



Серия «Науки о Земле»

2025. Т. 52. С. 52–64

Онлайн-доступ к журналу:

<http://izvestiageo.isu.ru/ru>

ИЗВЕСТИЯ

Иркутского

государственного

университета

Научная статья

УДК 556.06(470.21)

<https://doi.org/10.26516/2073-3402.2025.52.52>

## Применение методов машинного обучения для прогноза осенних ледовых явлений на реке Умба

С. А. Канашин\*

*Государственный гидрологический институт, г. Санкт-Петербург, Россия*

**Аннотация.** Целью работы является разработка методов прогноза сроков появления первичных ледовых явлений и установления ледостава с использованием машинного и глубокого обучения в рамках совершенствования существующих методов прогноза дат появления осенних ледовых явлений на реках Кольского полуострова в условиях современного изменения климата. В качестве объекта изучения выбрана р. Умба. Были использованы данные по гидрологическим постам порог Паялка, Исток и метеорологической станции Умбы. Выполнен анализ ледового режима р. Умбы и многолетней изменчивости сроков появления осенних ледовых явлений, сумм отрицательных температур воздуха. Выявлены основные предикторы и проведена классификация ледовых явлений для задания целевой переменной в нейросетевые модели. Приводится сравнение прогнозных значений, полученных с помощью автоматизированной библиотеки AutoKeras и гибридного подхода XGBoost + LSTM, объединяющего методы машинного и глубокого обучения. Погрешность прогноза с использованием гибридного подхода не превышает допустимую. С учетом имеющихся данных о ледовом и водном режимах, изменении метеорологических характеристик предложенный подход позволяет улучшить прогностические зависимости, разработанные для рек Кольского полуострова в середине XX в.

**Ключевые слова:** Кольский полуостров, ледовый режим, прогноз сроков замерзания, машинное обучение, глубокое обучение, нейронные сети.

**Для цитирования:** Канашин С. А. Применение методов машинного обучения для прогноза осенних ледовых явлений на реке Умба // Известия Иркутского государственного университета. Серия Науки о Земле. 2025. Т. 52. С. 52–64. <https://doi.org/10.26516/2073-3402.2025.52.52>

Original article

## Application of Machine Learning Methods to Forecast Autumn Ice Phenomena on the Uмба River

S. A. Kanashin\*

*State Hydrological Institute, Saint-Petersburg, Russian Federation*

**Abstract.** The aim of the work is to develop methods for forecasting the timing of the appearance of primary ice phenomena and the establishment of freeze-up using machine and deep learning methods in the context of improving the existing methods for forecasting the dates of autumn ice phenomena on the rivers of the Kola Peninsula under modern climate change. The Uмба River was chosen as the object of study. The work used data from the Payalka and Istok hydrological posts and the Uмба meteorological station. An analysis of the ice regime of the Uмба River and long-term variability in

© Канашин С. А., 2025

\* Полные сведения об авторе см. на последней странице статьи.  
For complete information about the author, see the last page of the article.

the timing of the appearance of autumn ice phenomena, the sum of negative air temperatures was performed. The main predictors were identified and the classification of ice phenomena was carried out to set the target variable in neural network models. A comparison of the forecast values obtained using the AutoKeras automated library and the XGBoost + LSTM hybrid approach, which combines machine and deep learning methods, is given. The forecast error using the hybrid approach does not exceed the permissible one. Taking into account the available data on ice and water regimes and changes in meteorological characteristics, the proposed approach allows us to improve the forecast dependencies developed for the rivers of the Kola Peninsula in the mid-20th century.

**Keywords:** Kola Peninsula, ice regime, freezing time forecast, machine learning, deep learning, neural networks.

---

**For citation:** Kanashin S.A. Application of Machine Learning Methods to Forecast Autumn Ice Phenomena on the Umba River. *The Bulletin of Irkutsk State University. Series Earth Sciences*, 2025, vol. 52, pp. 52–64. <https://doi.org/10.26516/2073-3402.2025.52.52> (in Russian)

---

## Введение

Ледовый режим рек, озер и водохранилищ оказывает значительное влияние на характер эксплуатации гидротехнических сооружений, водный транспорт, сроки использования ледовых переправ, а также прокладку нефте- и газопроводов [Георгиевский, Шаночкин, 2007].

Закономерности условий формирования ледовых явлений на реках Кольского полуострова рассмотрены в работах [Алексеевский, Магрицкий, Михайлов, 2015; Антропогенные и климатически ... , 2018; Баклагин, 2020; Василенко, Агафонова, Фролова, 2020; Зимний режим приливных ... , 2020; Ледовый режим и его опасные ... , 2016; Основные черты зимнего ... , 2020].

Устойчивые ледовые образования на Умбе появляются во второй декаде октября в виде шугохода и ледохода различной густоты, заберегов. Переходный период от начала первичных ледовых явлений до образования устойчивого ледостава достаточно длительный – до двух недель. Повышенная шугоносность рек и образование мощных зажоров объясняется озерным регулированием и большими уклонами местности.

Отсутствие значимых трендов к смещению сроков образования ледовых явлений и ледостава на р. Умбе связано как с озерным регулированием, шугообразованием, так и с относительно небольшими (по модулю) отрицательными температурами воздуха для образования устойчивого ледостава [Банщикова, Сумачев, 2021], устанавливающегося, как правило, в конце октября – первой половине ноября, а на порожистых участках и ниже – в истоке реки, где сказывается влияние Белого моря, образуется значительно позже или не образуется вовсе.

В связи с изменением характеристик ледового режима, включая сроки появления ледовых явлений и установления ледостава [Антропогенные и климатически ... , 2018; Ледовый режим и опасные ... , 2016], существующие методики их прогноза требуют уточнения.

Систематический выпуск прогнозов сроков появления ледовых явлений в России начался в 1940-х гг., и к настоящему времени в этой области достигнуты значительные результаты. Краткосрочные прогнозы ледовых явлений основываются не только на физико-статистических зависимостях, но и на строгих методах, использующих уравнение теплового баланса. Долгосрочные прогнозы ледовых явлений базируются на учете закономерностей

развития атмосферных процессов и преемственности их изменения в течение последующего периода времени [Георгиевский, 1986]. Однако многие методики, разработанные в середине XX в., требуют актуализации и уточнения с учетом современных условий.

За последние десять лет глубокое обучение – направление машинного обучения, использующее многослойные искусственные нейронные сети (ИНС) – существенно трансформировало подход к построению статистических моделей в различных областях. Этот метод активно применяется в задачах обработки изображений, машинного перевода, распознавания речи и многих других сферах. Не остаются в стороне и науки о Земле, включая гидрологию, где глубокое обучение находит все большее применение.

Преимущество глубоких нейронных сетей заключается в их высокой универсальности и эффективности. Благодаря этим качествам, а также стремительному увеличению объемов данных об окружающей среде и расширению доступа к вычислительным ресурсам, глубокие нейросети становятся новым поколением математических моделей. Они способны не только дополнить, но и потенциально заменить существующие методы моделирования геофизических процессов [Auzel, 2021].

Целью работы является разработка методики прогнозирования сроков появления льда и установления ледостава с использованием нейронной сети, основанной на методах глубокого обучения, для рек Кольского полуострова.

### **Материалы и методы**

В качестве объекта исследования выбрана р. Умба, протекающая в южной части Кольского полуострова, относящаяся к бассейну Белого моря. Умба относится к озерному типу рек, которые отличаются большой водностью. Характеризуется высокой порожистостью, чередованием плесов и перекатов.

Метеорологические данные получены с метеорологической станции в пос. Умба. В качестве предикторов прогностической зависимости были выбраны суточные данные: даты наступления ледового явления, тип ледового явления, накопленная сумма отрицательных температур воздуха (м/с Умба), накопленная сумма осадков, уровень воды, ледовые явления (р. Умба – Исток (пост расположен в 500 м от истока реки из оз. Умбозеро, в 123 км от устья) и р. Умба – порог Паялка (пост расположен в 1 км от пос. Умба, непосредственно выше порога, в 3,7 км от устья)) (рис. 1).

Для разработки методики прогнозирования сроков появления ледовых явлений и ледостава для р. Умбы была собрана база данных гидрологических и метеорологических характеристик за период с 1953 по 2020 г. с 1 октября по 31 января соответствующего водохозяйственного года. Выбор такого временного промежутка продиктован наиболее ранним началом перехода температуры воздуха через 0 °С и наиболее поздней датой формирования ледостава.

Ледовый режим реки характеризуется появлением первичных ледовых явлений во второй половине октября. Ледоход (шугоход) имеет место не каждый год, продолжительность его составляет около 5–10 дней.

Анализ исходных данных выявил тренд на более позднее появление первичных ледовых явлений начиная с 1980-х гг., что вызвано в первую очередь влиянием климатических изменений холодного периода (рис. 2).



Рис. 1. Посты наблюдений на р. Умбе

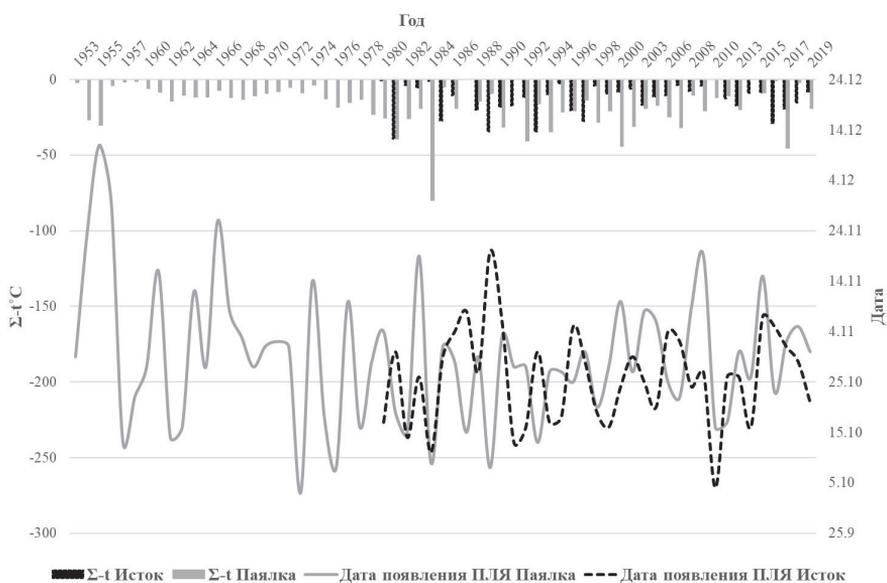


Рис. 2. Комплексный график изменения сроков появления льда на р. Умбе и накопленной суммы отрицательной температуры воздуха до появления первичных ледовых явлений

Анализ данных о сроках появления ледовых явлений на р. Умба не выявил значимой корреляционной связи между постами ( $r = 0,43$ ), поэтому методика прогноза дат появления ледовых явлений и ледостава с использованием ИНС была разработана и для поста р. Умба – порог Паялка, и для поста р. Умба – Исток

Нейронные сети были разработаны на языке программирования Python. Первая попытка создания нейронной сети была выполнена с использованием библиотеки AutoKeras – мощного инструмента автоматического машинного обучения (AutoML). AutoKeras значительно упрощает процесс создания, обучения и оптимизации нейросетей, автоматизируя подбор их структуры и гиперпараметров, в основе работы лежит метод поиска архитектуры нейронных сетей (Neural Architecture Search, NAS), который перебирает различные конфигурации и находит наиболее эффективную для решения конкретной задачи. Одним из ключевых преимуществ AutoKeras является автоматическая настройка таких параметров, как тип модели, количество слоев и нейронов в каждом из них, функции активации, а также гиперпараметры обучения. Благодаря этому пользователи даже с минимальным опытом в машинном обучении могут разрабатывать эффективные нейросетевые модели без глубокого понимания их внутреннего устройства. Модели, полученные с AutoKeras, наиболее подходят для первичного анализа модели, выявления слабых мест в данных и архитектуре модели.

Вторая нейронная сеть была создана гибридным способом с использованием алгоритмов классического машинного обучения и методов глубокого обучения. Так как основная задача сводилась к классификации классов ледовых явлений, было использовано сочетание XGBoost и LSTM. Применение моделей на основе XGBoost и LSTM в гидрологических задачах успешно зарекомендовало себя в ряде зарубежных исследований [Deep learning ... , 2019; Król, Banasik, 2022; Rainfall-runoff modelling ... , 2019; Ougahi, Rowan, 2025; Shen, 2018; Sit, Demir, 2019; What role does ... , 2021]. Подобные архитектуры позволяют учитывать сложные временные зависимости и пространственную изменчивость гидрологических процессов. В основе XGboost лежит алгоритм градиентного бустинга деревьев решений. Градиентный бустинг – это техника машинного обучения, которая строит предсказания в форме ансамбля слабых предсказывающих моделей, обычно деревьев решений. Предсказания от XGBoost передаются в алгоритм глубокого обучения LSTM (long-short term memory), который позволяет анализировать временные ряды, запоминать последовательность данных, анализируя динамику изменения предикторов и целевой переменной во времени. Для учета временных зависимостей для предикторов были рассчитаны «лаги» – задержки во временном ряду, которые показывают значения предикторов на несколько дней назад (рис. 3).

На вход нейронная сеть получает следующие данные:

- дата за период с 1 октября по 31 января каждого гидрологического года с 1936 по 2019 г.;

- накопленная сумма отрицательных температур воздуха за каждую дату соответствующего периода;
- накопленная сумма осадков за каждую дату соответствующего периода;
- уровень воды за соответствующую дату;
- данные о ледовой обстановке за соответствующую дату.

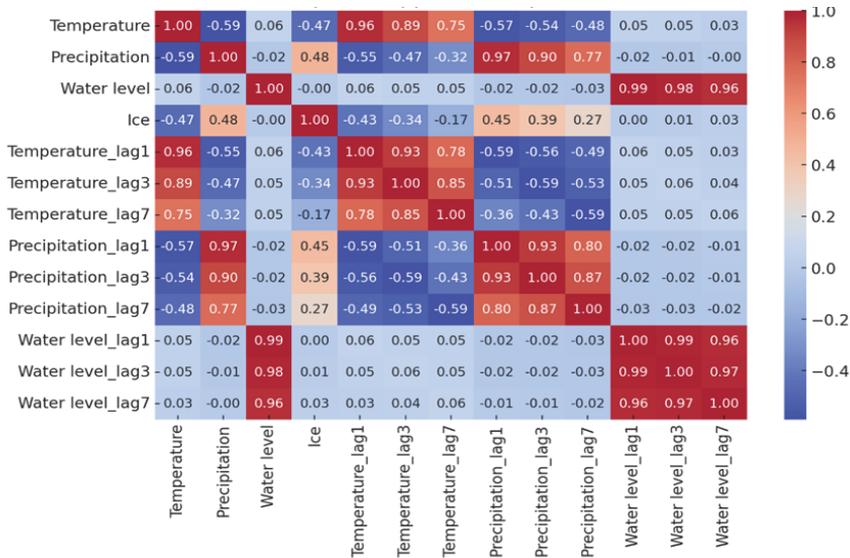


Рис. 3. Корреляционная матрица предикторов нейросетевой модели типа XGBoost + LSTM

Целевой переменной модели являются характеристики ледового явления: появление первичных ледовых явлений, установление ледостава и отсутствие ледовых явлений на интересующую дату.

### Обсуждение результатов

Основным предиктором для прогноза сроков появления первичных ледовых явлений и установления ледостава является накопленная сумма отрицательных температур воздуха. Для периода замерзания характерно ее уменьшение, что приводит к установлению неполного ледостава. Существенное влияние на формирование ледовых явлений оказывают атмосферные осадки. Увеличение их количества в период становления ледостава способствует образованию снегуры и шуги, что изменяет тип и сроки формирования ледового покрова [Банщикова, Сумачев, 2021].

Для разработки метода прогноза сроков появления первичных ледовых явлений и ледостава обучение модели 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.

Оценка качества моделей классификации является важнейшей частью процесса построения и валидации систем машинного обучения (табл. 1). Особенно это актуально в задачах с дисбалансом классов, где общая точность (accuracy) может вводить в заблуждение. Наиболее распространенные метрики в таких условиях – это точность (precision), полнота (recall) и F1-score, предложенные еще в рамках информационного поиска [van Rijsbergen, 1979].

Таблица 1

Оценка работы нейронных сетей для прогноза дат появления льда

Модель	Recall	Precision	F1-score
XGBoost + LSTM	0,69	0,64	0,66
AutoKeras	0,21	0,37	0,27

Пусть модель классифицирует объекты на два класса: положительный и отрицательный:

- TP (True Positive): число объектов положительного класса, правильно классифицированных как положительные;
- FP (False Positive): число объектов отрицательного класса, ошибочно классифицированных как положительные;
- FN (False Negative): число объектов положительного класса, ошибочно классифицированных как отрицательные.

Recall (полнота) отражает способность модели выявлять все положительные случаи. Высокая полнота означает, что модель редко пропускает важные события [Powers, 2007]. Precision (точность) показывает, какая доля предсказанных положительных случаев действительно относится к положительному классу. Высокая точность означает, что модель дает мало ложных срабатываний [Manning, Raghavan, Schütze, 2008]. F1-score – гармоническое среднее между точностью и полнотой. Применяется, когда необходимо найти баланс между этими двумя метриками [Sokolova, Lapalme, 2009].

Для прогноза дат появления льда с использованием библиотеки AutoKeras были использованы дополнительные климатические параметры: облачность, направление ветра, скорость ветра, температура почвы, атмосферное давление (рис. 4).

Прогноз сроков установления ледостава с использованием дополнительных климатических параметров для обоих постов на р. Умбе не дал хорошего результата, поэтому обучение нейронной сети проводилось с использованием основных предикторов (рис. 5).

Далее AutoKeras автоматически подобрала модель, состоящую из трех скрытых слоев Dense. Такая архитектура представляет собой обычную многослойную нейросеть (MLP), где каждый слой связан со всеми нейронами предыдущего. Она хорошо подходит для табличных данных, но не учитывает временную зависимость. Гибридный подход помимо XGBoost включает в себя два слоя GRU (упрощенная версия LSTM), слой Conv1D (выделяет локальные временные паттерны) и алгоритм SMOTE. Данный алгоритм гене-

рирует искусственные примеры малочисленных классов и помогает решить проблему несбалансированных данных (см. табл. 1). К таким классам можно отнести первичные ледовые явления из-за их малого числа относительно примеров других классов (ледостава и отсутствия льда).

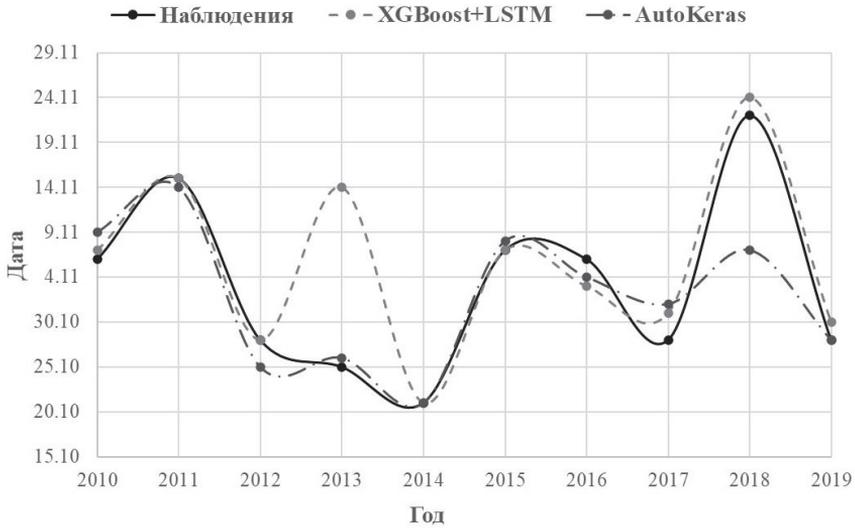


Рис. 4. Прогноз первичных ледовых явлений на посту р. Умба – порог Паялка

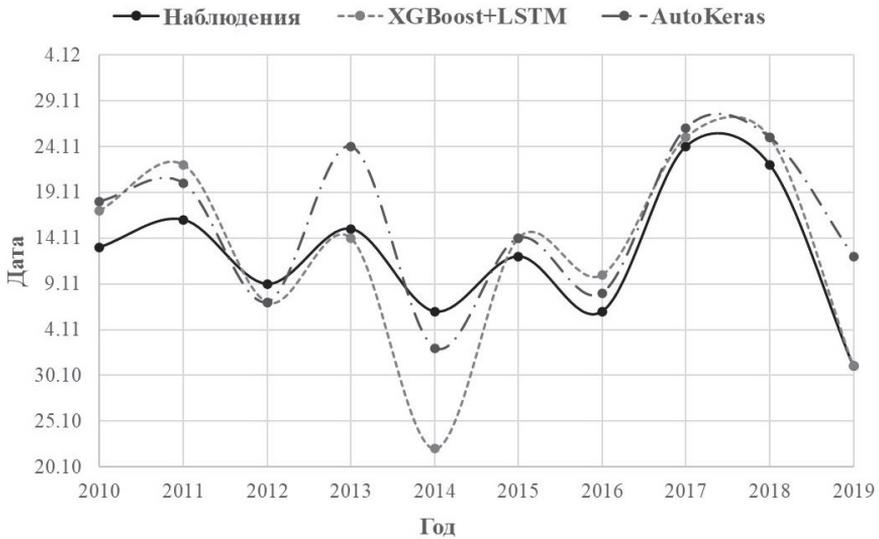


Рис. 5. Прогноз дат установления ледостава на посту р. Умба – порог Паялка

Как показано в табл. 2 и на рис. 4 и 5, использование библиотеки AutoKeras обеспечивает удовлетворительные прогнозы сроков появления первичных ледовых явлений и установления ледостава. Однако для повышения точности прогнозирования недостаточно простого решения задачи классификации. Необходим учет изменения предикторов и целевой переменной во времени, анализ взаимосвязи предикторов между собой и с целевой переменной, ввод дополнительных классов и признаков. Идея LSTM состоит в том, чтобы позволить каждому шагу RNN выбирать информацию для просмотра из некоторого более крупного набора информации. Основная проблема стандартных RNN заключается в затухании градиента, что затрудняет обучение моделей на длинных последовательностях. Благодаря своей архитектуре сочетание XGBoost и LSTM помогают решить эту проблему. Как правило, классифицированные ряды достаточно несбалансированны из-за учета поздних дат установления ледостава. Для настройки модели и учета наименьших классов (первичные ледовые явления) стоит использовать метод SMOTE (Synthetic Minority Over-sampling Technique), который позволяет добавить данные наименьших классов с помощью метода ближайшего соседа. Кроме того, в некоторых случаях увеличение числа классов, например, вводом класса для неустойчивого ледостава, может дать улучшенные результаты из-за ручной балансировки классов. В качестве альтернативы для решения проблемы несбалансированных классов ледовых явлений можно применить метод ASADYN (Adaptive Synthetic Data Generation). Основное отличие от SMOTE заключается в неравномерном распределении искусственных примеров класса.

Таблица 2

Результаты работы модели на независимых данных поста р. Умба – порог Паялка

Год	Первичные ледовые явления			Ледостав		
	Наблюдения	XGBoost + LSTM	AutoKeras	Наблюдения	XGBoost + LSTM	AutoKeras
2010	6.11	7.11	9.11	13.11	17.11	18.11
2011	15.11	15.11	14.11	16.11	22.11	20.11
2012	28.10	28.10	25.10	9.11	7.11	7.11
2013	25.10	14.11	26.10	15.11	14.11	24.11
2014	21.10	21.10	21.10	6.11	22.10	2.11
2015	7.11	7.11	8.11	12.11	14.11	14.11
2016	6.11	3.11	4.11	6.11	10.11	8.11
2017	28.10	31.10	1.11	24.11	25.11	26.11
2018	22.11	24.11	7.11	22.11	25.11	25.11
2019	28.10	30.10	28.10	31.10	31.10	12.11

## Выводы

Ледовый режим реки характеризуется появлением первичных ледовых явлений (забереги, шугоход) во второй половине октября. Ледостав, как правило, устанавливается в конце октября – первой половине ноября, на порожистых участках и в истоке реки значительно позже. Устойчивый ледостав вовсе может не образоваться.

Анализ исходных данных выявил тренд на позднее появление первичных ледовых явлений начиная с 1980-х гг., что вызвано в первую очередь влиянием климатических изменений холодного периода.

Разработанная для р. Умбы методика прогнозирования сроков появления льда и установления ледостава с использованием нейронной сети с использованием библиотеки AutoKeras с основными предикторами (накопленная сумма отрицательных температур воздуха за каждую дату соответствующего периода; накопленная сумма осадков за каждую дату соответствующего периода; уровень воды за соответствующую дату и данные о ледовой обстановке за соответствующую дату) показывает следующие результаты оценки точности прогноза: отношение среднеквадратичной ошибки прогноза к стандартному отклонению прогнозируемой величины составляет  $S/\sigma = 0,67$  для дат появления льда и установления ледостава. Средняя заблаговременность прогноза – 4 дня. Для гибридной нейросетевой модели отношение  $S/\sigma$  составило 0,65 и 0,51 для дат появления льда и установления льда соответственно. Заблаговременность прогноза модели XGBoost + LSTM составила 3,5 дня. Метод прогноза с помощью гибридной нейронной сети можно считать приемлемым, так как погрешность проверочного прогноза в 85 % не превышает допустимую погрешность (для осенних ледовых явлений – 4 сут.)

Вклад дополнительных предикторов: облачность, направление ветра, скорость ветра, температура почвы, атмосферное давление существенно не улучшают результат.

Таким образом, используя продолжительные ряды наблюдений за гидрологическими и метеорологическими характеристиками, применение нейронных сетей позволяет существенно улучшить существующие методики прогнозирования параметров ледового режима рек Кольского полуострова. Возможность использования большого числа предикторов позволяет строить уникальные прогностические зависимости различных типов замерзания рек, учитывать естественную и искусственную зарегулированность водотоков, морфологические особенности русел, климатические изменения и др.

Использование простых архитектур благодаря своей простоте и небольшой требовательности к вычислительным мощностям позволяет выполнить анализ исходных данных, выполнить предварительный прогноз. Более сложные архитектуры позволяют учитывать временные зависимости, несбалансировку данных, при целесообразности могут искусственно увеличить количество предикторов, что повышает качество прогностической модели.

### Список литературы

*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.

Антропогенные и климатически обусловленные изменения стока воды и ледовых явлений рек Российской Арктики / Н. Л. Фролова, Д. В. Магрицкий, М. Б. Киреева [и др.] // Вопросы географии. 2018. № 145. С. 233–251.

*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.

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

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)»: [сборник]. Тверь, 2020. Т. 2 (3). С. 98–101.

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

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

Зимний режим приливных устьев рек Терского берега Белого моря / Е. А. Крастынь, М. О. Фатхи, Е. Д. Панченко [и др.] // Четвертые Виноградовские чтения. Гидрология от познания к мировоззрению. СПб., 2020. С. 1092–1097.

Ледовый режим и его опасные проявления на реках Арктической зоны России / С. А. Агафонова, А. Н. Василенко, А. А. Мироненко [и др.] // Труды V Всероссийской конференции «Ледовые и термические процессы на водных объектах России». М.: РГАУ – МСХА им. К. А. Тимирязева, 2016. С. 15–21.

Ледовый режим и опасные гидрологические явления на реках арктической зоны европейской территории России / С. А. Агафонова, Н. Л. Фролова, А. Н. Василенко [и др.] // Вестник Московского университета. Серия 5, География. 2016. № 6. С. 41–49.

Основные черты зимнего гидрологического режима приливных устьев рек Терского берега Белого моря на примере рек Умба и Кузерка / Д. А. Смирнова, А. А. Шишов, А. Н. Василенко [и др.] // Труды IX Международной научно-практической конференции «Морские исследования и образование (MARESEDU-2020)». Тверь, 2020. Т. 1 (3). С. 94–97.

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, N 1. P. 5–18. <https://doi.org/10.21638/spbu07.2021.101>

Deep learning and process understanding for data-driven Earth system science / M. Reichstein, G. Camps-Valls, B. Stevens [et al.] // Nature. 2019. Vol. 566. P. 195–204. <https://doi.org/10.1038/s41586-019-0912-1>

Król A., Banasik K. Predicting Ice Phenomena in a River Using the Artificial Neural Network and Extreme Gradient Boosting // Resources. 2022. Vol. 11, N 2. P. 12. <https://doi.org/10.3390/resources11020012>

Manning C. D., Raghavan P., Schütze H. Introduction to Information Retrieval. Cambridge University Press, Stanford NLP book, 2008. 544 p. URL: <https://nlp.stanford.edu/IR-book/> (date of access: 22.04.2025)

Powers D. M. W. Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness and Correlation // Technical Report SIE-07-001. 2007. 24 p. URL: [https://www.researchgate.net/publication/228529307\\_Evaluation\\_From\\_Precision\\_Recall\\_and\\_F-Factor\\_to\\_ROC\\_Informedness\\_Markedness\\_Correlation](https://www.researchgate.net/publication/228529307_Evaluation_From_Precision_Recall_and_F-Factor_to_ROC_Informedness_Markedness_Correlation) (date of access: 22.04.2025).

Rainfall-runoff modelling using Long Short-Term Memory (LSTM) networks / F. Kratzert, D. Klotz, C. Brenner [et al.] // Hydrology and Earth System Sciences. 2019. Vol. 23, N 10. P. 5089–5110. <https://doi.org/10.5194/hess-23-5089-2019>

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. Art. N 2762. <https://doi.org/10.1038/s41598-025-87187-1>

Shen C. A. Transdisciplinary Review of Deep Learning Research and Its Relevance for Water Resources Scientists // Water Resources Research. 2018. Vol. 54, N 11. P. 8558–8593. <https://doi.org/10.1029/2018WR022643>

Sit M., Demir I. Distributed deep learning model for flood prediction // Journal of Hydrology. 2019. Vol. 570. P. 524–534. <https://doi.org/10.1016/j.jhydrol.2018.12.045>

Sokolova M., Lapalme G. A systematic analysis of performance measures for classification tasks // Information Processing & Management. 2009. Vol. 45, N 4. P. 427–437. <https://doi.org/10.1016/j.ipm.2009.03.002>

van Rijsbergen C. J. Information Retrieval. London : Butterworths, 1979. 208 p.

What role does hydrological science play in the age of machine learning / G. S. Nearing, A. K. Sampson, F. Kratzert [et al.] // Water Resources Research. 2021. Vol. 57, N 3. Article e2020WR028091. <https://doi.org/10.1029/2020WR028091>

## References

Alekseevskii N.I., Magritskii D.V., Mikhailov V.N. Antropogennye i estestvennye izmeneniya gidrologicheskikh ogranichenii dlya prirodopol'zovaniya v del'takh rek Rossiiskoi Arktiki [Anthropogenic and natural changes in hydrological restrictions for nature management in the deltas of rivers in the Russian Arctic]. *Vodnoe khozyaistvo Rossii: problemy, tekhnologii, upravlenie* [Water management in Russia: problems, technologies, management], 2015, no. 1. pp. 14-31. (in Russian).

Frolova N.L., Magritsky D.V., Kireeva M.B. et al. Antropogennye i klimaticheski obuslovlennyye izmeneniya stoka vody i ledovykh yavlenii rek Rossiiskoi Arktiki [Anthropogenic and climate-induced changes in water runoff and ice phenomena in rivers of the Russian Arctic]. *Voprosy geografii* [Geography Questions], 2018, no. 145, pp. 233-251. (in Russian)

Baklagin V.N. Zavisimosti kharakternykh dat ledovogo rezhima Belogo morya ot temperaturnogo fona nad ego akvatoriei [Dependences of characteristic dates of the White Sea ice regime on the temperature background above its water area]. *Uspekhi sovremenogo estestvoznaniya* [Achievements of modern natural science], 2020, no. 7-0, pp. 55-60. (in Russian)

Banshchikova L.S., Sumachev A.E. Variatsiya temperatury vozdukh kholodnogo perioda na Kolskom poluostrove kak faktor izmeneniya 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 economics], 2021, vol. 11, no. 3. pp. 397-405. (in Russian)

Vasilenko A.N., Agafonova S.A., Frolova N.L. Issledovaniya svyazi termicheskogo i ledovogo rezhimov rek Rossiiskoi Arktiki po dannym mnogoletnikh nablyudeni [Research of the relationship between thermal and ice regimes of rivers in the Russian Arctic based on long-term observations]. *Trudy IX Mezhdunarodnoi nauchno-prakticheskoi konferentsii "Morskie issledovaniya i obrazovanie (MARESEDU-2020)"* [Proceedings of the IX International scientific and practical conference "Marine research and education (MARESEDU-2020)"], Tver, 2020, vol. 2(3), pp. 98-101. (in Russian)

Georgievskii Yu.M. Kratkosrochnyye i dolgosrochnyye prognozy ledovykh yavlenii na rekakh, ozerakh i vodokhranilishchakh [Short-term and long-term forecasts of ice phenomena on rivers, lakes and reservoirs]. Leningrad, LPI Publ., 1986. 50 p. (in Russian)

Georgievskii Yu.M., Shanochkin S.V. *Gidrologicheskie prognozy* [Hydrological forecasts. St. Petersburg, RSHU Publ., 2007, 436 p. (in Russian)

Krastyn E.A., Fathi M.O., Panchenko E.D. et al. Zimniy rezhim prilivnykh ust'ev rek Terskogo berega Belogo morya [Winter regime of tidal estuaries of the rivers of the Tersky coast of the White Sea]. *Chetvertye Vinogradovskie chteniya. Gidrologiya ot poznaniya k mirovozzreniyu* [Fourth Vinogradov readings. Hydrology from knowledge to worldview], 2020, pp. 1092-1097. (in Russian)

Agafonova S.A., Vasilenko A.N., Mironenko A.A. et al. Ledovyy rezhim i ego opasnyye proyavleniya na rekakh Arkticheskoi zony Rossii [Ice regime and its dangerous manifestations on the rivers of the Arctic zone of Russia]. *Trudy V Vserossiskoi. Konferentsii "Ledovyye i termicheskie protsessy na vodnykh ob'ektakh Rossii"* [Proceedings of V All-Russian conference "Ice and thermal processes on water bodies of Russia"]. Moscow, Agricultural Academy named after. K.A. Timiryazeva Publ., 2016, pp. 15-21. (in Russian)

Agafonova S. A., Frolova N. L., Vasilenko A.N. et al. Ledovyy rezhim i opasnyye gidrologicheskie yavleniya na rekakh arkticheskoi zony evropeiskoi territorii Rossi [Ice regime and dangerous hydrological phenomena on the rivers of the Arctic zone of the European territory of Russia]. *Vestnik Moskovskogo universiteta. Seriya 5, Geografiya* [Bulletin of Moscow University. Series 5, Geography], 2016, no. 6, pp. 41-49. (in Russian)

Smirnova D.A., Shishov A.A., Vasilenko A.N. et al. Osnovnyye cherty zimnego gidrologicheskogo rezhima prilivnykh ust'ev rek Terskogo berega Belogo morya na primere rek Umba i Kuzerka [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 Kuzerka rivers]. *Trudy IX Mezhdunarodnoi nauchno-prakticheskoi konferentsii "Morskie issledovaniya i obrazovanie (MARESEDU-*

2020)” [Proceedings of the IX International Scientific and Practical Conference “Marine Research and Education (MARESEDU-2020)”, 2020, vol. 1 (3), pp. 94-97. (in Russian)

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. <https://doi.org/10.21638/spbu07.2021.101>

Reichstein M., Camps-Valls G., Stevens B. et al. Deep learning and process understanding for data-driven Earth system science. *Nature*, 2019, vol. 566, pp. 195-204. <https://doi.org/10.1038/s41586-019-0912-1>

Król A., Banasik K. Predicting Ice Phenomena in a River Using the Artificial Neural Network and Extreme Gradient Boosting. *Resources*, 2022, vol. 11, no. 2, pp. 12. <https://doi.org/10.3390/resources11020012>

Manning C.D., Raghavan P., Schütze H. *Introduction to Information Retrieval*. Cambridge University Press, Stanford NLP book, 2008, 544 p. URL: <https://nlp.stanford.edu/IR-book/> (date of access: 22.04.2025)

Powers D.M.W. *Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness and Correlation. Technical Report SIE-07-001*. 2007, 24 p. URL: [https://www.researchgate.net/publication/228529307\\_Evaluation\\_From\\_Precision\\_Recall\\_and\\_F-Factor\\_to\\_ROC\\_Informedness\\_Markedness\\_Correlation](https://www.researchgate.net/publication/228529307_Evaluation_From_Precision_Recall_and_F-Factor_to_ROC_Informedness_Markedness_Correlation) (date of access: 22.04.2025).

Kratzert F., Klotz D., Brenner C. et al. Rainfall–runoff modelling using Long Short-Term Memory (LSTM) networks. *Hydrology and Earth System Sciences*, 2019, vol. 23, no. 10, pp. 5089-5110. <https://doi.org/10.5194/hess-23-5089-2019>

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, art. no. 2762. <https://doi.org/10.1038/s41598-025-87187-1>

Shen C.A. Transdisciplinary Review of Deep Learning Research and Its Relevance for Water Resources Scientists. *Water Resources Research*, 2018, vol. 54, no. 11, pp. 8558-8593. <https://doi.org/10.1029/2018WR022643>

Sit M., Demir I. Distributed deep learning model for flood prediction. *Journal of Hydrology*, 2019, vol. 570, pp. 524-534. <https://doi.org/10.1016/j.jhydrol.2018.12.045>

Sokolova M., Lalpalme G. A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 2009, vol. 45, no. 4, pp. 427-437. <https://doi.org/10.1016/j.ipm.2009.03.002>

van Rijsbergen C. J. *Information Retrieval*. London, Butterworths, 1979, 208 p.

Nearing G.S., Sampson A.K., Kratzert F. et al. What role does hydrological science play in the age of machine learning. *Water Resources Research*, 2021, vol. 57, no. 3, art. no. e2020WR028091. <https://doi.org/10.1029/2020WR028091>

#### Сведения об авторе

**Канашин Сергей Андреевич**

аспирант

Государственный гидрологический институт

Россия, 199004, г. Санкт-Петербург,

2-ая линия В. О., 23

e-mail: [ckanashin@yandex.ru](mailto:ckanashin@yandex.ru)

#### Information about the authors

**Kanashin Sergey Andreevich**

Postgraduate

State Hydrological Institute

23, 2nd line Vasilyevsky Island, St. Petersburg,

199004, Russian Federation

e-mail: [ckanashin@yandex.ru](mailto:ckanashin@yandex.ru)

Код научной специальности: 1.6.16

Статья поступила в редакцию 21.04.2025; одобрена после рецензирования 29.05.2025; принята к публикации 10.06.2025

The article was submitted April, 21, 2025; approved after reviewing May, 29, 2025; accepted for publication June, 10, 2025