

DOI: <https://doi.org/10.37162/2618-9631-2026-1-171-188>

УДК 556.06+556.535.5

## Прогнозирование сроков формирования первичных ледовых явлений на реках Кольского полуострова

*С.А. Канашин<sup>1</sup>, Л.С. Банщикова<sup>1</sup>, А.Э. Сумачев<sup>2</sup>*

<sup>1</sup>Государственный гидрологический институт, г. Санкт-Петербург, Россия;

<sup>2</sup>Санкт-Петербургский государственный университет,  
г. Санкт-Петербург, Россия  
*ckanashin@yandex.ru*

Целью данного исследования является оценка возможности применения методов машинного обучения для совершенствования зависимостей, связанных с прогнозом сроков появления первичных устойчивых ледовых явлений. В качестве объекта изучения выбраны реки Кольского полуострова с различными условиями формирования ледового режима. Выполнен пространственно-временной анализ сроков появления первичных ледовых явлений, анализ многолетней изменчивости сумм отрицательной температуры воздуха на исследуемой территории. Сформирована база данных гидрологической и метеорологической информации за характерные даты, собран предиктивный состав модели. В работе представлен прогноз осенних ледовых явлений с использованием двух подходов – регрессионного и классификационного. Регрессионный подход предполагает использование деревьев решений (XGBoost), классификационный, в свою очередь, опирается на гибридную нейросетевую модель (XGBoost – CNN-GRU). Прогноз, полученный гибридным подходом, не превышает допустимые погрешности и может быть рекомендован к использованию.

*Ключевые слова:* ледовый режим, Кольский полуостров, прогноз ледовых явлений, нейронные сети, машинное обучение, глубокое обучение, XGBoost, LSTM

## Forecasting the dates of initial ice formation on the Kola Peninsula rivers

*S.A. Kanashin<sup>1</sup>, L.S. Banshchikova<sup>1</sup>, A.E. Sumachev<sup>2</sup>*

<sup>1</sup>State Hydrological Institute, Saint Petersburg, Russia;

<sup>2</sup>Saint-Petersburg State University, Saint Petersburg, Russia  
*ckanashin@yandex.ru*

The objective of the present study is to evaluate the feasibility of using machine and deep learning methods to improve dependencies associated with forecasting the dates of occurrence of initial persistent ice phenomena. The study focuses on the rivers of the Kola Peninsula with varying ice formation conditions. A spatiotemporal analysis of the dates of initial ice phenomena and long-term variability of negative air temperature totals in the study area was performed. A database of hydrological and meteorological information for characteristic dates was compiled, and a predictive model was assembled. The paper presents a forecast of autumn ice phenomena using two approaches: regression and classification. The regression approach utilizes decision trees (XGBoost), while the classification approach relies on a hybrid neural network model (XGBoost – CNN-GRU). The forecast obtained by the hybrid approach does not exceed permissible errors and can be recommended for use.

*Keywords:* ice regime, Kola Peninsula, ice phenomena forecast, neural networks, machine learning, deep learning, XGBoost, LSTM

## Введение

Формирование устойчивых ледовых явлений является неотъемлемой частью гидрологического цикла. Сроки появления, продолжительность формирования, интенсивность являются важными характеристиками, необходимыми как для безаварийной эксплуатации ГТС, так и для работы служб спасения, рыболовных хозяйств, проектирования и строительства газопроводов, автодорожных и железнодорожных мостов.

Начало формирования ледового покрова на реках Кольского полуострова определяются рядом физико-географических факторов, среди которых ключевую роль играют широтное положение, интенсивность охлаждения водной массы, морфометрические характеристики русла, а также степень естественной и антропогенной зарегулированности стока.

Формирование первичных устойчивых ледовых явлений на реках зависит от комплекса факторов: достижение критических сумм отрицательных температур, наличие течения, морфологических особенности русел, региональных климатических условий и степени антропогенного воздействия. В более холодных внутренних районах полуострова на малых реках появление первичных заберегов происходит уже в начале ноября. В то же время, например, в прибрежных районах Баренцева моря, благодаря смягчающему влиянию морского климата и относительно тёплым погодным условиям в осенний период, сроки начала ледообразования, как правило, приходятся на более поздние даты. Кроме того, на участках с высокими уклонами и порогами, где наблюдаются большие скорости течения, происходит интенсивное шугообразование.

Анализу изменчивости указанных выше характеристик посвящен ряд работ, в том числе [1, 3–7, 9, 12, 15, 16]. Выявленные изменения характеристик ледового режима, включая сроки появления ледовых явлений и установления ледостава, имеют значимый тренд за многолетний период, более того, изменилась последовательность и продолжительность формирования различного вида ледовых явлений.

В работе [8] указано, что запросы потребителей в области ледовых прогнозов во многом свелись к решению проблем, связанных с обеспечением гидрометеорологической безопасности страны. В этой связи в Гидрометцентре России продолжают исследования по созданию методов и методик прогнозирования сроков наступления осенних и весенних ледовых явлений, заторов и зажоров льда, в основу которых положен синоптико-статистический метод.

Разработанные в 40-х годах прошлого века как краткосрочные методы, основанные на физико-статистических зависимостях и уравнении теплового баланса, так и долгосрочные прогнозы, учитывающие закономерности развития атмосферных процессов [11], не учитывают современные изменения климата и, соответственно, параметров ледового режима, требуют уточнения и модернизации в условиях изменяющегося климата и роста объёма доступных данных.

За последние десять лет глубокое обучение – направление машинного обучения, использующее многослойные нейронные сети – значительно расширило возможности построения прогностических моделей в различных областях знаний. Такие модели активно применяются в обработке изображений, распознавании речи, машинном переводе и других сферах. В области наук о Земле, включая гидрологию, они также демонстрируют высокую эффективность [18].

Преимущество нейронных сетей заключается в их универсальности, способности выявлять сложные скрытые зависимости и учитывать большое количество предикторов, включая климатические, морфологические и антропогенные факторы. Всё это делает их перспективным инструментом для моделирования и прогнозирования ледовых явлений.

Целью данного исследования является анализ условий формирования ледового режима предзимнего периода рек Кольского полуострова и оценка возможности применения методов машинного обучения для совершенствования зависимостей, связанных с прогнозом сроков появления первичных устойчивых ледовых явлений.

В ходе работы была создана база данных, включающая основные характеристики ледового режима рек Кольского полуострова и метеопараметры, обобщающая расчетные характеристики ледового режима за период с 1930 по 2022 год; количественно и качественно проанализирована межгодовая изменчивость данных характеристик; выявлены основные статистические зависимости; разработана классификация рек.

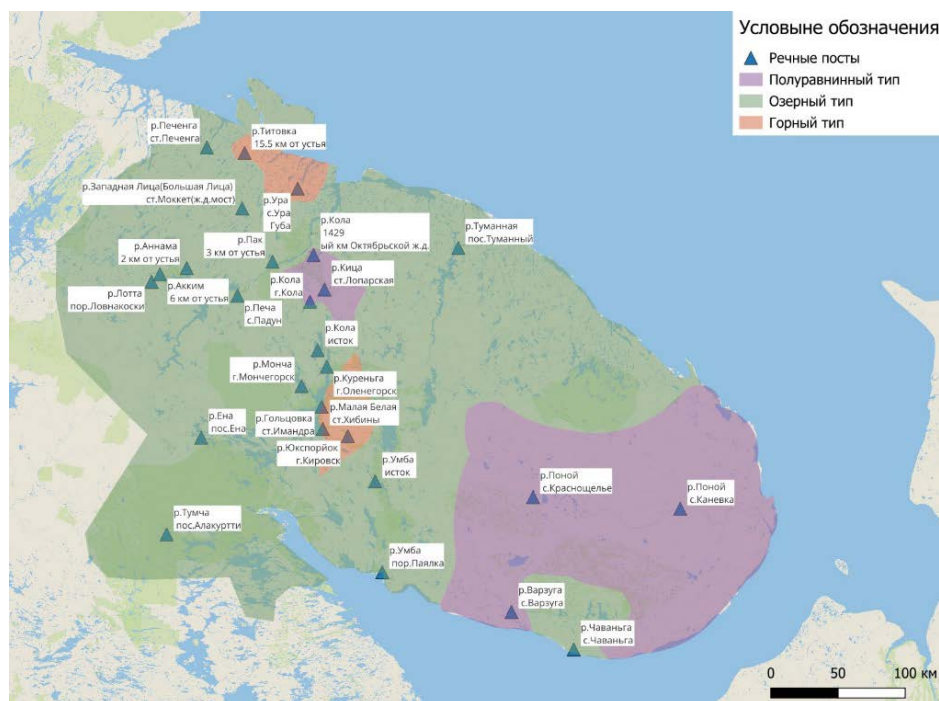
Данная работа является частью диссертационного исследования, в рамках которого рассматривались такие модели машинного обучения, как XGBoost, CatBoost, LSTM, GRU, TCN, Transformer. В настоящей работе представлены результаты для лучших моделей регрессионного и классификационного подходов (XGBoost и XGBoost-CNN-GRU соответственно).

## Материалы и методы

Объект исследования – реки Кольского полуострова. Для проведения исследования была сформирована база данных по 24 гидрологическим постам и по 11 метеостанциям [14]. В качестве предикторов прогностической зависимости на основе среднесуточных данных выбраны: даты наступления ледового явления, вид ледового явления, уровень воды, условные обозначения ледовых явлений, которые были систематизированы и приведены к единой классификации. Метеорологические данные – накопленная сумма отрицательных температур воздуха, накопленная сумма осадков. Данные представлены с 1936 по 2020 год за период с 1 октября по 31 января соответствующего водохозяйственного года. Выбор временного периода продиктован наиболее ранним началом перехода температуры воздуха через 0 °C и наиболее поздней датой формирования ледостава.

Вследствие того, что большинство рек Кольского полуострова относятся к малым водотокам, большое влияние на формирование первичных ледовых явлений и установление ледостава оказывают локальные факторы.

Реки Кольского полуострова, в зависимости от рельефа и ряда других географических особенностей, подразделяются на три типа: полуравнинные, озёрного типа и горные (рис. 1). Данная классификация также может быть применена для типизации водотоков по условиям замерзания.



**Рис. 1.** Типизация рек по условиям их протекания.

**Fig. 1.** Classification of rivers according to their flow conditions.

К рекам полуравнинного типа следует отнести реки Варзуга, Поной, Кица и участки реки Кола в нижнем и среднем течении. Замерзание на этих реках, как правило, начинается с образования заберегов и сала. На реке Варзуга эти явления, как правило, носят кратковременный характер, после чего наблюдается образование шуги в 64 случаях из 100 лет наблюдений [7].

Большинство малых и средних рек Мурманской области относятся к водотокам озёрного типа. Среди исследуемых объектов к данной категории можно отнести, в частности, реки Чаваньга, Кола, Ура, Умба, Печенга, Титовка, Западная Лица и ряд других. На формирование ледового режима, помимо озёр, оказывают существенное влияние тёплые морские течения Баренцева и Белого морей.

К горному типу относятся малые водотоки, берущие начало на возвышенностях Кольского полуострова. Эти реки характеризуются значительными уклонами русел, протекают в узких скалистых долинах и имеют

развитую порожисто-водопадную структуру. К данному типу относятся реки Малая Белая, Юкспорйок, Тумча, Ура, Титовка.

Для прогноза сроков появления льда и установления ледостава были созданы модели, разработанные на языке программирования Python с использованием библиотек XGBoost, TensorFlow (Keras), Scikit-learn. Эти инструменты позволяют эффективно решать как задачи регрессии, так и задачи классификации, в частности – многоклассовой классификации ледовых явлений, что является задачей повышенной сложности из-за сезонной и пространственной неоднородности. Таким образом, в данной работе реализован регрессионный подход методами градиентного бустинга. Результатом работы этой прогностической модели является дата появления первичного ледового явления. Также был реализован классификационный подход с использованием гибридной модели XGBoost-CNN-GRU. Результатом работы модели является вероятность появления класса ледового явления на каждый интересующий пользователя день. На данный момент переход от вероятностей появления первичных ледовых явлений к датам осуществлялся вручную.

Все наблюдаемые ледовые явления были учтены (обработаны) и распределены по четырём классам: отсутствие льда, устойчивые первичные ледовые явления, неполный ледостав, установившийся ледостав. Выбранными предикторами служили: сумма отрицательной температуры воздуха, сумма осадков, уровень воды, характеристика ледового режима, а также их статистические характеристики: среднее, стандартное отклонение, минимум, максимум, разность между максимальной и минимальной величиной и тренд изменения характеристики. Процесс образования ледовых явлений обладает кумулятивным эффектом: гидрологическая и метеорологическая обстановка за предыдущие дни влияет на текущую вероятность ледообразования. Для учета погодных условий и водности рек за предшествующий замерзанию период расчет статистических характеристик предиктивного состава производился за 3, 5, 7, 14 дней до появления ледового явления. В общей сложности для прогноза сроков осенних ледовых явлений использовалось 102 признака. В качестве целевых переменных выступали: класс прогнозируемого явления и дата появления соответствующего класса. Для решения задач регрессии наилучшие результаты показали модели, использующие деревья решений, например, модель градиентного бустинга XGBoost Regressor, предложенная Т. Ченом и К. Гестрином [20]. Такой механизм машинного обучения позволяет улавливать сложные нелинейные зависимости и взаимодействия между предикторами и целевой переменной, с которыми простые модели или линейные методы не справляются. Кроме того, деревья решений устойчивы к пропущенным значениям и различным масштабам признаков, а бустинг снижает риск переобучения за счет усреднения множества моделей. В научной литературе представлено несколько успешных примеров использования XGBoost – от моделирования речного стока и уровня воды до оценки качества и состояния подземных вод. Например, моделирование ледовых явлений на реке Варта

показало, что градиентный бустинг (XGBoost) не уступает по точности нейросетям и позволяет оценить важность разных предикторов (температура воздуха, температура воды, уровень и расход воды) в формировании льда [22]. Преимущество XGBoost не только в точности, но и в скорости: благодаря параллельной реализации алгоритм способен быстро обрабатывать большие массивы данных [17].

Наличие многолетних суточных данных наблюдений за метеорологическими и гидрологическими характеристиками, фазами водного режима позволяют применить методы нейросетевого моделирования, основанные на типизации характеристик ледового режима. Так же как и для регрессионных моделей, исходные данные были разбиты на четыре класса ледовых явлений. Целевой переменной модели является характеристика ледового явления: появление первичных ледовых явлений, установление ледостава и отсутствие ледовых явлений на интересующую дату. Для решения задачи классификации ледовых явлений была использована гибридная модель, объединяющая метод машинного обучения XGBoost и нейросетевые модели CNN, GRU. Применение моделей гибридного типа в гидрологических задачах успешно зарекомендовало себя в ряде зарубежных исследований [19, 21, 23]. Подобные архитектуры позволяют учитывать сложные временные зависимости и пространственную изменчивость гидрологических процессов.

Долгосрочная память (Long Short-Term Memory, LSTM) – это разновидность рекуррентных нейронных сетей, специально разработанная для преодоления проблемы «затухающего градиента», присущей классическим рекуррентным нейронным сетям (РНС). В стандартных рекуррентных сетях при длительных последовательностях градиенты ошибки при обратном распространении стремительно уменьшаются, из-за чего сеть утрачивает способность учиться на дальних зависимостях во времени. Архитектура LSTM включает особые управляющие элементы, так называемые «gates» (входной, выходной и «затвор забывания»), и ячейку памяти, позволяющую хранить информацию на протяжении многих шагов, предотвращая ее стирание при обновлении весов [22]. В данном исследовании используется облегченная альтернатива LSTM – GRU (gated recurrent unit), имеющая упрощенную структуру, которая, однако, во многих задачах показывает сравнимую с моделями LSTM точность.

Комплексное моделирование природных процессов часто выигрывает от объединения разнородных методов, где каждый восполняет недостатки других. Гибридная архитектура, сочетающая градиентный бустинг деревьев (XGBoost) и рекуррентные сети, позволяет одновременно учитывать как сложные нелинейные зависимости между всеми входными признаками, так и временную последовательность и долгосрочную память явления. Идея такого ансамбля опирается на принцип комплементарности моделей: дерево решений лучше улавливает отношения между статическими или мгновенными признаками, выявляет важные факторы и нелинейные

правила, тогда как рекуррентная сеть превосходно моделирует эволюцию системы во времени и помнит предысторию процесса [24]. Гибридные архитектуры могут быть реализованы по-разному – от параллельного обучения двух моделей с последующим объединением их прогнозов до последовательной схемы, где вывод одной модели используется как дополнительный вход для другой. В работе по прогнозу ледовых явлений сочетание разных подходов уже показало себя: так, объединение сверточной сети и LSTM дало значительно более высокую метрику F1-score при классификации ледяных заторов, чем каждая из моделей по отдельности, доказав их взаимодополняемость [22].


В качестве основного инструмента оценки эффективности классификационных моделей в исследовании применяется анализ матрицы ошибок (confusion matrix), на основе которой рассчитываются метрики Accuracy, Precision, Recall и F1-score. Каждая из них отражает разные аспекты качества классификации: Accuracy характеризует общую долю верно классифицированных наблюдений, Precision описывает точность положительных предсказаний, Recall отражает полноту выявления положительных случаев, а F1-score, являясь гармоническим средним между Precision и Recall, обеспечивает интегральную оценку, учитывающую одновременно и точность, и полноту.

Заблаговременность прогнозов первичных ледовых явлений, полученных с помощью моделей, которые разработаны на методах машинного обучения, соответствует заблаговременности прогнозов метеорологических параметров и составляет четыре дня. Применительно к долгосрочному прогнозированию, разработанные модели могут иметь рекомендательный характер, так как прогноз появления классов ледовых явлений выполняется на каждый день интересующего периода. Точность же данного прогноза будет зависеть от точности долгосрочных прогнозов метеорологических и гидрологических параметров.

### Обсуждение и результаты

Несмотря на отмечаемые изменения многолетних сроков ледообразования, средняя дата появления первичных ледовых явлений на реках первого типа все также приходится на третью декаду октября. Под влиянием современных климатических изменений сроки начала ледообразования на реках полуравнинного типа также существенно не изменились: для р. Варзуги – 2 дня, для р. Поной – 4 дня (рис. 2).

На формирование ледового режима, помимо озёр, оказывают существенное влияние тёплые морские течения Баренцева и Белого морей, в связи с чем первичные ледовые явления наблюдаются, как правило, с середины октября до начала ноября. Проведённый анализ не выявил статистически значимого влияния климатических изменений на сроки начала ледообразования. Замерзание рек, как правило, происходит за счёт срастания берегов. Ледоход на большинстве рек не наблюдается; шугоход, при его наличии, продолжается, как правило, не более 10 дней.



**Рис. 2.** Хронологические графики появления первичных ледовых явлений на реках Кольского полуострова по типам рек: полуравнинные (а); озерного типа (б); горные (в).


**Fig. 2.** Chronological graphs of the appearance of primary ice phenomena on the rivers of the Kola Peninsula by river type: semi-plain (a); lake type (б); mountain (в).

Появление льда (6 ноября) на р. Малой Белой наиболее позднее из всех исследуемых рек за счет турбулентного перемешивания и высокой скорости потока (рис. 2). Устойчивые первичные ледовые явления на реке Малая Белая преимущественно представлены заберегами. В верховьях и на мелководных перекатах морозы быстро образуют забереги, после чего в течение нескольких недель происходит становление ледяного покрова. Так же как и для всех рек Кольского полуострова, для р. Малой Белой значимый тренд на раннее появления первичных ледовых явлений не выявлен.

Отсутствие выраженных тенденций к смещению сроков формирования первичных ледяных явлений на реках Кольского полуострова объясняется озёрным регулированием стока, широким распространением шугообразования, а также тем, что для установления устойчивого ледостава в регионе, как правило, достаточно сравнительно невысоких отрицательных температур воздуха. Анализ метеорологических данных за октябрь-ноябрь показывает, что характерные температурные значения и даты их наступления остаются относительно стабильными на протяжении исследуемого периода.

Основным предиктором для прогноза сроков появления первичных ледовых явлений и установления ледостава является накопленная сумма отрицательных температур воздуха. В условиях современного изменения климата увеличение сумм отрицательных температур воздуха (рис. 3) приводит к увеличению периода замерзания рек от появления первичных ледовых явлений до установления ледостава. Существенное влияние на формирование ледовых явлений оказывают атмосферные осадки. Увеличение их количества в период становления ледостава способствует образованию снежуры и шуги, что изменяет тип и сроки формирования ледового покрова. Поскольку прогностические модели обоих подходов разрабатывались для всех исследуемых постов Кольского полуострова, одним из признаков выступает код поста. Так как этот признак является категориальным, его непосредственное использование в большинстве алгоритмов машинного обучения затруднено. Для приведения его к требуемому формату применялось кодирование методом one-hot encoding. Обучение моделей производилось с помощью кросс-валидации. Из всего набора данных выделен независимый набор данных для оценки точности работы модели (с 2010 по 2019 г.). На первом этапе оставшиеся данные были разделены на обучаемый и тестовый наборы в соотношении 80 % и 20 % соответственно. На втором этапе модель обучалась на всех оставшихся данных и результат ее прогноза оценивался по независимым данным.

В целом качество работы модели по распознаванию классов ледового режима можно охарактеризовать как среднее: общая точность составляет 77 %. Средние значения  $\text{precision} = 63 \%$ ,  $\text{recall} = 62 \%$  и  $\text{F1-score} = 63 \%$  показывают, что модель в сопоставимой степени подвержена как ложным срабатываниям, так и пропускам событий, обеспечивая сбалансированный, но требующий дальнейшего улучшения уровень классификации ледовых явлений. Архитектура гибридной нейросетевой модели (классификационный подход) приведена в табл. 1.



**Рис. 3.** Среднемноголетние суммы отрицательных температур воздуха Кольского полуострова.

**Fig. 3.** Average long-term sums of negative air temperatures on the Kola Peninsula.

**Таблица 1.** Архитектура нейросетевой модели типа XGBoost+CNN-GRU

**Table 1.** Architecture of the XGBoost+CNN-GRU neural network model

Слой	Параметры	Назначение слоя
XGBoost	Число деревьев 300, глубина деревьев 6, скорость обучения = 0.05	Обучение на исходных признаках; получение вероятностей принадлежности к классам
Конкатенация	–	Объединение нормализованных признаков с выходом XGBoost (4 признака)
Conv1D	32 фильтра, метод активации Relu	Выделение локальных закономерностей во временном ряду (например, всплесков температуры)
BatchNormalization	–	Стабилизация обучения, ускорение сходимости
GRU	Количество нейронов 64	Учет долгосрочных зависимостей и запоминание временной информации
Dropout	30 % отключаемых нейронов	Предотвращение переобучения путем случайного "выключения" нейронов
GRU	Количество нейронов 32	Углубленная обработка временного контекста и извлечение финального состояния
Dropout	30 % отключаемых нейронов	Регуляризация модели
Dense	Количество нейронов 16, метод активации Relu	Промежуточная нелинейная трансформация признаков
Dense	Количество нейронов 4, метод активации softmax	Финальная классификация по 4 классам ледового явления

Для сравнения регрессионного и классификационных подходов использованы средняя квадратической погрешности проверочных прогнозов ( $S$ ). Методика считается допустимой для выпуска прогнозов, если погрешность проверочных прогнозов в 85 % случаев из их общего числа не превышает допустимую. Допустимая погрешность назначается исходя из средней заблаговременности прогнозов, которая для осенних ледовых явлений составляет 4 дня. Хорошей модель считается при соотношении  $S \leq 3.0$ , удовлетворительной при  $S \leq 4.8$  [8]. Стоит отметить, что для оценки качества методик будет использоваться ненормированная  $S$  на число постоянных в прогностическом уравнении, так как построенные архитектуры имеют достаточно большое количество параметров.

Результаты прогноза дат появления первичных ледовых явлений приведены в табл. 2.

**Таблица 2.** Результаты прогноза дат появления первичных ледовых явлений  
**Table 2.** Results of forecasting the dates of occurrence of primary ice phenomena

Река – пост	XGBoost (регрессия)		XGBoost+CNN+GRU (классификация)	
	S	%4дня	S	%4дня
<b>Полуравнинные реки</b>				
р. Кола – 1429-й км Октябрьской ж. д.	2.1	100	4.5	78
р. Кица – ст. Лопарская	1.8	100	3.0	90
р. Поной – с. Краснощелье	1.6	100	1.8	100
р. Поной – с. Каневка	1.8	100	1.0	100
р. Варзуга – с. Варзуга	1.4	100	3.4	80
<b>Озерные реки</b>				
р. Туманная – пос. Туманный	2.3	90	6.2	80
р. Печа – с. Падун	1.8	100	4.3	78
р. Чаваньга – с. Чаваньга	1.4	100	3.8	78
р. Умба – исток	1.5	100	3.6	80
р. Умба – пор. Паялка	1.5	100	6.5	90
р. Ена – пос. Ена	1.7	100	2.1	90
р. Монча – г. Мончегорск	2.4	90	11.3	30
<b>Горные реки</b>				
р. Ура – с. Ура-Губа	1.8	100	1.9	100
р. Малая Белая – ст. Хибины	2.6	100	5.6	78
р. Юкспорйок – г. Кировск	2.4	100	15.6	22
р. Тумча – пос. Алакуртти	1.4	100	1.9	100

Наилучшие результаты показал регрессионный подход (табл. 3). По выбранным параметрам оценки модель, основанную на деревьях решений XGBoost, можно рекомендовать для прогноза первичных ледовых явлений для всех исследуемых водотоков.

**Таблица 3.** Архитектура модели градиентного бустинга XGBoost  
**Table 3.** Architecture of the XGBoost gradient boosting model

Слой / блок	Параметры	Назначение слоя
Подготовка целевой переменной	Target_Date → число дней от 1 сентября соответствующего сезона	Преобразование дат наступления ледового явления в непрерывную регрессионную переменную (количество дней до события)
Кодирование признака Post	OneHotEncoder(sparse=False, handle_unknown='ignore')	Преобразование категориального признака гидрологического поста в набор бинарных признаков
Формирование матрицы признаков X	Исключение Season, Target_Class, Target_Date; конкатенация числовых и one-hot признаков	Получение полного набора входных признаков для обучения модели
Деление на выборки по годам	Обучающая выборка: Season < 2010; тестовая выборка: Season ≥ 2010	Разделение данных во времени для имитации прогноза «на будущее» и корректной оценки обобщающей способности
Масштабирование признаков	StandardScaler (обучение по train, применение к train и test)	Нормализация числовых признаков, улучшение сходимости и стабильности обучения XGBoost
Модель XGBoost-регрессии	XGBRegressor (n_estimators=100, max_depth=4, learning_rate=0.1, eval_metric='mae', random_state=42)	Обучение градиентного бустинга по деревьям решений для прогноза числа дней до наступления ледового явления
Логирование обучения	eval_set = (train, test), вывод MAE по boosting-итерациям, график MAE	Контроль процесса обучения и выявление возможного переобучения по кривым ошибок на train и test
Постобработка предсказаний	Прогноз y_pred → календарные даты; расчёт ошибок в сутках, MAE, долей попаданий в интервалы	Оценка точности прогноза дат (в сутках) и характеристика распределения ошибок по величине
Метрики по классам ледовых явлений	Группировка по Target_Class; расчёт MAE и долей попаданий в интервалы для каждого класса	Анализ качества прогноза отдельно для разных типов ледовых явлений

Качество модели, основанной на классификационном подходе, для большинства рек можно оценить как удовлетворительное. Однако для выполнения прогноза осенних ледовых явлений данный подход можно рекомендовать только для рек Поной (посты Краснощелье и Каневка), Ена, Ура и Тумча.

Большие отличия между прогнозными и историческими данными могут возникнуть из-за временного запаздывания сумм отрицательных температур воздуха и появления первичных ледовых явлений. Подбор репрезентативных данных для части постов Кольского полуострова был затруднен доступностью данных. Кроме того, для улучшения качества моделей, в том числе классификационного подхода, следует рассмотреть расширенный список предикторов, включающий приращение отрицательных температур воздуха в явном виде, учет дней с оттепелью, количество дней с жидкими и твердыми осадками.

### Выводы

Анализ данных показал, что большое влияние на формирование первичных ледовых явлений и установление ледостава оказывают локальные факторы, поскольку большинство рек Кольского полуострова относятся к малым водотокам. Принцип классификации участков рек по типу замерзания: полуравнинные, озерного типа и горные – позволил учесть эти факторы при разработке прогностических зависимостей.

Использование нейронных сетей на основе длительных рядов гидрологических и метеорологических наблюдений значительно повышает эффективность существующих методов прогнозирования параметров ледового режима рек Кольского полуострова.

Благодаря возможности включения большого числа предикторов становится возможным построение уникальных прогностических моделей для различных типов ледообразования, с учётом как естественной и антропогенной зарегулированности водотоков, так и морфологических особенностей русел, климатических изменений и других факторов.

Наиболее оправданным подходом для прогноза элементов ледового режима является регрессионный подход (метод градиентного бустинга XGBoost). Однако также следует более подробно рассмотреть классификационный подход с гибридной моделью, учитывающей нелинейные зависимости между предикторами и целевой переменной, и модели, учитывающие временные зависимости (LSTM, GRU, TCN и др.) для исследования паттернов изменения предикторов и целевой переменной во времени.

Заблаговременность прогноза первичных ледовых явлений, полученных с помощью моделей, которые разработаны на методах машинного обучения, соответствует заблаговременности прогнозов метеорологических параметров и составляет 4 дня. В контексте долгосрочного прогнозирования разработанные модели могут использоваться в рекомендательном режиме. Они позволяют получать прогноз появления классов ледовых

явлений для каждого дня интересующего периода, но полученные даты следует рассматривать как ориентировочные, а не как оперативный прогноз.

Полученные результаты являются частью диссертационного исследования и темы НИР 125022702938-5, в настоящее время проходят апробацию на сети Мурманского УГМС, а также являются частью исследования в рамках научного проекта № 03/2025-И Русского географического общества «Оценка изменений гидролого-гидрохимического режима водных объектов Кольского полуострова и прилегающих территорий под воздействием естественных и антропогенных факторов».

### **Благодарности**

Авторы статьи выражают благодарность сотрудникам Мурманского УГМС за ценные советы и помощь в организации исследования.

### **Acknowledgments**

The authors of the article express their gratitude to the staff of the Murmansk UGMS for valuable advice and assistance in organizing the study.

### **Список литературы**

1. Агафонова С.А., Василенко А.Н., Мироненко А.А., Фролова Н.Л. Ледовый режим и его опасные проявления на реках Арктической зоны России // Ледовые и термические процессы на водных объектах России. Труды V Всеросс. конференции М.: Изд-во РГАУ – МСХА им. К.А. Тимирязева, 2016. С. 15-21.

2. Агафонова С.А., Фролова Н.Л., Василенко А.Н. и др. Ледовый режим и опасные гидрологические явления на реках Арктической зоны европейской территории России // Вестник Моск. ун-та. Серия 5. География. 2016. № 6. С. 41-49.

3. Алексеевский Н.И., Магрицкий Д.В., Михайлов В.Н. Антропогенные и естественные изменения гидрологических ограничений для природопользования в дельтах рек Российской Арктики // Водное хозяйство России: проблемы, технологии, управление. 2015. № 1. С. 14-31.

4. Баклагин В.Н. Зависимости характерных дат ледового режима Белого моря от температурного фона над его акваторией // Успехи современного естествознания. 2020. № 7-0. С. 55-60.

5. Банищикова Л.С., Банищikov А.А., Сумачев А.Э. Распространение зажоров и заторов льда на реке Варзуга // Экологические проблемы северных регионов и пути их решения. Тезисы докладов VII Всероссийской научной конференции с международным участием, посвященной 30-летию Института проблем промышленной экологии Севера ФИЦ КНЦ РАН и 75-летию со дня рождения доктора биологических наук, профессора В.В. Никонова. 2019. С. 102-104.

6. Банищикова Л. С., Сумачев А. Э. Вариация температуры воздуха холодного периода на Кольском полуострове как фактор изменения ледового режима // Арктика: экология и экономика. 2021. Том 11, № 3. С. 397-405.

7. Банищикова Л.С., Сумачев А.Э., Бирюкова В.А., Канахин С.А. Ледовый режим реки Варзуга. Оценка их риска и негативных последствий // Сборник трудов VI Всероссийской конференции с международным участием «Гидрометеорология и экология: достижения и перспективы развития/MGO 2022», Санкт-Петербург, 14–15 декабря 2022 г. С. 28-31.

8. Бельчиков В.А., Борщ С.В., Павроз Ю.А., Романов А.В., Сильницкая М.И., Симонов Ю.А., Христофоров А.В. Современное состояние и перспективы совершенствования системы оперативного гидрологического прогнозирования в Гидрометцентре России // Гидрометеорологические исследования и прогнозы. 2019. №. 4 (374). С. 184-202.

9. Бефани Н.Ф., Калинин Г.П. Упражнения и методические разработки по гидрологическим прогнозам. Л.: Гидрометеоиздат, 1983. 390 с.

10. Василенко А.Н., Агафонова С.А., Фролова Н.Л. Исследования связи термического и ледового режимов рек Российской Арктики по данным многолетних наблюдений // Труды IX Международной научно-практической конференции «Морские исследования и образование (MARESEDU-2020)». Тверь, 2020. Т. 2 (3). С. 98101.

11. Георгиевский Ю.М., Шаночкин С.В. Гидрологические прогнозы. СПб.: РГТМУ, 2007. 436 с.

12. Георгиевский Ю.М. Краткосрочные и долгосрочные прогнозы ледовых явлений на реках, озерах и водохранилищах. Л.: ЛПИ, 1986. 50 с.

13. Крастынь Е.А. и др. Зимний режим приливных устьев рек Терского берега Белого моря // Сборник докладов международной конференции памяти выдающегося русского ученого Юрия Борисовича Виноградова «Четвертые Виноградовские чтения. Гидрология: от познания к мировоззрению». 2020. С. 1092-1097.

14. Ресурсы поверхностных вод СССР. Кольский полуостров Т. 1. Л: Гидрометеиздат, 1966–1970. 316 с.

15. Свидетельство о государственной регистрации базы данных № 2025622437 «Многолетние гидрометеорологические характеристики ледового режима рек и озер Кольского полуострова». Правообладатель: ФГБУ «Государственный гидрологический институт». Авторы: Канашин С.А., Банщикова Л.С. Заявл. 19.05.2025 г., опубл. 03.06.2025 г.

16. Смирнова Д.А. и др. Основные черты зимнего гидрологического режима приливных устьев рек Терского берега Белого моря на примере рек Умба и Кузрека // Труды IX Международной научно-практической конференции «Морские исследования и образование» (MARESEDU-2020). 26-30 октября 2020 г. Том II (III). Тверь: ПолиПРЕСС, 2020. С. 94-97.

17. Фролова Н.Л. и др. Антропогенные и климатически обусловленные изменения стока воды и ледовых явлений рек Российской Арктики // Вопросы географии. 2018. № 145. С. 233-251.

18. Adli Zakaria M.N., Ahmed A.N., Abdul Malek M. et al. Exploring machine learning algorithms for accurate water level forecasting in Muda River, Malaysia. Heliyon. URL: [https://www.cell.com/heliyon/fulltext/S2405-8440\(23\)04897-1?\\_returnURL=https%3A%2F%2Flinkinghub.elsevier.com%2Fretrieve%2Fpii%2FS2405844023048971%3Fshowall%3Dtrue](https://www.cell.com/heliyon/fulltext/S2405-8440(23)04897-1?_returnURL=https%3A%2F%2Flinkinghub.elsevier.com%2Fretrieve%2Fpii%2FS2405844023048971%3Fshowall%3Dtrue)

19. Ayzel G.V. Deep neural networks in hydrology: the new generation of universal and efficient models // Vestnik of Saint Petersburg University. Earth Sciences. 2021. Vol. 66, no. 1. P. 5-18.

20. Chang W., Chen X., He Z., Zhou S.A Prediction Hybrid Framework for Air Quality Integrated with W-BiLSTM(PSO)-GRU and XGBoost Methods // Sustainability, 2023, vol. 15, no 22, pp. 16064. DOI: 10.3390/su152216064.

21. Chen T., Guestrin C. XGBoost: A Scalable Tree Boosting System // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2016. P. 785-794. DOI: 10.1145/2939672.2939785.

22. Fan H., Zhao Y., Liu Z., Li D., Wang B. Flood flow prediction based on combined CNN-GRU-XGBoost model // ResearchGate. 2023. URL: [https://www.researchgate.net/publication/372423866\\_Flood\\_flow\\_prediction\\_based\\_on\\_combined\\_CNN-GRU-XGBoost\\_model](https://www.researchgate.net/publication/372423866_Flood_flow_prediction_based_on_combined_CNN-GRU-XGBoost_model).

23. Madaeni F., Chokmani K., Lhissou R., Homayouni S. et al. Convolutional neural network and long short-term memory models for ice-jam predictions. URL: <https://doi.org/10.5194/tc-16-1447-2022>.

24. Kratzert F., Klotz D., Brenner C., Schulz K., Herrnegger M. Rainfall–runoff modelling using Long Short-Term Memory (LSTM) networks. URL: <https://doi.org/10.5194/hess-22-6005-2018>.

25. Huang X., Zhuang X., Tian F., Niu Z., Chen Y., Zhou Q., Yuan C. A Hybrid ARIMA-LSTM-XGBoost Model with Linear Regression Stacking for Transformer Oil Temperature Prediction // Energies. 2025. Vol. 18, no. 6. P. 1432. <https://doi.org/10.3390/en18061432>

26. Ougahi J.H., Rowan J.S. Enhanced streamflow forecasting using hybrid modelling integrating glacio-hydrological outputs, deep learning and wavelet transformation // Scientific Reports. 2025. Vol. 15. Article 2762. DOI: <https://doi.org/10.1038/s41598-025-87187-1>.

27. Tran T.V., Peche A., Kringel R., Brömme K., Altfelder S. Machine Learning-Based Reconstruction and Prediction of Groundwater Time Series in the Allertal, Germany // *Water*. 2025. Vol. 17, no. 3. P. 433. <https://doi.org/10.3390/w17030433>

28. Wu Y., Ding Y., Feng J. SMOTE-Boost-based sparse Bayesian model for flood prediction // *J. Wireless Com Network*. 2020. Vol. 78. <https://doi.org/10.1186/s13638-020-01689-2>

### References

1. Agafonova S.A., Vasilenko A.N., Mironenko A.A., Frolova N.L. Ledovyj rezhim i ego opasnye projavlenija na rekah Arkticheskoj zony Rossii [Ice regime and its dangerous manifestations on the rivers of the Arctic zone of Russia]. *Ice and thermal processes on water bodies of Russia*. Proceedings of the V All-Russian Conf. Moscow: Publishing house of the Russian State Agrarian University – Moscow, Agricultural Academy named after K.A. Timiryazev, 2016, pp. 15-21 [in Russ.].

2. Agafonova S.A., Frolova N.L., Vasilenko A.N. et al. Ledovyj rezhim i opasnye gidrologicheskie javlenija na rekah Arkticheskoj zony evropejskoj territorii Rossii [Ice regime and dangerous hydrological phenomena on the rivers of the Arctic zone of European Russia]. *Vestnik Moskovskogo universiteta. Seriya 5. Geografiya [Moscow University Bulletin. Series 5. Geography]*, 2016, no. 6, pp. 41-49 [in Russ.].

3. Alekseevsky N.I., Magritsky D.V., Mikhailov V.N. Antropogennye i estestvennye izmenenija gidrologicheskijh ograničenij dlja prirodnopol'zovanija v del'tah rek Rossijskoj Arktiki [Anthropogenic and natural changes in hydrological constraints for nature management in the river deltas of the Russian Arctic]. *Vodnoe hozyaystvo Rossii: problemy, tekhnologii, upravlenie [Water Sector of Russia: problems, technologies, management]*, 2015, no. 1, pp. 14-31 DOI: 10.35567/1999-4508-2015-1-2 [in Russ.].

4. Baklagin V.N. Zavisimosti harakternyh dat ledovogo rezhima Belogo morja ot temperaturnogo fona nad ego akvatoriej [Dependence of characteristic dates of the White Sea ice regime on the temperature background above its water area]. *Uspekhi sovremennogo estestvoznaniya [Advances in modern natural science]*, 2020, no. 7-0, pp. 55-60 [in Russ.].

5. Bانشchikova L.S., Bانشchikov A.A., Sumachev A.E. Rasprostranenie zazorov i zatorov l'da na reke Varzuga [The spread of ice jams and ice dams on the Varzuga River]. *Environmental problems of the northern regions and ways to solve them*. Tezisy dokladov VII Vserossijskoj nauchnoj konferencii s mezhdunarodnym uchastiem, posvjashhennoj 30-letiju Instituta problem promyshlennoj jekologii Severa FIC KNC RAN i 75-letiju so dnja rozhdenija doktora biologicheskijh nauk, professora V.V. Nikonova, 2019, pp. 102-104 [in Russ.].

6. Bانشchikova L.S., Sumachev A.E. Variacija temperatury vozduha holodnogo perioda na Kol'skom poluostrove kak faktor izmenenija ledovogo rezhima [Variation of air temperature during the cold period on the Kola Peninsula as a factor in changing the ice regime]. *Arktika: ekologiya i ekonomika [Arctic: ecology and economy]*, 2021, vol. 11, no. 3, pp. 397-405 [in Russ.].

7. Bانشchikova L.S., Sumachev A.E., Biryukova V.A., Kanashin S.A. Ledovyj rezhim reki Varzuga. Ocenka ih riska i negativnyh posledstvij [Ice regime of the Varzuga River. Assessment of their risk and negative consequences]. VI All-Russian Conference with international participation "Hydrometeorology and Ecology" / MGO 2022, Saint Petersburg, December 14–15, 2022, pp. 28-31 [in Russ.].

8. Belchikov V.A., Borsch S.V., Pavroz Yu.A., Romanov A.V., Silnitskaya M.I., Simonov Yu.A., Khristoforov A.V. Sovremennoe sostojanie i perspektivy sovershenstvovanija sistemy operativnogo gidrologicheskogo prognozirovanija v Gidrometcentre Rossii [Current state and prospects for improving the operational hydrological forecasting system in the Hydrometeorological Center of Russia]. *Gidrometeorologicheskie issledovaniya i prognozy [Hydrometeorological Research and Forecasting]*, 2019, vol. 74, no. 4, pp. 184-202 [in Russ.].

9. Befani N.F., Kalinin G.P. Uprazhnenija i metodicheskie razrabotki po gidrologicheskim prognozam [Exercises and methodological developments on hydrological forecasts]. Leningrad, Gidrometeoizdat Publ., 1983. 390 p. [in Russ.].

10. Vasilenko A.N., Agafonova S.A., Frolova N.L. Issledovaniya svjazi termicheskogo i ledovogo rezhimov rek Rossijskoj Arktiki po dannym mnogoletnijh nabljudenij [Studies of the rela-

tionship between thermal and ice regimes of rivers in the Russian Arctic based on long-term observations]. Proceedings of the IX International Scientific and Practical Conference "Marine Research and Education (MARESEDU-2020)". Tver, 2020, vol. 2 (3), pp. 98-101 [in Russ.].

11. *Georgievskiy Yu.M., Shanochkin S.V.* Hidrologicheskie prognozy [Hydrological forecasts]. Saint Petersburg, RSHU Publ., 2007, 436 p. [in Russ.].

12. *Georgievskiy Yu.M.* Kratkosrochnye i dolgosrochnye prognozy ledovyh javlenij na rekah, ozerah i vodohranilishhah [Short-term and long-term forecasts of ice phenomena on rivers, lakes and reservoirs]. Leningrad, LPI Publ., 1986, 50 p [in Russ.].

13. *Krastyn E.A. et al.* Zimnij rezhim prilivnyh ust'ev rek Terskogo berega Belogo morja [Winter regime of tidal estuaries of the rivers of the Tersky coast of the White Sea]. Sbornik dokladov mezhdunarodnoj nauchnoj konferencii pamjati vydajushhegosja russkogo uchenogo Jurija Borisovicha Vinogradova «Chetvertye Vinogradovskie chtenija. Hidrologija: ot poznaniya k mirovozzreniju», 2020, pp. 1092-1097 [in Russ.].

14. Resursy poverhnostnyh vod SSSR. Kol'skij poluostrov. T. 1 [Surface Water Resources of the USSR. Kola Peninsula. Vol. 1]. Leningrad, Gidrometeoizdat Publ., 1966-1970, 316 p. [in Russ.].

15. Svidetel'stvo o gosudarstvennoj registracii bazy dannyh № 2025622437 «Mnogoletnie gidrometeorologicheskie harakteristiki ledovogo rezhima rek i ozer Kol'skogo poluostrova» Certificate of state registration of database No. 2025622437 "Long-term hydrometeorological characteristics of the ice regime of rivers and lakes of the Kola Peninsula". Copyright holder: Federal State Budgetary Institution "State Hydrological Institute". Authors: Kanashin S.A., Banshchikova L.S, declared 19.05.2025, published 03.06.2025 [in Russ.].

16. *Smirnova D.A. et al.* Osnovnye cherty zimnego gidrologicheskogo rezhima prilivnyh ust'ev rek Terskogo berega Belogo morja na primere rek Umba i Kuzreka [Main features of the winter hydrological regime of tidal estuaries of the rivers of the Tersky coast of the White Sea on the example of the Umba and Kuzreka rivers]. Proceedings of the IX International Scientific and Practical Conference "Marine Research and Education (MARESEDU-2020)". Tver, 2020, vol. 2 (3), pp. 98-101[in Russ.].

17. *Frolova N.L. et al.* Antropogennye i klimaticheski obuslovlennye izmenenija stoka vody i ledovyh javlenij rek Rossijskoj Arktiki [Anthropogenic and climate-induced changes in water runoff and ice phenomena of rivers in the Russian Arctic]. *Voprosy geografii [Questions of geography]*, 2018, no. 145, pp. 233-251 [in Russ.].

18. *Adli Zakaria M.N., Ahmed A.N., Abdul Malek M. et al.* Exploring machine learning algorithms for accurate water level forecasting in Muda River, Malaysia. *Heliyon*. URL: [https://www.cell.com/heliyon/fulltext/S2405-8440\(23\)04897-1?\\_returnURL=https%3A%2F%2Flinkinghub.elsevier.com%2Fretrieve%2Fpii%2FS2405844023048971%3Fshowall%3Dtrue](https://www.cell.com/heliyon/fulltext/S2405-8440(23)04897-1?_returnURL=https%3A%2F%2Flinkinghub.elsevier.com%2Fretrieve%2Fpii%2FS2405844023048971%3Fshowall%3Dtrue)

19. *Ayzel G.V.* Deep neural networks in hydrology: the new generation of universal and efficient models. *Vestnik of Saint Petersburg University. Earth Sciences*, 2021, vol. 66, no. 1, pp. 5-18.

20. *Chang W., Chen X., He Z., Zhou S.* A Prediction Hybrid Framework for Air Quality Integrated with W-BiLSTM(PSO)-GRU and XGBoost Methods. *Sustainability*, 2023, vol. 15, no 22, pp. 16064. DOI: 10.3390/su152216064.

21. *Chen T., Guestrin C.* XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2016, pp. 785-794. DOI: 10.1145/2939672.2939785.

22. *Fan H., Zhao Y., Liu Z., Li D., Wang B.* Flood flow prediction based on combined CNN-GRU-XGBoost model. *ResearchGate*. 2023. URL: [https://www.researchgate.net/publication/372423866\\_Flood\\_flow\\_prediction\\_based\\_on\\_combined\\_CNN-GRU-XGBoost\\_model](https://www.researchgate.net/publication/372423866_Flood_flow_prediction_based_on_combined_CNN-GRU-XGBoost_model).

23. *Madaeni F., Chokmani K., Lhissou R., Homayouni S. et al.* Convolutional neural network and long short-term memory models for ice-jam predictions. URL: <https://doi.org/10.5194/tc-16-1447-2022>.

24. Kratzert F., Klotz D., Brenner C., Schulz K., Herrnegger M. Rainfall–runoff modelling using Long Short-Term Memory (LSTM) networks. URL: <https://doi.org/10.5194/hess-22-6005-2018>.
25. Huang X., Zhuang X., Tian F., Niu Z., Chen Y., Zhou Q., Yuan C. A Hybrid ARIMA-LSTM-XGBoost Model with Linear Regression Stacking for Transformer Oil Temperature Prediction. *Energies*, 2025, vol. 18, no. 6, pp. 1432. <https://doi.org/10.3390/en18061432>
26. Ougahi J.H., Rowan J.S. Enhanced streamflow forecasting using hybrid modelling integrating glacio-hydrological outputs, deep learning and wavelet transformation. *Scientific Reports*, 2025, vol. 15, article 2762. DOI: <https://doi.org/10.1038/s41598-025-87187-1>.
27. Tran T.V., Peche A., Kringel R., Brömme K., Altfelder S. Machine Learning-Based Reconstruction and Prediction of Groundwater Time Series in the Allertal, Germany. *Water*, 2025, vol. 17, no. 3, pp. 433. <https://doi.org/10.3390/w17030433>
28. Wu Y., Ding Y., Feng J. SMOTE-Boost-based sparse Bayesian model for flood prediction. *J. Wireless Com Network*, 2020, vol. 78. <https://doi.org/10.1186/s13638-020-01689-2>

Поступила 15.10.2025; принята в печать 17.03.2026.  
Submitted 15.10.2025; accepted for publication 17.03.2026.