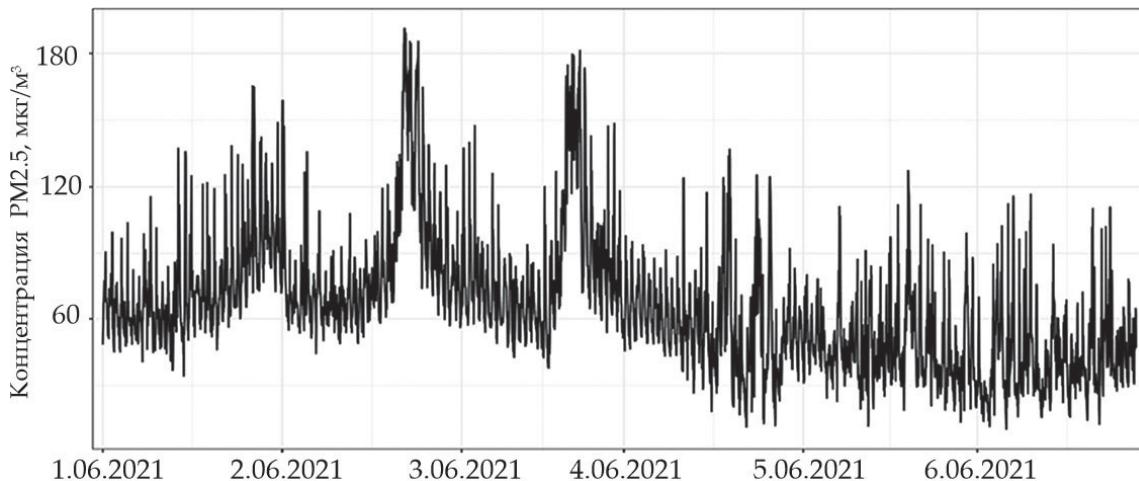


Рис. 2.
Концентрация PM2.5 в период выполнения работ нулевого цикла на строительной площадке точечной застройки

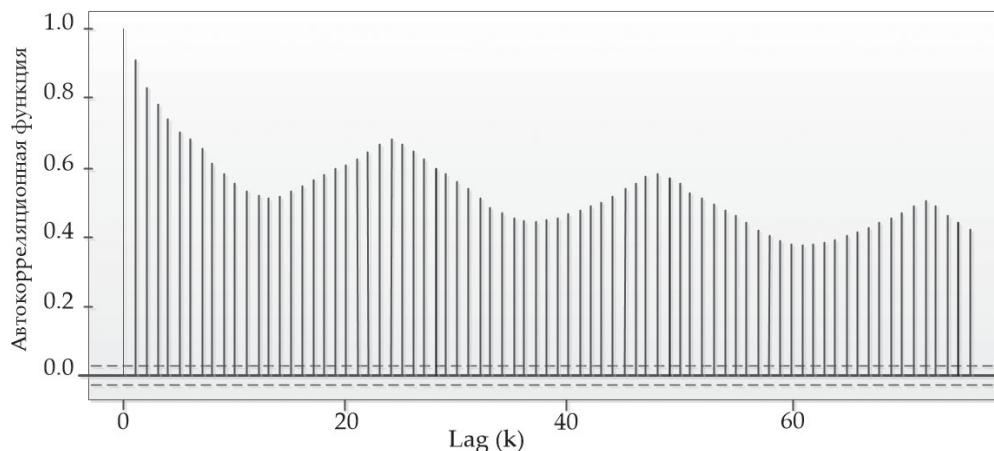


Рис. 3. Автокорреляция концентрации PM2.5.

Для объективной оценки точности прогнозирования были установлены три ключевых метрики: RMSE (среднеквадратичная ошибка), MAE (средняя абсолютная ошибка) и MASE (средняя абсолютная масштабированная ошибка). Процесс валидации включал тестирование моделей на данных за предшествующие сутки (24 часа) после завершения их обучения на тренировочном датасете. Такой подход позволил установить чёткие критерии эффективности и провести всестороннюю проверку прогностических возможностей разработанных моделей.

Используя программный комплекс «Modeltime», были изучены взаимозависимости между метеопараметрами и содержанием мелкодисперсных частиц PM2.5 в атмосфере. Анализ, основанный на методе корреляции Пирсона, рисунок 3, выявил интересные закономерности. Все изученные параметры продемонстрировали отрицательную корреляцию между собой, причем наиболее выраженная обратная связь (-0,929) наблюдалась между температурными показателями и относительной влажностью воздуха. При этом концентрация PM2.5 показала лишь незначительную обратную зависимость от климатических факторов: коэффициент корреляции с влажностью составил (-0,107), а с температурой (-0,048).

В ходе анализа временных рядов выявлена цикличность с интервалом в сутки, что указывает на наличие периодических паттернов в измерениях. На основе результатов корреляционного анализа были подобраны унивариантные модели (учитывается только один фактор влияния) как базис для последующего построения комплексных многофакторных систем.

Для прогнозирования концентрации PM2.5 в зоне строительства сначала применялись четыре одномерные модели: экспоненциальное сглаживание (EMA), нейронная авторегрессия (NNAR), Prophet и ARIMA. Каждая модель генерировала прогноз на сутки вперед. Далее были применены многомерные модели, включая Prophet, XGBoost, SVM, RF и NN для анализа взаимосвязей между зависимыми и независимыми параметрами при прогнозировании концентрации PM2.5. Основными переменными в процессе моделирования послужили данные реальных измерений, показатели влажности и температуры воздуха. Эффективность прогнозирования всех моделей отражена

в таблицах 2 и 3, а визуальное сопоставление прогнозируемых и реальных измерений загрязнения представлено на рисунке 4.

Таблица 2.

Оценка точности прогнозирования одномерных моделей

№ п/п	Наименование модели	MAE	MASE	RMSE
1	ARIMA	1.81	0.84	2.3520
2	Prophet	1.92	0.92	2.4896
3	EMA	2.10	0.94	2.4840
4	NNAR	2.30	1.05	2.7130

Сравнительная оценка точности одномерных моделей в прогнозировании пылевого загрязнения показал, что модель ARIMA демонстрирует наилучшие показатели точности среди всех исследованных моделей.

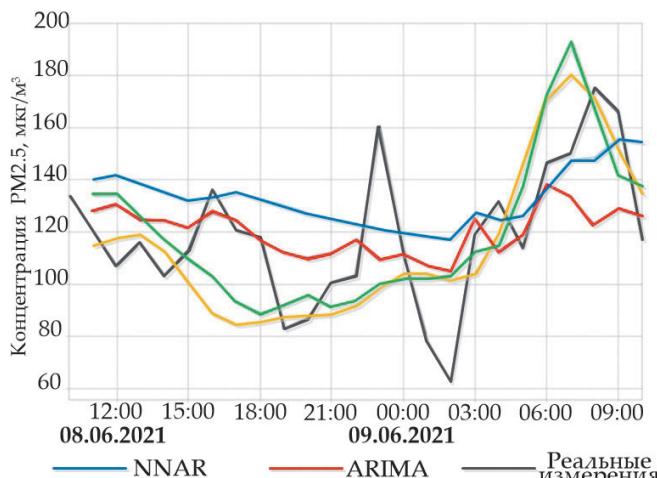
Таблица 3.

Оценка точности прогнозирования многомерных моделей

№ п/п	Наименование модели	MAE	MASE	RMSE
1	XGBoost	1.71	0.76	2.3810
2	RF	1.82	0.83	2.3732
3	Prophet	1.83	0.84	2.3583
4	SVM	1.84	0.84	2.4230
5	NN	2.05	0.93	2.4827
6	NARX	2.05	0.93	2.5925

Сравнительная оценка точности многомерных моделей в прогнозировании пылевого загрязнения показала, что алгоритмы XGBoost и Random Forest, учитывающие ряд параметров, продемонстрировали существенно большую точность по сравнению с моделью ARIMA.

Финальная стадия исследования включала создание ансамблевой модели на основе трех наиболее результативных алгоритмов. Для повышения точности прогнозирования был применен принцип взвешенного ансамбля, где каждому алгоритму присваивался определенный коэффициент значимости. Наибольший вес получил XGBoost (3), за ним следовал Random Forest (2), а замыкала тройку ARIMA с весом (1). Ансамблевая модель позволяет



(а)

Рис. 4. Прогноз концентрации мелкодисперсных частиц PM2.5 в воздушной среде строительной площадки:
(а) одномерные модели; (б) многомерные модели

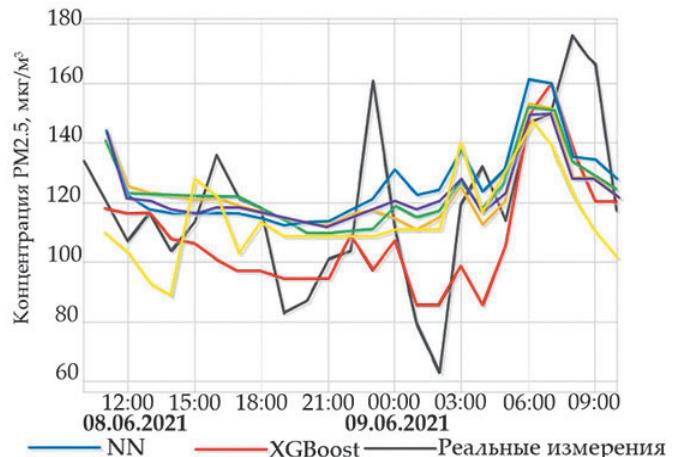
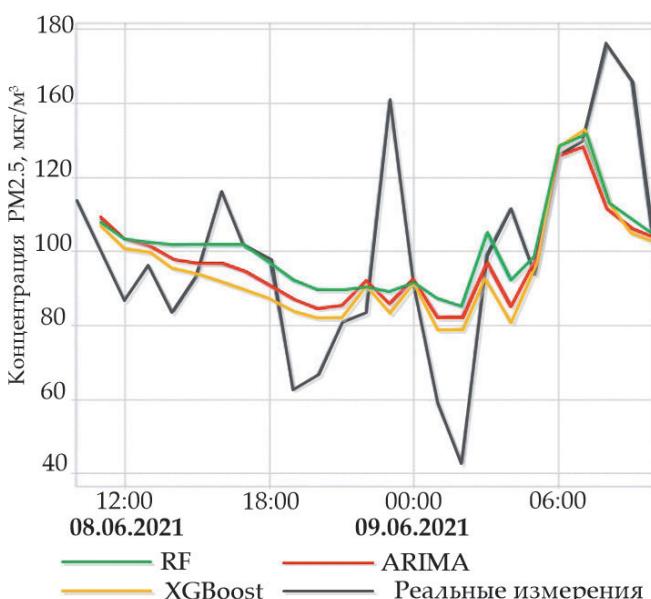
объединить сильные стороны разных алгоритмов машинного обучения, обеспечивая более надежный прогноз.

Представленные результаты прогнозирования с использованием ансамблевой модели можно увидеть в графической форме на рисунке 5, а численные показатели оценки точности приведены в таблице 4.

Таблица 4.

Оценка точности прогнозирования ансамблевой модели

№ п/п	Наименование модели	MAE	MASE	RMSE
1	XGBoost (3)	1.56	0.72	2.1880
2	RF (2)	1.61	0.74	2.1986
3	ARIMA (1)	1.62	0.74	2.1832



(б)

Анализ точности прогнозирования показал, что среди всех протестированных алгоритмов XGBoost продемонстрировал самые высокие показатели эффективности.

Ансамблевые модели демонстрируют в целом высокую точность при прогнозировании концентрации PM2.5 в зоне точечной застройки. Понимание факторов влияния на концентрацию PM2.5 становится возможным благодаря внедрению в процесс моделирования реальных данных метеорологических условий. Результаты данной работы убедительно свидетельствуют о преимуществах комбинированных методов моделирования при прогнозировании атмосферных загрязнений.

Стой от отметить, что исходя из специфики структуры рассматриваемых алгоритмов в составе моделей, предназначенных для прогнозирования концентрации PM2.5, применение каждого из них можно рассматривать, исходя из конкретных условий.

Для определения точности прогноза модели ARIMA необходимо последовательно добавлять переменные в процесс моделирования и сопоставлять результаты с фактическими показателями концентрации. Это дает возможность получать данные прогноза на основе конкретного условия, например скорости ветра, если в условиях производства работ невозможно получить реальные метеорологические данные. Модель EMA выступает инструментом гностического анализа усредненных значений и динамики их изменений. Эта модель придает разный вес данным: недавние показатели обладают большей значимостью, а влияние старых постепенно ослабевает. Благодаря такому временному сглаживанию алгоритм не просто усредняет группы значений, а создает динамическую модель, учитывающую фактор времени, т. е. прогноз может быть долгосрочный. Алгоритм Prophet позволяет учитывать сезонные колебания концентрации при моделировании. Прогнозирование выброса пыли во время строительных

Рис. 5. Прогноз концентрации мелкодисперсных частиц PM2.5 в воздушной среде строительной площадки на основании ансамблевой модели

работ для различных климатических периодов – холодных и теплых сезонов. Нейросети, подражая когнитивным процессам человека, обрабатывают данные и выявляют сложные взаимозависимости, которые не подчиняются линейной логике, предлагая несколько вариантов прогноза, с учетом возможных сезонных изменений. Модель XGBoost представляет собой технологию градиентного анализа деревьев решений алгоритма. В процессе работы этот алгоритм последовательно создает новые модели, учитывая и корректируя недостатки предыдущих. Такой подход минимизирует количество ошибок в каждом последующем результате прогноза.

Ключевое ограничение данного исследования заключается в использовании исключительно метеорологических параметров при построении модели. Однако, несмотря на это, созданные модели продемонстрировали приемлемую точность, что свидетельствует об их надежности. В процессе строительства подрядчики могут применять эти модели для прогнозирования концентрации PM2.5. Кроме того, они представляют ценность при разработке проектных решений на основе данных по концентрации от объектов-аналогов.

ВЫВОДЫ

Разработанные одномерные и многомерные модели демонстрируют достаточную надежность и приемлемую точность несмотря на то, что они основаны исключительно на метеорологических параметрах, что является главным лимитирующим фактором данного исследования. Практическое применение этих моделей открывает широкие возможности: строительные компании могут прогнозировать концентрации PM2.5 во время выполнения работ, а проектировщики – использовать данные по объектам-аналогам при разработке новых проектных решений. Таким образом, даже при наличии ограничений в исходных данных, модели доказали свою эффективность и практическую ценность для строительной отрасли. Результаты показали, что ансамблевая модель обеспечивает наиболее достоверные результаты при прогнозировании концентрации частиц PM2.5. Эффективность данной модели в прогнозировании пылевого загрязнения атмосферы была убедительно продемонстрирована. Такие прогностические инструменты позволяют глубже понять механизмы, определяющие содержание мелкодисперсных частиц в воздухе строительных объектов.

СПИСОК ЛИТЕРАТУРЫ

1. Kaja N., Stuti G. Impact of construction activities on environment // International Journal of Engineering Technologies and Management Research. 2023. Vol. 10, issue 1. Pp. 17-24. DOI:10.29121/ijetmr.v10.i1.2023.1277.
2. Манжилевская, С. Е. Влияние мелкодисперсной пыли на окружающую среду при локальном строительстве // Строительство и реконструкция. 2020. N 6. C. 86-99. URL: <https://oreluniver.ru/public/file/archive/> sir_2073-7416-2020-92-6-86-98.pdf (дата обращения: 28.04.2025). ISSN 2073-7416. DOI: 10.33979/2073-7416-2020-92-6-86-98.
3. Петренко, Л. К., Манжилевская, С. Е., Тутаев, А. А., Тимошенко, Е. В. Организация мероприятий по охране атмосферного воздуха на строительных площадках от воздействия мелкодисперсной пыли // Инженерный вестник Дона. 2019. N 1. C. 167. URL: http://www.ivdon.ru/uploads/article/pdf/IVD_135_Petrenko_uspr.pdf_1ef3342139.pdf (дата обращения: 28.04.2025). ISSN 2073-8633.
4. Манжилевская, С. Е. Экологический мониторинг экологической безопасности в зонах строительства, реконструкции и функционирования объектов // Строительные материалы и изделия. 2019. N. 2. C. 78-84. URL: <https://bstu-journals.ru/wp-content/uploads/2019/07/manzhilevskaja.pdf> (дата обращения: 28.04.2025). E-ISSN 2618-7183. DOI: 10.34031/2618-7183-2019-2-3-78-84.
5. Menzelintseva, N. V., Karapizova, N. Y., Mikhailovskaya, Y. S., Redhwan, A. M. Efficiency of standards compliance for PM(10) and PM(2,5). International Review of Civil Engineering. 2016. Vol. 7, issue 6. Pp. 1-8. DOI:10.15866/irece.v7i6.9750.
6. Азаров, В. Н., Кузьмичев, А. А., Николенко, Д. А., Васильев, А. Н., Козловцева, Е. Ю. Исследование дисперсного состава пыли городской среды // Вестник МГСУ. 2020. N 15. C. 432–442. URL: https://www.elibrary.ru/download/elibrary_42665447_43310220.pdf (дата обращения: 28.04.2025). ISSN 1997-0935. DOI: 10.22227/1997-0935.2020.3.432-442.
7. Сумеркин, Ю. А., Теличенко, В. И., Оценка экологической безопасности при домовых территорий жилых районов // Промышленное и гражданское строительство. 2017. N 6. C. 75-79. URL: <http://www.pgs1923.ru/ru/index.php/04/04/02/index.php?m=4&y=2017&v=06&p=13> (дата обращения: 28.04.2025). ISSN 0869-7019.
8. Rossello Josep L., Font-Rosselló J., Frasser C.F., Moran A., Canals V., Roca M. Stochastic Computing Applications to Artificial Neural Networks. Design and Applications of Emerging Computer Systems. 2023. Vol. 1, issue 1. Pp. 303-330. DOI:10.1007/978-3-031-42478-6_12.
9. Ахмедова, О. О., Лясин, Р. А., Азаров, В. Н. Анализ систем мониторинга качества воздуха, созданных на базе недорогих сенсорных датчиков // Строитель Донбасса. 2024. N 4. C. 80-87. URL: https://donna.su/publish_house/journals/sd/2024-4/11_akhmedova_lyasin_azarov.pdf (дата обращения: 28.04.2025). ISSN: 2617-1848. DOI:10.71536/sd.2024.4c29.11.
10. Hasan M., Abedin M., Hájek P., Coussement K., Sultan N., Lucey B. A blending ensemble learning model for crude oil price forecasting. Annals of Operations Research. 2024. Vol. 1, issue 1. Pp. 1. DOI:10.1007/s10479-023-05810-8.
11. Tao G. Reducing Construction Dust Pollution by Planning Construction Site Layout. Buildings. 2022. Vol. 12. Pp. 531. DOI:10.3390/buildings12050531.
12. Bogachev K., Mikhaleva M., Gorelov I. Algebraic multilevel method AMG: Comparison with the method BICGSTAB + ILU and its use in the method CPR. Moscow University Mathematics Bulletin. 2010. Vol. 65. Pp. 156-160. DOI:10.3103/S0027132210040042.

13. Zhou G., Liu Z., Shao W., Sun B., Li L., Liu J., Li G. *Study on the Effects of Dust Particle Size and Respiratory Intensity on the Pattern of Respiratory Particle Deposition in Humans.* Indoor Air. 2024. Vol. 1. DOI:10.1155/2024/5025616.
14. Azarov V.N., Trokhimchuk M.K., Sidelnikova O.E., *Research of dust content in the earthworks working area.* Procedia Engineering. 2016. Vol. 150. Pp. 2008-2012. DOI: 10.1016/j.proeng.2016.07.282.
15. Meskhi B. Ch., Evtushenko A. I., Azarov V. N., Zhukova N. *Comprehensive assessment of the dust environment at the construction industry enterprises.* E3S Web of Conferences: IV International Scientific Conference “Construction and Architecture: Theory and Practice of Innovative Development”. 2021. Vol. 281. Pp. 09024. DOI 10.1051/e3s-conf/202128109024.
16. Стреляева, А. Б., Калюжина, Е. А. Экологическая безопасность при проведении земляных и строительно-отделочных работ // Вестник Волгоградского государственного архитектурно-строительного университета. Серия: Строительство и архитектура. 2017. N 50. C. 321-329. URL: https://www.elibrary.ru/download/elibrary_32321732_47879159.pdf (дата обращения: 28.04.2025). ISSN 1815-4360.
17. Kuzmichev A. A., Azarov V. N., Kuzmichev A. V. *The study of the particulate matter's adhesion regularities on the vertical buildings' and structures' surfaces.* IOP Conference Series: Materials Science and Engineering: Construction and Architecture: Theory and Practice of Innovative Development. 2020. Vol. 913. 032043. DOI 10.1088/1757-899X/913/3/032043.
18. Ridwan M., Sadik K., Afendi F. *Comparison of ARIMA and GRU Models for High-Frequency Time Series Forecasting.* Scientific Journal of Informatics. 2024. Vol. 10. Pp. 389-400. DOI:10.15294/sji.v10i3.45965.
19. Peruvazhuthi K., Kumar D., Chithra N. *Performance evaluation of univariate time-series techniques for forecasting monthly rainfall data.* Journal of Water and Climate Change. 2022. Vol. 13. DOI:10.2166/wcc.2022.107.
20. Afarini N., Hindarto D. *Forecasting Airline Passenger Growth: Comparative Study LSTM VS Prophet VS Neural Prophet.* Sinkron. 2024. Vol. 9. Pp. 505-513. DOI: 10.33395/sinkron.v9i1.13237.

ИНФОРМАЦИЯ ОБ АВТОРЕ

Манжилевская Светлана Евгеньевна – кандидат технических наук, доцент кафедры организации строительства Донского государственного технического университета, Ростов-на-Дону, Россия. Научные интересы: совершенствование системы защиты атмосферного воздуха при точечном строительстве в городской среде от пылевого загрязнения.

Майлян Дмитрий Рафаэлович – доктор технических наук, заведующий кафедрой железобетонных и каменных конструкций Донского государственного технического университета, Ростов-на-Дону, Россия. Член-корреспондент Российской Академии естественных наук, «Почетный строитель РФ» и «Почетный работник высшего профессионального образования РФ». Научные интересы: развитие общей методики повышения экологической безопасности в строительной деятельности.

INFORMATION ABOUT THE AUTHOR

Manzhilevskaya Svetlana E. – PhD. Sc. (Eng.), Associate professor of Construction Management Department, Don State Technical University, Rostov-on-Don, Russia. Scientific interests: improvement of the atmospheric air protection system for point-pattern construction in the urban environment from dust pollution.

Mailyan Dmitrii R. – D. Sc. (Eng.), Head of the Concrete Constructions and Structures Department, Don State Technical University, Rostov-on-Don, Russia. Corresponding member of Academy of building sciences of Russia, Honorary Builder of the Russian Federation and Honorary Worker of Higher Professional Education of the Russian Federation. Scientific interests: development of a general methodology for improving environmental safety in construction activities.

REFERENCES

1. Kaja N., Stuti G. (2023), “Impact of construction activities on environment”, International Journal of Engineering Technologies and Management Research, vol. 10, issue 1, pp. 17-24, DOI:10.29121/ijetmr.v10.i1.2023.1277.
2. Manzhikevskaya S.E. (2020), *Vliyanie melkodispersnoj pyli na okruzhayushchuyu sredu pri lokal'nom stroitel'stve* [Impact of fine dust on the environment in local construction], Stroitel'stvo i rekonstrukciya, vol. 6, pp. 86-99, available at: https://oreluniver.ru/public/file/archive/sir_2073-7416-2020-92-6-86-98.pdf (Accessed 28 April 2025), ISSN 2073-7416, DOI: 10.33979/2073-7416-2020-92-6-86-98.
3. Petrenko L.K., Manzhilevskaya S.E., Tutaev A. A., Timoshenko E. V. (2019), *Organizaciya meropriyatij po ohrane atmosfernogo vozduha na stroitel'nyh ploshchadkah ot vozdejstviya melkodispersnoj pyli* [Organization of measures for the protection of atmospheric air at construction sites from the impact of fine dust], Inženernyj vestnik Dona, vol. 1, p. 167. available at: http://www.ivdon.ru/uploads/article/pdf/IVD_135_Petrenko_ucnp.pdf_1ef3342139.pdf (Accessed 28 April 2025), ISSN 2073-8633.
4. Manzhikevskaya S.E. (2019), *Ekologicheskiy monitoring ekologicheskoy bezopasnosti v zonah stroitel'stva, rekonstrukcii i funkcionirovaniyu ob"ektorov* [Environmental monitoring of ecological safety in areas of construction, reconstruction and operation of objects], Stroitel'nye materialy i izdeliya, vol. 2, pp. 78-84, available at: <https://bstu-journals.ru/wp-content/uploads/2019/07/manzhilevskaja.pdf> (Accessed 28 April 2025), E-ISSN 2618-7183, DOI: 10.34031/2618-7183-2019-2-3-78-84.
5. Menzelintseva N.V., Karapuzova N.Y., Mikhailovskaya Y.S., Redhwan A.M. (2016), “Efficiency of standards compliance for PM(10) and PM(2,5)”, International Review of Civil Engineering, vol. 7, issue 6, pp. 1-8, DOI:10.15866/irece.v7i6.9750.
6. Azarov Valeriy, Kuzmichev Andrey, Nikolenko Denis, Vasilev Anatoliy, Kozlovseva Elena. (2020), *Issledovanie dispersnogo sostava pyli gorodskoj sredy* [The research of dust dispersed composition of urban environment], Vestnik MGSU,

- vol. 15, pp. 432–442, available at: https://www.elibrary.ru/download/elibrary_42665447_43310220.pdf (Accessed 28 April 2025), ISSN 1997-0935, DOI: 10.22227/1997-0935.2020.3.432-442.
7. Sumerkin Yu. A., Telichenko V. I. (2017), *Ocenka ekologicheskoy bezopasnosti pridomovyh territorij zhilyh rajonov [Assessment of ecological safety of territories adjoining residential areas]*, Promyshlennoe i grazhdanskoe stroitel'stvo, vol. 6, pp. 75–79, available at: <http://www.pgs1923.ru/ru/index.php/04/04/02/02/index.php?m=4&y=2017&v=06&p=13> (Accessed 28 April 2025), ISSN 0869-7019.
 8. Rossello Josep L., Font-Rosselló J., Frasser C.F., Moran A., Canals V., Roca M. (2023), “*Stochastic Computing Applications to Artificial Neural Networks*”, *Design and Applications of Emerging Computer Systems*, vol. 1, issue 1, pp. 303-330, DOI:10.1007/978-3-031-42478-6_12.
 9. Akhmedova O.O., Lyasin R. A., Azarov V. N. (2024), *Analiz sistem monitoringa kachestva vozduha, sozdannyh na baze nedorogih sensornyh datchikov [Analysis of air quality monitoring systems based on low-cost sensors]*, *The Builder of Donbass*, vol. 4, pp. 80-87, available at: https://donna.sru/publish_house/journals/sd/2024-4/11_akhmedova_lyasin_azarov.pdf (Accessed 28 April 2025). ISSN: 2617-1848. DOI:10.71536/sd.2024.4c29.11.
 10. Hasan M., Abedin M., Hájek P., Coussement K., Sultan N., Lucey B. (2024), “*A blending ensemble learning model for crude oil price forecasting*”, *Annals of Operations Research*, vol. 1, issue 1. p. 1, DOI:10.1007/s10479-023-05810-8.
 11. Tao G. (2022), “*Reducing Construction Dust Pollution by Planning Construction Site Layout*”, *Buildings*, vol. 12, pp. 531, DOI:10.3390/buildings12050531.
 12. Bogachev K., Mikhaleva M., Gorelov I. (2010), “*Algebraic multilevel method AMG: Comparison with the method BICGSTAB + ILU and its use in the method CPR*”, *Moscow University Mathematics Bulletin*, vol. 65, pp. 156-160, DOI:10.3103/S0027132210040042.
 13. Zhou G., Liu Z., Shao W., Sun B., Li L., Liu J., Li G. (2024), “*Study on the Effects of Dust Particle Size and Respiratory Intensity on the Pattern of Respiratory Particle Deposition in Humans*”, *Indoor Air*, vol. 1, DOI:10.1155/2024/5025616.
 14. Azarov V.N., Trokhimchyk M.K., Sidelnikova O.E. (2016), “*Research of dust content in the earthworks working area*”, *Procedia Engineering*, vol. 150, pp. 2008-2012, DOI: 10.1016/j.proeng.2016.07.282.
 15. Meskhi B. Ch., Evtushenko A. I., Azarov V. N., Zhukova N. (2021), “*Comprehensive assessment of the dust environment at the construction industry enterprises*”, *E3S Web of Conferences: IV International Scientific Conference “Construction and Architecture: Theory and Practice of Innovative Development”*, vol. 281, 09024, DOI 10.1051/e3sconf/202128109024.
 16. Strelyanova A.B., Kalyuzhina E.A. (2017), *Ekologicheskaya bezopasnost' pri provedenii zemlyanyh i. stroitel'no-otdelochnyh rabot [Environmental Safety of Earthworks and Construction and Decoration Works]*. *Vestnik Volgogradskogo gosudarstvennogo arhitekturno-stroitel'nogo universiteta. Seriya: Stroitel'stvo i arhitektura*, vol. 50, pp. 321–329, available at: https://www.elibrary.ru/download/elibrary_32321732_47879159.pdf (Accessed 28 April 2025), ISSN 1815-4360.
 17. Kuzmichev A. A., Azarov V. N., Kuzmichev A. V. (2020), “*The study of the particulate matter's adhesion regularities on the vertical buildings' and structures' surfaces*”, *IOP Conference Series: Materials Science and Engineering: Construction and Architecture: Theory and Practice of Innovative Development*, vol. 913, 032043, DOI 10.1088/1757-899X/913/3/032043.
 18. Ridwan M., Sadik K., Afendi F. (2024), “*Comparison of ARIMA and GRU Models for High-Frequency Time Series Forecasting*”, *Scientific Journal of Informatics*, vol. 10, pp. 389-400, DOI:10.15294/sji.v10i3.45965.
 19. Afarini, N. and Hindarto, D., 2024. *Forecasting Airline Passenger Growth: Comparative Study LSTM VS Prophet VS Neural Prophet*. *Sinkron*, 9, pp.505–513. DOI:10.3395/sinkron.v9i1.13237.
 20. Peruvazhuthi, K., Kumar, D. and Chithra, N., 2022. *Performance evaluation of univariate time-series techniques for forecasting monthly rainfall data*. *Journal of Water and Climate Change*, 13. DOI:10.2166/wcc.2022.107.

Статья поступила в редакцию 29.04.2025; одобрена после рецензирования 16.05.2025; принята к публикации 23.05.2025.

The article was submitted 29.04.2025; approved after reviewing 16.05.2025; accepted for publication 23.05.2025.