УДК 556.18 *https://doi.org/10.35567/1999-4508-2026-4-28-44*

Оригинальная статья/Original paper

Особенности краткосрочного прогнозирования мутности на примере рек Амур, Ангара, Уссури

О. М. Розенталь[1], Т. Н. Синцова[2]

tanya_sinzova@mail.ru

[1] *Институт водных проблем Российской академии наук, Москва, Россия*
[2] *Горный институт Уральского отделения Российской академии наук, г. Пермь, Россия*

АННОТАЦИЯ

Актуальность. В настоящее время при решении задач краткосрочного прогнозирования мутности воды широко используются методы машинного обучения и ансамблевые подходы. Надежность оценок мутности воды на основе этих методов позволяет решать такие актуальные задачи, как планирование хозяйственной деятельности, обеспечение эффективного функционирования водоканалов, оптимизация дозировки коагулянтов, снижение риска нарушения санитарных норм в системах водоснабжения. **Методы.** Для краткосрочного прогнозирования мутности использованы классические статистические методы, методы машинного обучения и ансамблевые подходы: ARIMA, SARIMA, ARFIMA, Holt – Winters, Prophet, Bagging, Boosting, Stacking. Данные наблюдений за мутностью воды взяты в пунктах районов головных водоочистных сооружений городов Хабаровска, Уссурийска и Ангарска в реках Амур, Уссури и Ангара с частотой измерения используемого прибора 1 раз в 45 минут. **Результаты.** Показано, что ансамблевые подходы Stacking и Boosting превосходят другие модели ввиду применения комплекса различных источников информации. Выявлено, что эффективность методов зависит от характеристик конкретного временного ряда мутности: при сильной сезонности для р. Амур лучше работает Holt – Winters, при умеренной и стабильной динамике для р. Ангары – ARIMA или Stacking, а при высокой изменчивости для р. Уссури – Boosting. Установлено, что для выбора модели следует учитывать точность и доступность данных, особенности гидрологического режима водного объекта и цели прогноза. В дальнейших исследованиях рекомендовано использовать гибридные модели на основе физических факторов (осадков, расхода воды) для улучшения качества прогноза.

КЛЮЧЕВЫЕ СЛОВА: краткосрочное прогнозирование, мутность воды, река Амур, река Ангара, река Уссури, ансамблевый подход, метод машинного обучения, ARIMA, Holt – Winters, Prophet, Bagging, Stacking, Boosting

ФИНАНСИРОВАНИЕ: Исследование выполнено при финансовой поддержке Министерства науки и высшего образования РФ в рамках государственного задания Горного института УрО РАН «Исследование закономерностей эволюции гидросферы в районах интенсивного недропользования с целью минимизации экологического риска и обеспечения устойчивости водопользования» (рег. номер НИОКТР: 124020500053-6), в рамках темы № FMWZ-2025-0002 государственного задания Института водных проблем Российской академии наук (номер государственной регистрации 125030703344-8).

© Розенталь О. М., Синцова Т. Н., 2026

ДЛЯ ЦИТИРОВАНИЯ: Розенталь О. М., Синцова Т. Н., Особенности краткосрочного прогнозирования мутности на примере рек Амур, Ангара, Уссури // Водное хозяйство России: проблемы, технологии, управление. 2026. № 4. С. 28–44. https://doi.org/10.35567/19994508-2026-4-28-44; EDN: OAVXUX

Features of short-term turbidity forecasting using the Amur, Angara, and Ussuri rivers as examples

Oleg M. Rozental[1], **Tatyana N. Sintsova**[2]

tanya_sinzova@mail.ru

[1] *Water Problems Institute of the Russian Academy of Sciences, Moscow, Russia*
[2] *Mining Institute of the Ural Branch of the Russian Academy of Sciences, Perm, Russia*

ABSTRACT

Relevance. Currently, machine learning methods and ensemble approaches are widely used. Reliable turbidity estimates based on these methods will help solve such pressing problems as planning economic activities, ensuring the reliable operation of water utilities, optimizing coagulant dosages, preventing system overload, and reducing the risk of violating sanitary standards within the water supply systems. **Methods.** Classic statistical methods, machine learning methods, and ensemble approaches, including ARIMA, SARIMA, ARFIMA, Holt – Winters, Prophet, Bagging, Boosting, and Stacking, were used in this study for short-term turbidity forecasting. Water turbidity observation data were collected from three observation points located near the main water treatment plants in the cities of Khabarovsk, Ussuriysk, and Angarsk in the Amur, Ussuri, and Angara rivers with a measurement frequency of once every 45 minutes. **Results.** Stacking and Boosting ensemble approaches are shown to outperform other models due to the use of a combination of different data sources. The effectiveness of the methods is revealed to depend on the characteristics of a specific turbidity time series: Holt – Winters performs better with strong seasonality for the Amur River, ARIMA or Stacking performs better with moderate and stable dynamics for the Angara River, and Boosting performs better with high variability for the Ussuri River. It is established that model selection requires consideration of data accuracy and availability, special features of the water body hydrological regime, and the forecast objectives. It appears necessary to use hybrid models based on physical factors (precipitation, water discharge) in future studies to improve forecast quality.

KEYWORDS: short-term forecasting, water turbidity, Amur, Angara, Ussuri rivers, ensemble approach, machine learning method, ARIMA, Holt – Winters, Prophet, Bagging, Stacking, Boosting

FINANCING: This research was supported by the Ministry of Science and Higher Education of the Russian Federation as part of the state assignment of the Mining Institute of the Ural Branch of the Russian Academy of Sciences “Study of the Evolutionary Patterns of the Hydrosphere in Areas of Intensive Subsoil Use to Minimize Environmental Risk and Ensure Sustainable Water Use” (Registration No. 124020500053-6), also within the framework of topic No. FMWZ-2025-0002 of the state assignment of the Water Problems Institute of the Russian Academy of Sciences (state registration number 125030703344-8).

FOR CITATION: Rozental O. M., Sintsova T. N. Features of short-term turbidity forecasting using the Amur, Angara, and Ussuri rivers as examples. *Water Sector of Russia: Problems, Technologies, Management*. 2026. No. 4. P. 28–44. https://doi.org/10.35567/19994508-2026-4-28-44; EDN: OAVXUX

ВВЕДЕНИЕ

Колебания мутности воды имеют существенную межгодовую, сезонную и внутрисуточную изменчивость, т. к. определяются сложной совокупностью гидрологических и гидродинамических процессов в водных объектах, что подтверждается исследованиями физических и химических показателей качества воды [1–3]. Долгопериодные колебания мутности в водных объектах обусловлены в первую очередь их гидрологическим режимом, поэтому довольно сложно их прогнозировать. Решить эту задачу можно с применением физико-математических моделей.

Действующая система государственного мониторинга за мутностью воды не обеспечивает в полной мере количество натурных данных ввиду ограниченного числа пунктов наблюдений, нерегулярного и редкого отбора проб. В этой ситуации сложно оценить экстремальные значения мутности воды редкой обеспеченности и выявить с заданной надежностью отличающиеся от естественного генезиса выбросы. Актуальной задачей является оценка прогностических значений мутности на основе статистических методов, методов машинного обучения и ансамблевых подходов там, где особо важны результаты выполненных исследований: в условиях хозяйственной деятельности на водосборе и в пределах водного объекта с учетом климатических изменений для эффективного функционирования водозаборов и обеспечения территорий чистой питьевой водой.

Целью представленной в статье работы стало исследование технологии получения прогноза мутности воды при наличии минимальных исходных данных на примере рек Амур, Ангара и Уссури. Мутность воды – важный показатель качества водных ресурсов, т. к. концентрация взвешенных частиц тесно связана с эрозионными процессами в бассейне, гидрологическим режимом и антропогенной нагрузкой на водный объект. Повышенная мутность ухудшает условия для рыб и других организмов и может быть индикатором загрязнения водного объекта.

В краткосрочном прогнозе определяющую роль играет стохастика рассматриваемых колебаний мутности воды, обусловленная турбулентными пульсациями и когерентными структурами, определяющимися макротурбулентными процессами внутрисуточных колебаний. Ввиду того что их короткопериодные колебания связаны с внутриводоемными процессами (разбавления и миграции) и влиянием гидродинамических параметров, необходимо исследовать механизмы формирования внутрисуточных колебаний мутности воды с уче-

том дисперсий их естественного изменения, а также природу этих колебаний – ошибки это измерений или влияние внутриводоемных процессов.

Кратковременный прогноз мутности природной воды необходим для обеспечения эффективной и стабильной работы систем водоподготовки водоканалов, минимизации рисков нарушения качества очистки и снижения эксплуатационных затрат. Такой прогноз позволяет оптимизировать дозировки коагулянтов, предотвращать перегрузку системы из-за резких скачков мутности воды (например, во время паводков, обильных осадков или техногенных сбоев), а также скорректировать режим работы оборудования, спрогнозировать потенциальные нештатные ситуации и снизить риски нарушения санитарных норм.

Для прогнозирования мутности применяются методы регрессии, нейронные сети, гауссовские процессы и другие алгоритмы машинного обучения [4–13]. В настоящее время в ряде работ рассматривается целесообразность использования краткосрочных прогнозов мутности в технологическом цикле для водоканалов [14–22]. Краткосрочные прогнозы демонстрируют большой потенциал в обработке больших массивов данных, ускорении решения задач прогнозирования и выявлении нелинейных закономерностей колебаний мутности воды. Эти подходы особенно эффективны, когда эмпирические или полевые данные ограниченны или неоднородны [19, 20]. Так, вопросы необходимости учета значительно более короткопериодных внутрисуточных колебаний физических показателей качества воды, в т. ч. мутности воды р. Уссури, на основе применения современных автоматических измерительных комплексов рассмотрены в работе [3]. В исследовании [1] выявлена значимость внутрисуточных колебаний физических показателей качества воды на водозаборе Камского водохранилища в районе г. Березники. В г. Якутске в мае 2026 г. на АО «Водоканал», согласно данным официального сайта https://vodokanal-ykt.ru, увеличили кратность отбора проб определяемых показателей, в т. ч. мутности воды: исследования воды в р. Лене проводили каждые два часа ввиду повышенных значений показателей (мутность составляла 6,52 мг/дм^3, после очистки – 0,21 мг/дм^3).

Согласно действующим нормативным документам[1], предельно допустимая концентрация мутности в питьевой воде составляет 1,5 мг/дм^3. Однако за рубежом, в соответствии с требованиями Агентства по охране окружающей среды США (US EPA)[2], 95 % питьевой воды в течение месяца должны иметь показатель мутности менее 0,5 NTU (нефелометрические единицы мутности), при этом ни один отдельно взятый образец этой воды не должен превышать 5 NTU в любой момент времени.

Актуальна необходимость краткосрочного прогноза мутности на р. Амур, что подтверждается исследованием авторов в 2024 г. [21]. Проблема связана

1 СанПиН 1.2.3685-21. Гигиенические нормативы и требования к обеспечению безопасности и (или) безвредности для человека факторов среды обитания.

2 EPA's Budget and Spending Planning Budget Results (англ.). US EPA. Агентство по охране окружающей среды США (12 января 2017 г.).

с наличием существенных изменений в больших диапазонах содержания растворенных веществ в водах Амура из-за значительных отличий химического состава вод рек Сунгари, Уссури и Бурея на всех этапах формирования паводка, а также с превышениями нормативов качества воды в районе водозабора г. Хабаровска в период паводка 2020 г. Поэтому для водоканалов очень важно краткосрочное прогнозирование мутности (на 12 ч), т. к. этот временной период связан с технологической возможностью произвести необходимые действия для предотвращения повышения мутности воды, подаваемой в системы питьевого водоснабжения.

В статье [22] рассматривается еще один аспект практической значимости краткосрочного прогнозирования мутности. Речь идет о планировании работ по расширению гавани Ле-Авра на северо-западе Франции, включающих строительство новой дамбы, чтобы обеспечить прямой доступ речных судов к контейнерным терминалам при любых погодных условиях и в полной безопасности, для чего предлагается установить две мониторинговые станции по определению мутности воды. Опорная станция будет расположена вне масштаба смоделированного шлейфа мутности, создаваемого работами, вторая – внутри смоделированного шлейфа. Мутность воды планируется измерять непрерывно: если показатели начнут расходиться на обеих станциях, это означает, что текущие работы создают значительно больше мутности, чем ожидалось, что может повлиять на близлежащие экосистемы. Однако, поскольку при определенных условиях значения измеряемой в обоих точках мутности могут естественным образом расходиться, краткосрочная система прогнозирования может помочь обнаружить наблюдаемые расхождения и способствовать принятию оптимальных управленческих решений.

Рассмотренные статьи как отечественных, так и зарубежных авторов [4–22] подтверждают практическую значимость применения методик краткосрочной системы прогнозирования мутности на основе методов ансамблевого подхода и машинного обучения для управления водными ресурсами, особенно в регионах с ограниченными сетями мониторинга. При этом точные прогнозные оценки мутности воды способствуют раннему выявлению всплеска загрязнения и позволяют обеспечить устойчивое планирование использования водных ресурсов при недостаточности данных наблюдений.

МЕТОДЫ ИССЛЕДОВАНИЯ

Исходные данные

Для обеспечения надежности водоснабжения необходима подача населению воды, потребительские свойства которой соответствуют санитарно-гигиеническим требованиям. Принципиальное значение для эффективной работы систем водоснабжения имеет мониторинг качества и количества воды,

поступающей на водопроводные очистные сооружения. Поэтому в данной работе акцентированы вопросы обеспечения достаточной частоты измерений (45 мин) за качеством воды, а именно – мутностью. Изменение колебаний мутности воды в значительной мере зависит от водности рек: например, в период больших расходов воды наблюдаются более частые, а в межень – редкие изменения.

В условиях высокой антропогенной нагрузки на реки Амур, Уссури и Ангара на рассматриваемых головных водоочистных сооружениях Хабаровска, Уссурийска и Ангарска осуществляется непрерывный высокочастотный мониторинг мутности воды с 45-минутной дискретностью на основе автоматизированного измерительного комплекса «КИМ».

Исходные данные рядов наблюдений мутности воды взяты на основе материалов, представленных НВЦ УНИТОК, за период 2021–2022 гг. с объемом выборки 100 значений для каждой из рассматриваемых рек в течение соответствующего сезона. При этом временные ряды были разделены на обучающую часть и тестовый период длиной до 16 наблюдений. Сопоставлялись также сезонные результаты для оценки краткосрочного прогнозирования мутности воды, имеющей существенную межсезонную и внутрисуточную изменчивость.

Методы прогнозирования

В рамках проведенной работы использованы как классические статистические модели, так и методы машинного обучения и ансамблевые подходы:

- **ARIMA** – авторегрессионная интегрированная скользящая средняя;
- **SARIMA** – сезонная версия ARIMA, дополнительно учитывающая сезонную периодичность (регулярные циклы в данных, например, годовые, недельные и т. п.);
- **ARFIMA** – обобщение ARIMA, допускающее дробный порядок интегрирования;
- **Holt – Winters** – метод экспоненциального сглаживания с компонентами уровня, тренда и сезонности;
- **Prophet** – реализует аддитивную модель, также способную разлагать ряд на тренд, сезонность и шум;
- **Bagging** – ансамблевый метод, в котором множество моделей обучаются на разных бутстрэп-выборках, а результаты усредняются;
- **Boosting** – метод последовательного обучения, где каждая последующая модель фокусируется на ошибках предыдущих;
- **Stacking** – ансамбль, в котором несколько базовых моделей обучаются параллельно, затем их прогнозы используются в качестве признаков для метамодели.

Лучшие результаты, полученные на основе вышеприведенных методов прогнозирования для 16 временных интервалов на примере рек Амур, Уссури и Ангара, представлены на рис. 1.

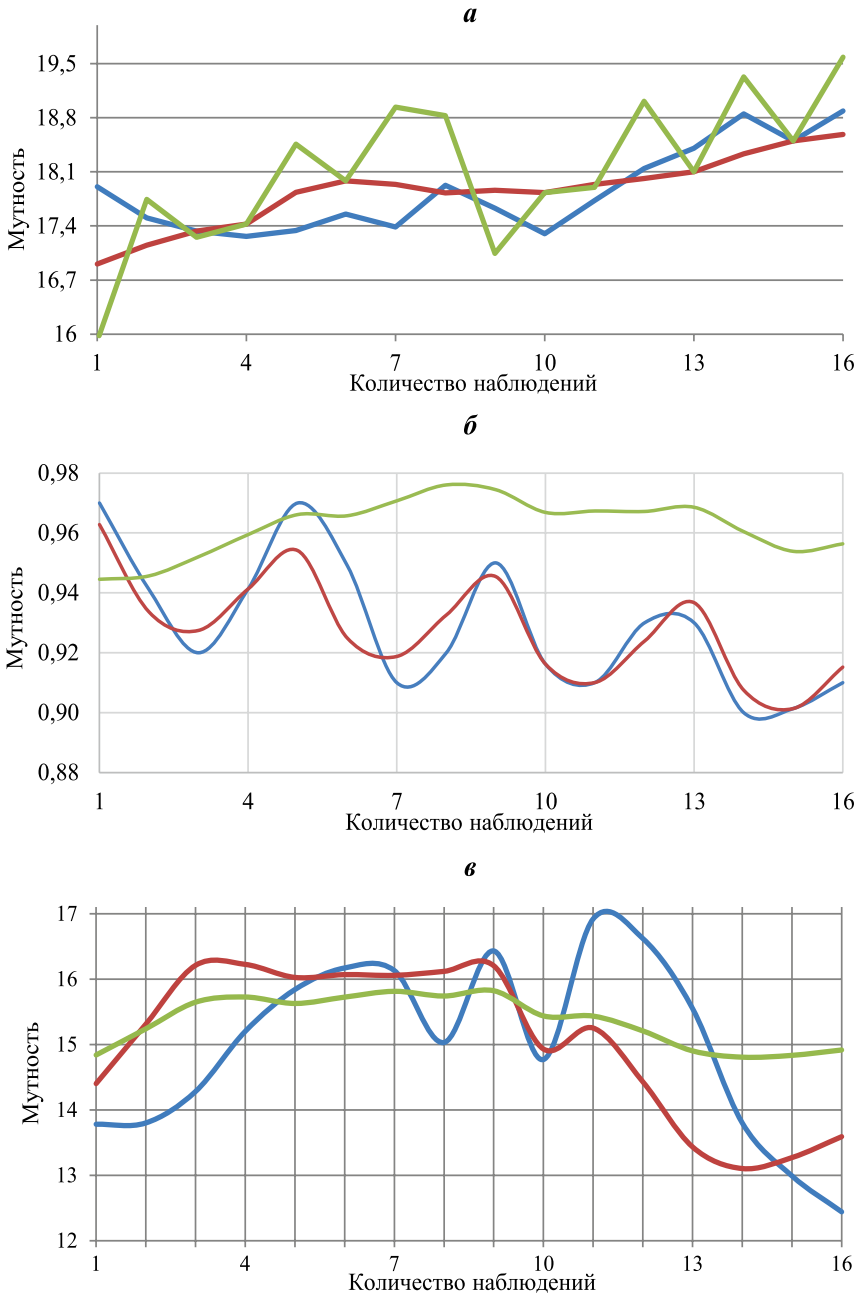


Рис. 1. Фактическая мутность воды (синяя линия), лучший прогнозный результат (красная) и следующий после лучшего (зеленая) на примере рек Амур (*а*), Ангара (*б*) и Уссури (*в*)

Fig. 1. Actual water turbidity (blue line), best forecast result (red), and next-to-best result (green) for the Amur (*a*), Angara (*b*), and Ussuri (*c*) rivers

В результате анализа лучшими прогностическими методами признаны: для Амура – Holt – Winters и Stacking, для Ангары – Stacking и ARIMA, для Уссури – Boosting и Bagging.

Для оценки качества прогнозов использовались: средняя абсолютная ошибка (MAE), среднеквадратическая ошибка (MSE) и корень из MSE (RMSE), что позволило оценивать стандартное отклонение остатка. Определялись также средний абсолютный процент ошибки (MAPE), симметричная MAPE (sMAPE) – взвешенная относительная ошибка, ограниченная от 0 до 200 %, и коэффициент детерминации (R^2) – доля дисперсии наблюдений, объясняемая моделью.

РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

Как известно, чем меньше значения MAE, MSE, MAPE, тем выше качество прогноза. Из данных табл. 1 можно сделать вывод, что в среднем по горизонтам 2, 4, 8 и 16 качество прогноза для разных рек ухудшается неодинаково. Аналогичные различия наблюдаются и в том, насколько хорошо модели улавливают характерные особенности каждой реки.

Таблица 1. Средние метрики для прогнозов мутности воды
Table 1. Average metrics for turbidity forecasts

р. Амур								
Модель	Holt – Winters	Stacking	ARIMA	Boosting	SARIMA	ARFIMA	Prophet-like	Bagging
MAE	1,225	1,520	1,694	1,694	1,773	3,984	4,428	3,983
MAPE, %	10,87	13,46	15,20	15,20	15,91	35,19	39,51	35,97
R^2	0,978	0,965	0,932	0,932	0,923	0,745	0,424	0,252
р. Ангара								
Модель	Stacking	ARFIMA	Prophet	ARIMA	Bagging	SARIMA	Boosting	Holt – Winters
MAE	0,044	0,054	0,054	0,054	0,068	0,081	0,08	0,086
MAPE, %	5,11	6,03	6,03	6,03	7,35	8,67	8,92	9,09
R^2	0,607	0,546	0,546	0,546	0,329	0,239	0,31	0,137
р. Уссури								
Модель	Boosting	Bagging	Stacking	Prophet	Holt – Winters	ARIMA	ARFIMA	SARIMA
MAE	0,534	1,017	1,445	1,577	1,641	1,75	1,75	1,75
MAPE, %	3,67	7,51	10,65	11,25	11,92	13,06	13,06	13,06
R^2	0,882	0,739	0,462	0,37	0,461	0,295	0,295	0,295

Установлено, что на Амуре лучшие результаты по абсолютным и относительным ошибкам имеет метод Holt – Winters: средний MAPE ≈ 10,87 %. Метод Ensemble Stacking также продемонстрировал высокую точность (RMSE ≈ 1,68, R^2 ≈ 0,978). Классические ARIMA и Boosting показали схожие результаты, немного уступая Stacking. Самыми слабыми оказались Prophet-like и Bagging, у которых RMSE превышал 4 г/л. Высокие значения MAPE и низкий R^2 у ARFIMA, Bagging и Prophet-like объясняются плохой адаптацией к длинным горизонтам и сезонности: дробное интегрирование ARFIMA ока-

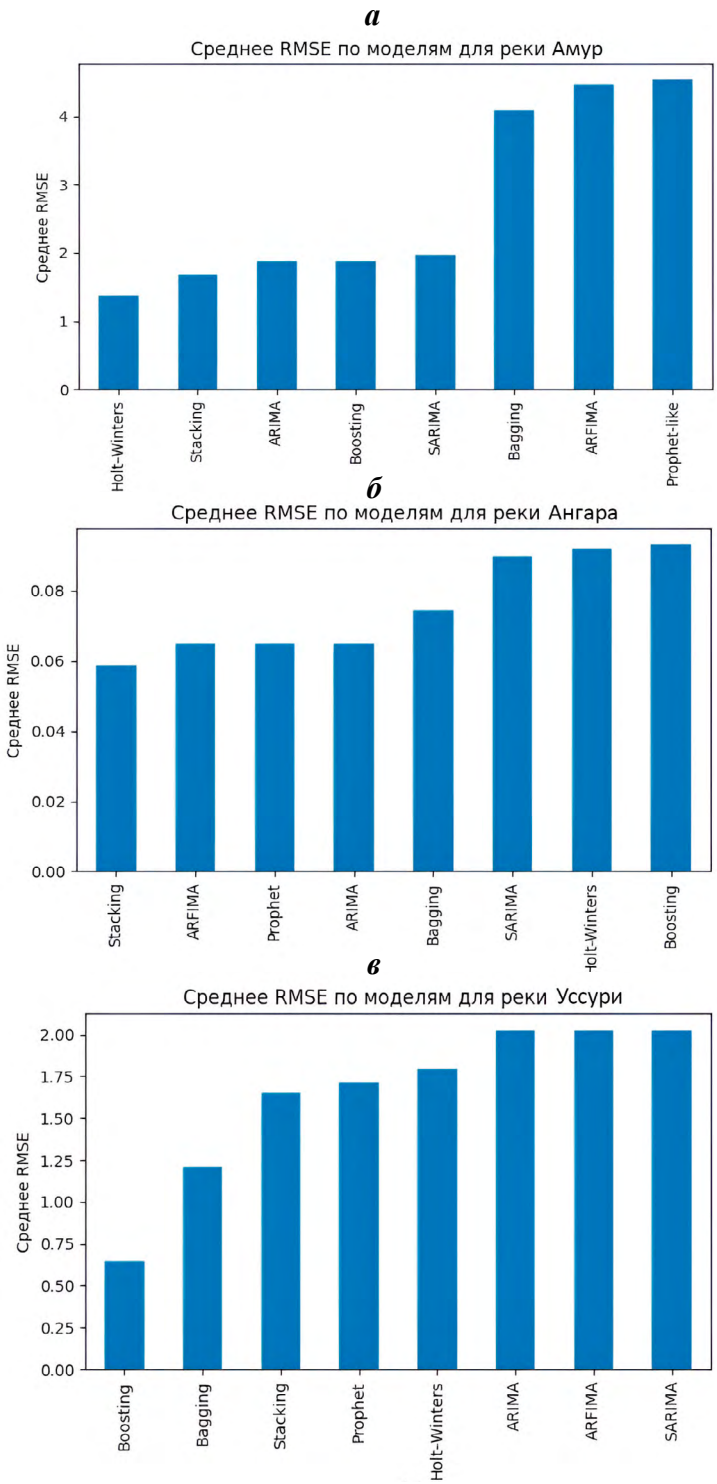


Рис. 2. График RMSE по моделям для рек: Амур (а), Ангара (б) и Уссури (в)
Fig. 2. RMSE graph for the Amur (a), Angara (b), and Ussuri (c) rivers

залось неэффективным для этой реки, а агрегационный ансамбль Bagging не смог снизить дисперсию из-за высокой вариабельности мутности.

Вода р. Ангары характеризуется меньшими значениями мутности, что отражается в низких ошибках. Совокупный ансамбль Stacking лидирует по метрике MAPE ≈ 5,11 % (такой же вывод следует и судя по величине симметричной средней абсолютной процентной ошибки sMAPE ≈ 4,8 %). Модели ARIMA, ARFIMA и Prophet показали одинаковые результаты, что связано с идентичными настройками и влиянием малого уровня шума. Метод Holt – Winters оказался менее эффективным на Ангаре, поскольку сезонность здесь выражена слабее, при этом Boosting и SARIMA дали более высокие ошибки, что отражает чувствительность этих методов к небольшой выборке.

Река Уссури отличается наиболее нерегулярной мутностью. Лучший результат здесь показал Boosting: MAPE ≈ 3,7 %, R^2 ≈ 0,88. Bagging занял второе место, Stacking был менее успешным, поскольку метамодель не смогла «выучить» закономерности, а классические ARIMA, SARIMA и ARFIMA оказались самыми слабыми, показывая более чем двукратную ошибку по сравнению с Boosting. Методы Holt – Winters и Prophet дали средние результаты, их сезонные и трендовые компоненты не смогли адекватно отразить сложную динамику р. Уссури.

Подтверждают сделанные выводы столбчатые графики среднего RMSE по моделям (рис. 2). Для Амура результат наглядно показывает превосходство методов Holt – Winters и Stacking (RMSE ≈ 1,37 г/л), для Ангары лидирующим снова оказывается совокупный ансамбль Stacking (средний RMSE меньше 0,06 г/л), а для Уссури полученный средний RMSE ≈ 0,65 г/л подтверждает лучший результат для Boosting.

Сравнение методов краткосрочного прогнозирования мутности воды на примере рек Амур, Уссури и Ангара

При исследовании качества воды р. Амур самым эффективным оказался метод Holt – Winters, что объясняется выраженной сезонностью мутности. В работе сезонность мутности Амура проявлена в 75-часовом цикле замеров в виде дневной составляющей. При компонентном анализе временного ряда и сезонности на основе базового обучения рассматриваемых моделей и построения прогнозов сезонная составляющая автоматически обнаруживается и моделируется с помощью рядов Фурье, что особенно полезно для данных с ежедневными закономерностями. Ансамбль Stacking также показал высокую точность, но немного уступил Holt – Winters, а классические ARIMA и Boosting дали схожие результаты. ARFIMA, Prophet и Bagging показали значительно худшие результаты: высокая доля ошибок и низкий R^2 свидетельствуют о том, что эти методы плохо учитывают сложную сезонную структуру Амура.

Все модели, примененные к данным по р. Ангаре, показали очень низкие значения ошибок, что обусловлено стабильным характером ее гидрологического режима. При этом наилучшие результаты продемонстрировали ансамблевый метод Stacking и простые ARIMA-подобные подходы (ARIMA, ARFIMA, Prophet). Эффект ансамбля Bagging был заметно хуже, а методы Boosting и SARIMA иногда переобучались. Holt – Winters показал худшие результаты, поскольку сезонность Ангары слабо выражена и сглаживание лишь увеличивает лаг прогноза.

Река Уссури характеризуется высокой изменчивостью, поэтому для нее метод Boosting оказался наиболее адаптивным, последовательно уменьшая смещение за счет последовательного обучения, он также лучше справлялся с резкими скачками. Bagging хорошо себя проявил, снижая дисперсию, при этом Stacking, напротив, не смог объединить прогнозы так же удачно, возможно, из-за недостатка данных для обучения метамодели. Классические ARIMA-методы и Holt – Winters оказались слишком жесткими для сложной динамики Уссури.

Из данных табл. 1 можно сделать вывод, что абсолютные ошибки краткосрочных прогнозов мутности воды на р. Ангаре в несколько раз меньше, чем на Амуре и Уссури, поскольку мутность Ангары обычно низкая. При этом на Амуре и Уссури диапазон значений выше, поэтому ошибки выглядят большими. Относительные ошибки (MAPE, sMAPE) позволяют сравнить показатели рек: самая низкая MAPE наблюдается у Boosting на Уссури (≈ 3,7 %), что свидетельствует о хорошей предсказуемости при грамотной настройке модели; на Амуре лучшая MAPE (≈ 10,9 %) у Holt – Winters, а на р. Ангаре – у Stacking (≈ 5,1 %).

Сравнение R^2 показывает, насколько примененные модели объясняют вариацию мутности относительно самой худшей модели для каждого горизонта. На Амуре лидирует Holt – Winters ($R^2 \approx 0{,}98$), на Ангаре – Stacking ($R^2 \approx 0{,}61$), на Уссури – Boosting ($R^2 \approx 0{,}88$). В целом ансамблевые методы (Stacking и Boosting) зачастую занимают первые места, однако на Амуре классический Holt – Winters за счет сильной сезонности показал лучшие результаты.

Оценка сложности и применимости методов краткосрочного прогнозирования мутности воды

Классические модели (ARIMA, SARIMA, ARFIMA, Holt – Winters). Эти методы просты в реализации, имеют небольшие вычислительные затраты и хорошо интерпретируемы. Они подходят для серий с регулярной структурой (как у р. Амур) и позволяют легко включать сезонность. Однако метод ARFIMA требует оценки дробного порядка и оказался малоэффективен на изученных рядах.

Prophet. Модель автоматизирует выбор трендов и сезонностей, допускает пропуски и работу с неравномерными наблюдениями. Она проста в применении и интерпретируема, но требует настройки. Модель показала среднюю точность на Амуре и Уссури. На р. Ангаре данные Prophet совпали с ARIMA, что указывает на схожесть структур.

Bagging. Этот метод уменьшает дисперсию прогнозов за счет обучения на разных подвыборках. На реках Амур и Уссури Bagging улучшил стабильность, но не достиг лучших результатов, вычислительные затраты возрастают из-за необходимости обучать множество моделей.

Boosting последовательно уменьшает смещение, уделяя больше внимания трудным наблюдениям. При оценке краткосрочного прогноза мутности на р. Уссури Boosting оказался наилучшим благодаря способности отражать резкие изменения. Однако этот метод чувствителен к выбросам и требует тщательной настройки скорости обучения, что усложняет его применение.

Stacking. Использует метамодель для оптимального объединения прогнозов. На реках Амур и Ангара Stacking заметно улучшил результаты, но на Уссури был менее успешен. Метод требует достаточного объема данных для обучения метамодели и более сложен в реализации.

Таким образом, в ходе проведенного исследования выработаны следующие рекомендации.

Для прогнозирования мутности воды в р. Амур рекомендуется использовать метод Holt – Winters, который наилучшим образом учитывает сезонный характер временного ряда мутности и обеспечивает наименьшие значения ошибок прогноза (MAE ≈ 1,23 г/л, MAPE ≈ 10,9 %, R^2 ≈ 0,98). В качестве альтернативы можно применять ансамбль Stacking, который также показал высокую точность (R^2 ≈ 0,97) и может быть полезен при наличии достаточного объема данных наблюдений для метамодели. Ансамблевые методы Bagging и Prophet на Амуре показали слабые результаты и не рекомендуются.

Из-за малой амплитуды колебаний мутности р. Ангары практически все модели дают приемлемую точность. Наилучшие результаты демонстрирует Stacking (MAPE ≈ 5,1 %, sMAPE ≈ 4,8 %, R^2 ≈ 0,61). При ограниченных ресурсах и в случаях, когда построения сложного ансамбля не требуется, целесообразно использовать простые модели – ARIMA или Prophet. Они обеспечивают уровень ошибки MAPE около 6 % и отличаются сравнительно низкими вычислительными затратами. Метод Holt – Winters не рекомендуется для р. Ангары, поскольку ее сезонная составляющая слабая.

Для нерегулярного и изменчивого ряда р. Уссури следует выбирать Boosting, обеспечивающий минимальные ошибки (MAE ≈ 0,53 г/л, MAPE ≈ 3,7 %, R^2 ≈ 0,88); Bagging может быть запасным вариантом, хотя его точность ниже, Stacking и классические модели дают более высокие ошибки и не рекомендуются без дополнительной оптимизации.

В целом, ансамблевые подходы, особенно Stacking и Boosting, часто превосходят отдельные модели за счет комбинирования различных источников информации, однако их эффективность зависит от характеристик конкретного временного ряда: при сильной сезонности (р. Амур) лучше работает Holt – Winters, при умеренной и стабильной динамике (р. Ангара) – достаточно

ARIMA или Stacking, а при высокой изменчивости (р. Уссури) лучшим становится Boosting. Выбор модели должен учитывать не только точность, но и доступность данных, вычислительные ресурсы, устойчивость к выбросам и необходимость интерпретируемости.

ВЫВОДЫ

В настоящее время принципиальное практическое значение имеет надежность и качество прогнозов, особенно когда представлено множество временных рядов, а специалисты с опытом моделирования временных рядов встречаются относительно редко. В представленной статье описывается практический подход к прогнозированию мутности воды, который сочетает настраиваемые статистические модели краткосрочного прогноза для совершенствования контроля качества воды в районах водозаборов водных объектов. Предложен комплекс ансамблевых методов с интерпретируемыми параметрами, который показал высокую эффективность по сравнению с другими моделями для рек Амур и Уссури.

На основе 45-минутных измерений мутности воды проведена настройка восьми моделей, включающих классические статистические модели, методы машинного обучения и ансамблевые подходы, для прогнозирования 16 наблюдений (лагов прогноза с шагом 45 мин). Наилучшие результаты продемонстрировали ансамблевые методы Stacking и Boosting на примере рек Амур и Уссури. Показана высокая точность прогноза с заблаговременностью 12 ч (16 наблюдений) для р. Амур (Stacking, $R^2 \approx 0{,}97$) и р. Уссури (Boosting, $R^2 \approx 0{,}88$), подтверждающая, что получены хорошие регрессионные модели с достаточно полной системой факторов. Они могут быть адаптированы для других крупных водных объектов, характеризующихся существенной внутрисуточной изменчивостью мутности воды, на основе использования автоматических систем с 45-минутной дискретностью измерения, что открывает возможные перспективы их применения в региональных исследованиях. Полученные результаты на основе модели Stacking для р. Ангары при $R^2 \approx 0{,}61$ показывают, что эта модель неполная и требует введения для увеличения точности прогноза дополнительных физических факторов, например расхода воды и осадков на основе гибридных моделей.

Таким образом, в рамках проведенного исследования обоснована необходимость использования прогнозных ансамблевых методов с учетом современных автоматических систем измерений мутности в реальном времени на водозаборах, т. к. даже в комплексе используемые методы, подтверждающие хорошую сходимость прогнозной кривой с натурными наблюдениями на основе RMSE, не представляют в полном объеме процессы формирования колебаний мутности воды.

Благодарности. *Авторы выражают благодарность главному научному сотруднику лаборатории проблем гидрологии суши Горного института УрО РАН д-ру геогр. наук, профессору Анатолию Павловичу Лепихину за полезные рекомендации, которые помогли в работе над статьей.*

КОНФЛИКТ ИНТЕРЕСОВ

Авторы заявляют об отсутствии конфликта интересов.

CONFLICT OF INTERESTS

The authors declare no relevant conflict of interests.

СПИСОК ЛИТЕРАТУРЫ

1. Лепихин А. П., Любимова Т. П., Богомолов А. В., Опутин М. А., Синцова Т. Н. Особенности внутрисуточных колебаний показателей качества воды, наблюдаемых в Камском водохранилище // Географический вестник. 2024. № 3 (70). С. 70–82.
2. Синцова Т. Н., Лепихин А. П., Розенталь О. М., Левин Л. Ю., Богомолов А. В. Статистические аспекты внутрисуточных колебаний показателей качества воды (на примере Камского водохранилища) // Вестник Пермского федерального исследовательского центра. 2025. № 4. С. 17–35.
3. Розенталь О. М., Синцова Т. Н. Динамика физических показателей качества воды (на примере исследования р. Уссури) // Экологические системы и приборы. 2024. № 3. С. 3–13.
4. Чалов С. Р., Морейдо В. М., Денисова И. С., Солоников И. А. Высокочастотный мониторинг и модели машинного обучения для оценки синоптической изменчивости стока взвешенных наносов малой городской реки // Гидросфера. Опасные процессы и явления. 2023. Т. 5. № 1. С. 59–74.
5. Troin M., Arsenault R., Wood A.W., Brissette F., Martel J.-L. Generating Ensemble Streamflow Forecasts: A Review of Methods and Approaches Over the Past 40 Years // Water Resources Research. 2021. Vol. 57. No. 7. https://doi.org/10.1029/2020WR028392
6. Dion P., Martel J.-L., Arsenault R. Hydrological ensemble forecasting using a multi-model framework // Journal of Hydrology. 2021. Vol. 600. Art. 126537. https://doi.org/10.1016/j.jhydrol.2021.126537
7. Tanguy M., Eastman M., Chevuturi A., Magee E., Cooper E., Johnson R. H. B., Facer-Childs K., Hannaford J. Optimising ensemble streamflow predictions with bias correction and data assimilation techniques // Hydrology and Earth System Sciences. 2025. Vol. 29. No. 6. P. 1587–1614. https://doi.org/10.5194/hess-29-1587-2025
8. Smith K. A., Barker L. J., Tanguy M., Parry S., Harrigan S., Legg T. P., Prudhomme C., Hannaford J. A multi-objective ensemble approach to hydrological modelling in the UK: an application to historic drought reconstruction // Hydrology and Earth System Sciences. 2019. Vol. 23. No. 8. P. 3247–3268. https://doi.org/10.5194/hess-23-3247-2019
9. Rele B., Hogan C., Kandanaarachchi S., Leigh C. Short-term prediction of stream turbidity using surrogate data and a meta-model approach // arXiv. 2022. arXiv:2210.05821
10. Khosravi K., Farooуqe A. A., Shahvaran A. R. Daggupati P., Heddam S. Hatamiafkoueieh Ja. Beyond conventional modeling: A cutting-edge hybrid IAER-AMT decision-tree-based algorithm for high-resolution river turbidity prediction // Ain Shams Engineering Journal. 2025. Vol. 16. No. 9. Art. 103511. https://doi.org/10.1016/j.asej.2025.103511
11. Santos V. S., Rocha P. A. C., Thé J. V. G. Gharabaghi B. Evaluation of machine learning methods for forecasting turbidity in river networks using Sentinel-2 remote sensing data // Ecological Informatics. 2025. Vol. 90. Art. 103313. https://doi.org/10.1016/j.ecoinf.2025.103313

12. Feng Y., Li Yu, Zhang B., Zhang Sh., Zhao T., and Zhang Chi. Naturalized and human-influenced streamflow of the Amur River for century-scale hydrological assessment // Scientific Data. 2026. Vol. 13. Art. 346. https://doi.org/10.1038/s41597-026-06685-7
13. Дударев О. В., Чаркин А. Н., Черных Д. В., Рубан А. С., Пипко И. И., Пугач С. П., Дубина В. А., Семилетов И. П. Изменчивость биогеохимического сигнала терригенного материала в нижнем течении и эстуарии реки Амур в годы с различными условиями формирования весеннего половодья // Вестник Дальневосточного отделения Российской академии наук. 2025. № 2. P. 57–75. https://doi.org/10.31857/S0869769825020051
14. Vient J. M., Fablet R., Jourdin F. and Delacourt C. End-to-End Neural Interpolation of Satellite-Derived Sea Surface Suspended Sediment Concentrations // Remote Sensing. 2022. Vol. 14 (16). Art. 4024. https://doi.org/10.3390/rs14164024
15. Ezzaouini M. A., Mahé G., Kacimi I., El Bilali A., Zerouali A., Nafii A. Predicting Daily Suspended Sediment Load Using Machine Learning and NARX Hydro-Climatic Inputs in Semi-Arid Environment // Water. 2022. Vol. 14. Iss. 6. Art. 862. https://doi.org/10.3390/w14060862
16. Saulquin B., Fablet R., Ailliot P., Mercier G., Doxaran D., Mangin A., and Fanton D'Andon O. H. Characterization of time-varying regimes in remote sensing time series: Application to the forecasting of satellite-derived suspended matter concentrations // IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. 2015. Vol. 8. Iss. 1. https://doi.org/10.1109/JSTARS.2014.2360239
17. Fazel Mojtahedi F., Yousefpour N., Chow S. H., Cassidy M. Offshore turbidity currents forecasting (part I): Integrating deep learning and computational fluid dynamics // Ocean Engineering. 2025. Vol. 331. Art. 121360. https://doi.org/10.1016/j.oceaneng.2025.121360
18. Huang W., Zhang C., Zhong H. et al. Advances in numerical and AI approaches for turbidity current research: a brief review // GeoEnergy Communications. 2025. Vol. 1. Art. 9. https://doi.org/10.1007/s44421-025-00009-y
19. Subramaniyan U., Rengasamy I., and Chellappa R. S. R. Sustainable Development in Reservoir Sedimentation Load Estimation from Statistical Analysis of Datasets to Deep Learning Algorithms // Global Nest Journal. 2024. Vol. 27. Iss. 1. Art. 05971. https://doi.org/10.30955/gnj.05971
20. Roushangar K, Alirezazadeh Sadaghiani A. Innovative deep learning and signal decomposition approaches for enhanced spatial and temporal suspended sediment concentration prediction // Environment Science Pollution Research International. 2025. Vol. 32. P. 15851–15876. https://doi.org/10.1007/s11356-025-36581-3
21. Шестеркин В. П., Шестеркина Н. М. Сток растворенных веществ в реке Амур у Хабаровска в многоводные 2020–2021 годы // Региональные проблемы. 2024. Т. 27. № 2. С. 53–55.
22. Regniers O., Beguet B., Débonnaire N., Budin R., Soula B., Briges A., Kervella S., Brasselet S., Lafon V. High Resolution Data-Driven Short-Term Forecast of Turbidity in a Real Case Water Quality Monitoring Application // IGARSS 2024–2024 IEEE International Geoscience and Remote Sensing Symposium, Athens, Greece. 2024. P. 5860–5864. https://doi.org/10.1109/IGARSS53475.2024.10640943

REFERENCES

1. Lepikhin A. P., Lyubimova T. P., Bogomolov A. V., Oputin M. A., Sintsova T. N. Features of intra-diurnal fluctuations in water quality indicators observed in the Kama Reservoir. *Geographical Bulletin*. 2024. No. 3 (70). P. 70–82.
2. Sintsova T. N., Lepikhin A. P., Rozental O. M., Levin L. Yu., Bogomolov A. V. Statistical Aspects of Intraday Fluctuations of Water Quality Indicators (on the Example of the Kama Reservoir). *Bulletin of the Perm Federal Research Center*. 2025. No. 4. P. 17–35.
3. Rosental O. M., Sintsova T. N. Dynamics of physical indicators of water quality (using the Ussuri River as an example). *Ecological systems and devices*. 2024. No. 3. P. 3–13.

4. Chalov S. R., Moreido V. M., Denisova I. S., Solonikov I. A. High-frequency monitoring and machine learning models for assessing synoptic variability of suspended sediment runoff of a small urban river. *Hydrosphere. Hazardous Processes and Phenomena*. Publishing NPO "Gidrotekhproekt" (Valdai). 2023. Vol. 5. No. 1. P. 59–74.
5. Troin M., Arsenault R., Wood A.W., Brissette F., Martel J.-L. Generating Ensemble Streamflow Forecasts: A Review of Methods and Approaches Over the Past 40 Years. *Water Resources Research*, 2021. Vol. 57. No. 7. https://doi.org/doi 10.1029/2020WR028392
6. Dion P., Martel J.-L., Arsenault R. Hydrological ensemble forecasting using a multi-model framework. *Journal of Hydrology*. 2021. Vol. 600. Art. 126537. https://doi.org/10.1016/j.jhydrol.2021.126537
7. Tanguy M., Eastman M., Chevuturi A., Magee E., Cooper E., Johnson R.H.B., Facer-Childs K., Hannaford J. Optimising ensemble streamflow predictions with bias correction and data assimilation techniques. *Hydrology and Earth System Sciences*, 2025. Vol. 29. No. 6. P. 1587–1614. https://doi.org/10.5194/hess-29-1587-2025
8. Smith K.A., Barker L.J., Tanguy M., Parry S., Harrigan S., Legg T.P., Prudhomme C., Hannaford J. A multi-objective ensemble approach to hydrological modelling in the UK: an application to historic drought reconstruction. *Hydrology and Earth System Sciences.* 2019. Vol. 23. No. 8. P. 3247–3268. https://doi.org/10.5194/hess-23-3247-2019
9. Rele B., Hogan C., Kandanaarachchi S., Leigh C. Short-term prediction of stream turbidity using surrogate data and a meta-model approach. arXiv, 2022. arXiv:2210.05821
10. Khosravi K., Farooуqe A.A., Shahvaran A.R., Daggupati P., Heddam S., Hatamiafkoueieh Ja. Beyond conventional modeling: A cutting-edge hybrid IAER-AMT decision-tree-based algorithm for high-resolution river turbidity prediction. *Ain Shams Engineering Journal.* 2025. Vol. 16. No. 9. Art. 103511. https://doi.org/10.1016/j.asej.2025.103511
11. Santos V.S., Rocha P.A.C., Thé J.V.G., Gharabaghi B. Evaluation of machine learning methods for forecasting turbidity in river networks using Sentinel-2 remote sensing data. *Ecological Informatics*, 2025. Vol. 90. Art. 103313. https://doi.org/10.1016/j.ecoinf.2025.103313
12. Feng Y., Li Yu, Zhang B., Zhang Sh., Zhao T. and Zhang Chi Naturalized and human-influenced streamflow of the Amur River for century-scale hydrological assessment. *Scientific Data*. 2026. Vol. 13. Art. 346. https://doi.org/10.1038/s41597-026-06685-7
13. Dudarev O. V., Charkin A. N., Chernykh D. V., Ruban A. S., Pipko I. I., Pugach S. P., Dubina V. A., and Semiletov I. P. Variability of the Biogeochemical Signal of Terrigenous Material in the Lower Reach and Estuary of the Amur River in Years with Different Conditions for the Formation of Spring Floods. *Bulletin of the Far Eastern Branch of the Russian Academy of Sciences*. 2025. No. 2. P. 57–75. https://doi.org/10.31857/S0869769825020051
14. Vient J. M., Fablet R., Jourdin F., and Delacourt C. End-to-End Neural Interpolation of Satellite-Derived Sea Surface Suspended Sediment Concentrations. *Remote Sensing.* 2022. Vol. 14 (16). Art. 4024. https://doi.org/10.3390/rs14164024
15. Ezzaouini M. A., Mahé G., Kacimi I., El Bilali A., Zerouali A., Nafii A. Predicting Daily Suspended Sediment Load Using Machine Learning and NARX Hydro-Climatic Inputs in Semi-Arid Environment. *Water.* 2022. Vol. 14. Iss. 6. Art. 862. https://doi.org/10.3390/w14060862
16. Saulquin B., Fablet R., Ailliot P., Mercier G., Doxaran D., Mangin A. and Fanton D'Andon O. H. Characterization of time-varying regimes in remote sensing time series: Application to the forecasting of satellite-derived suspended matter concentrations. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. 2015. Vol.* 8. Iss. 1. https://doi.org/10.1109/JSTARS.2014.2360239
17. Fazel Mojtahedi F., Yousefpour N., Chow S.H., Cassidy M. Offshore turbidity currents forecasting (part I): Integrating deep learning and computational fluid dynamics. *Ocean Engineering*. 2025. Vol. 331. Art. 121360. https://doi.org/10.1016/j.oceaneng.2025.121360

18. Huang, W., Zhang, C., Zhong, H. et al. Advances in numerical and AI approaches for turbidity current research: a brief review. *GeoEnergy Communications*. 2025. Vol. 1. Art. 9. https://doi.org/10.1007/s44421-025-00009-y
19. Subramaniyan U., Rengasamy I., and Chellappa R. S. R. Sustainable Development in Reservoir Sedimentation Load Estimation from Statistical Analysis of Datasets to Deep Learning Algorithms. *Global Nest Journal*. 2024. Vol. 27. Iss. 1. Art. 05971. https://doi.org/10.30955/gnj.05971
20. Roushangar K, Alirezazadeh Sadaghiani A. Innovative deep learning and signal decomposition approaches for enhanced spatial and temporal suspended sediment concentration prediction. Environment Science Pollution Research International. 2025. Vol. 32. P. 15851–15876. https://doi.org/10.1007/s11356-025-36581-3
21. Shesterkin V. P., Shesterkina N. M. Dissolved solids discharge in the Amur River near Khabarovsk during the high-water years of 2020-2021. *Regional problems*. 2024. Vol. 27. No. 2. P. 53–55.
22. Regniers O., Beguet B., Débonnaire N., Budin R., Soula B., Briges A., Kervella S., Brasselet S., Lafon V. High Resolution Data-Driven Short-Term Forecast of Turbidity in a Real Case Water Quality Monitoring Application. *IGARSS 2024-2024 IEEE International Geoscience and Remote Sensing Symposium*, Athens, Greece. 2024. P. 5860–5864. https://doi.org/10.1109/IGARSS53475.2024.10640943

Сведения об авторах:

Розенталь Олег Моисеевич, д-р техн. наук, профессор, главный научный сотрудник лаборатории управления водными ресурсами, Институт водных проблем Российской академии наук, Россия, 119333, Москва, ул. Губкина, д. 3; https://orcid.org/0000-0001-6261-6060; e-mail: omro3@yandex.ru

Синцова Татьяна Николаевна, ведущий инженер лаборатории проблем гидрологии суши, Горный институт Уральского отделения Российской академии наук, Россия, 614007, г. Пермь, ул. Сибирская, 78А; https://orcid.org/0000-0003-0327-4894; e-mail: tanya_sinzova@mail.ru

About the authors:

Oleg M. Rozental, Doctor of Technical Sciences, Professor, Chief Researcher of the Laboratory of Water Resources Management, Institute of Water Problems of the Russian Academy of Sciences; ul. Gubkina, 3; Moscow, 119333, Russia; https://orcid.org/0000-0001-6261-6060; e-mail: omro3@yandex.ru

Tatyana N. Sintsova, Lead Engineer of the Laboratory of Land Hydrology Problems, Mining Institute of the Ural Branch of the Russian Academy of Sciences; ul. Siberskaya, 78A; Perm, 614007, Russia; https://orcid.org/0000-0003-0327-4894; email: tanya_sinzova@mail.ru

Поступила в редакцию / Received 24.03.2026.
Поступила после рецензирования / Revised 29.05.2026.
Принята к публикации / Accepted 15.06.2026.