

LONG-TERM FORECAST OF THE ICE-FREE PERIOD ON ARCTIC SHIPPING RIVERS (A CASE STUDY OF THE PUR RIVER)

N. A. Volkova^{1,2}

¹ Russian State Hydrometeorological University, St. Petersburg, Russian Federation

² Arctic and Antarctic Research Institute, St. Petersburg, Russian Federation

Forecasting the onset and end dates of ice phenomena on Arctic shipping rivers, such as the Pur River, is essential for navigation planning and ensuring transport accessibility under changing climatic conditions. The development of reliable forecasting models that outperform traditional averaged approaches is of considerable scientific and practical importance. This study presents the development and comparative analysis of five machine learning models for forecasting the dates of ice formation and ice clearance on the Pur River at the Samburg gauging station: a convolutional neural network (CNN), a fully connected neural network (Dense), a multilayer perceptron (MLP), a support vector regression model (SVR), and a random forest model. Twelve hydrometeorological parameters were used as input variables. Forecast performance was quantitatively evaluated using the mean absolute error (MAE), root mean square error (RMSE), and the coefficient of determination (R^2). A comparison with an averaged baseline model showed that, for predicting ice-clearance dates, the fully connected neural network (Dense) demonstrated the best overall performance (MAE = 5.18 days, RMSE = 5.97 days, R^2 = 0.387). For predicting ice-formation dates, the multilayer perceptron (MLP) model exhibited the lowest prediction error and the highest explanatory power (MAE = 3.59 days, RMSE = 4.21 days, R^2 = 0.315). The results indicate that more complex machine learning models do not necessarily provide superior performance when forecasting complex hydrological events such as ice phenomena. Consequently, the optimal forecasting model should be selected individually for each predicted date.

Keywords: Pur River; ice phenomena; ice-free period; machine learning; neural networks; long-term forecasting; Arctic shipping

For citation:

Volkova, Nadezhda A. "Long-term forecast of the ice-free period on arctic shipping rivers (a case study of the Pur River)." *Vestnik Gosudarstvennogo universiteta morskogo i rechnogo flota imeni admiral S. O. Makarova* 17.6 (2025): 816–831. DOI: 10.21821/2309-5180-2025-17-6-816-831.

УДК 556.06, 556.535.5

ДОЛГОСРОЧНЫЙ ПРОГНОЗ СРОКОВ БЕЗЛЕДОСТАВНОГО ПЕРИОДА НА АРКТИЧЕСКИХ СУДОХОДНЫХ РЕКАХ (НА ПРИМЕРЕ РЕКИ ПУР)

Н. А. Волкова^{1,2}

¹ ФГБОУ ВО «Российский государственный гидрометеорологический университет», 192007, Санкт-Петербург, Российская Федерация

² ФГБУ «Арктический и антарктический научно-исследовательский институт», 199397, Санкт-Петербург, Российская Федерация

Темой исследования является прогнозирование сроков начала и окончания ледовых явлений на арктических судоходных реках, таких как река Пур, которое является важной процедурой для планирования навигации и обеспечения транспортной доступности в условиях меняющегося климата. В исследовании представлена разработка и сравнительный анализ пяти моделей машинного обучения для прогнозирования дат появления ледовых явлений и очищения ото льда реки Пур в замыкающем створе Самбур: сверточная нейронная сеть (CNN), полносвязная нейронная сеть (Dense), многослойный перцептрон (MLP), метод опорных векторов (SVR) и случайный лес (Random Forest). В качестве входных данных использовались 12 гидрометеорологических параметров. Проведена количественная оценка качества прогнозов с использованием метрик MAE (средняя абсолютная ошибка), RMSE (среднеквадратичная ошибка) и R^2 (коэффициент детерминации). Сравнение с осредненной моделью показало, что для прогноза дат очищения ото льда наилучшие результаты по совокупности метрик продемонстрировала полносвязная нейронная сеть (Dense) (MAE = 5,18, RMSE = 5,97, R^2 = 0,387). Для прогноза дат появления ледовых явлений наименьшую ошибку и наивысшую объясняющую способность

показала модель на основе многослойного перцептрона (MLP) ($MAE = 3,59$, $RMSE = 4,21$, $R^2 = 0,315$). Результаты свидетельствуют о том, что для прогнозирования сложных гидрологических событий, таких как ледовые явления, эффективность сложных моделей машинного обучения не всегда является оптимальной. Наилучшая модель должна подбираться отдельно для каждой прогнозируемой даты.

Ключевые слова: река Пур, ледовые явления, машинное обучение, нейронные сети, прогнозирование, арктическое судоходство, транспортное обеспечение, наращивание грузопотока, производственно-логистический цикл, ключевые метеопараметры.

Для цитирования:

Волкова Н. А. Долгосрочный прогноз сроков безледоставного периода на арктических судоходных реках (на примере реки Пур) / Н. А. Волкова // Вестник Государственного университета морского и речного флота имени адмирала С. О. Макарова. — 2025. — Т. 17. — № 6. — С. 816–831. DOI: 10.21821/2309-5180-2025-17-6-816-831. — EDN EIBDXB.

Введение (Introduction)

В контексте реализации государственной стратегии развития Арктической зоны Российской Федерации и наращивания грузопотока по Трансарктическому транспортному коридору возрастает роль крупных судоходных рек как критически важных транспортных артерий, обеспечивающих логистику промышленных кластеров. Река Пур, протекающая в зоне активного освоения нефтегазовых месторождений, является наглядным примером такой ключевой водной магистрали. Эффективность всего производственно-логистического цикла — от снабжения вахтовых поселков до вывода готовой продукции — жестко лимитирована продолжительностью *навигационного окна*, определяемого сроками начала и окончания ледовых явлений.

В условиях наблюдаемой климатической дестабилизации, проявляющейся в Арктике в виде аномального роста температур и увеличения межгодовой изменчивости ледовых условий, традиционные подходы к планированию навигации становятся недостаточными [1]. Неточность прогноза дат вскрытия и замерзания реки приводит к значительным экономическим рискам, включая простои флота, срыв контрактных обязательств и повышение аварийности. В этой связи разработка и внедрение высокоточных методов долгосрочного прогнозирования ледового режима, адаптированных к современной климатической реальности и учитывающих комплекс гидрометеорологических факторов, приобретает характер неотложной научно-практической задачи, решение которой напрямую влияет на надежность транспортного обеспечения арктических проектов [2–4].

Существующий арсенал методов прогнозирования ледовых явлений как в отечественной¹ [5–8], так и в зарубежной практике [9, 10] в основном базируется на статистических зависимостях между датами установления / разрушения ледового покрова и ключевыми метеопараметрами: температурой воздуха и суммой температур. Несмотря на свою историческую обоснованность, эти подходы демонстрируют растущую неадекватность применительно к арктическим рекам по следующим причинам:

1. Климатические изменения происходят нелинейно: статистические модели, калиброванные на основе данных XX в., не учитывают ускоренный характер современных климатических процессов, что ведет к систематическому смещению прогнозов.
2. Факторы воздействуют комплексно: традиционно модели часто опираются на ограниченный набор предикторов, не учитывая синергетического влияния таких параметров, как скорость ветра, высота снежного покрова, интенсивность осадков и др.
3. Большинство методик слабо приспособлены для оперативного учета новых данных и быстрой перенастройки в условиях меняющегося режима реки.
4. Существующие решения в основном ориентированы на краткосрочные прогнозы, в то время как стратегическое планирование требует сезонных и многомесячных оценок.

Перспективным направлением преодоления этих ограничений является применение алгоритмов машинного обучения [11–16], способных выявлять сложные нелинейные взаимосвязи в больших массивах гетерогенных данных. Однако их сравнительная эффективность для прогнозирования конкретных ледовых фаз на арктических реках требует тщательной валидации.

¹ Руководство по гидрологическим прогнозам. Вып. 3: Прогноз ледовых явлений на реках и водохранилищах. Л.: Гидрометеоздат, 1989. 168 с.

Целью исследования является разработка и сравнительный анализ эффективности различных алгоритмов машинного обучения для прогнозирования дат начала и окончания ледовых явлений на арктических судоходных реках на примере реки Пур, с последующей идентификацией оптимальной модели для оперативного планирования навигации.

Задачи исследования:

- сформировать репрезентативный массив исходных данных на основе многолетних гидрометеорологических наблюдений, включающий 12 ключевых параметров (x_1 – x_{12}), влияющих на ледовый режим реки Пур в створе Самбурга;
- реализовать и обучить пять различных архитектур машинного обучения: сверточную нейронную сеть (CNN), полносвязную нейронную сеть (Dense), многослойный перцептрон (MLP), метод опорных векторов (SVR) и случайный лес (Random Forest);
- провести верификацию точности прогностических моделей с использованием комплекса метрик качества: средней абсолютной ошибки (MAE), среднеквадратичной ошибки (RMSE), а также коэффициента детерминации (R^2);
- выполнить сравнительный анализ эффективности моделей между собой и с базовой осредненной моделью отдельно для прогноза дат очищения ото льда и дат появления ледовых явлений, оценить продолжительность безледоставного периода.

Методы и материалы (Materials and Methods)

Река Пур образуется от слияния рек Пяку-Пур и Айваседа-Пур. Площадь бассейна в месте слияния этих рек равна 57 500 км² и возрастает к устью реки Пур до 112 000 км². От истоков реки Пяку-Пур общая длина реки Пур составляет 1024 км.

В настоящее время река Пур от устья до Тарко-Сале является судоходной рекой (табл. 1). По навигационным условиям р. Пур можно разделить на два участка: верхний — от пос. Тарко-Сале до Уренгоя и нижний — от Уренгоя до устья реки Пур. Верхний участок имеет большое количество перекатов и менее удобен для судоходства, чем нижний. При снижении уровня до меженного в средний по водности год на верхнем участке реки насчитывается 14 перекатов с глубинами ниже гарантированных. Характерной особенностью реки на этом участке является незначительная протяженность отдельных перекатов, достигающая 150–200 м при длине плесов 5–7 км. Наиболее затруднительным на верхнем участке является перекат, расположенный на 33 км ниже Тарко-Сале [3].

По условиям обеспечения безопасности судоходства установлены следующие категории внутренних водных путей для реки Пур:

- внутренние водные пути с гарантированными габаритами судовых ходов и освещаемой навигационной обстановкой (*первая категория*);
- внутренние водные пути с гарантированными габаритами судовых ходов и со светоотражающей навигационной обстановкой (*вторая категория*);
- внутренние водные пути без гарантированных габаритов судовых ходов и без навигационной обстановки (*седьмая категория*).

Нижний участок реки Пур является наиболее благоприятным для судоходства. Глубины здесь сравнительно одинаковые и удерживаются на уровне гарантированных. Наиболее трудный перекат в многоводные годы находится на 185–187-м км вниз по течению от Тарко-Сале. В маловодные и средние по водности годы с глубинами меньше гарантированных насчитывается до пяти-шести перекатов. Короткий навигационный период реки Пур (в среднем 96–112 дней) является типичным для рек арктической зоны России (например, в Обь-Иртышском и Ленском бассейнах навигация также длится около 125–150 сут и открывается в июне-июле). В то же время на юге и юго-западе страны, а также в крупных городах, таких как Москва, навигация может длиться до 240 сут и быть круглогодичной. Как и многие другие крупные арктические реки, Пур является жизненно важной транспортной артерией в регионе, где практически отсутствуют другие пути сообщения, играя важную роль в транспортировке грузов для нефтегазовых месторождений (Уренгойское, Губкинское).

Категории внутренних водных путей, определяющих для участков внутренних водных путей габариты судовых ходов и навигационно-гидрографическое обеспечение условий плавания судов в навигацию 2025 г.²

Продолжи тему, Дней

2

Исследование проводилось для реки Пур в замыкающем створе Самбург. Выбор данного створа обусловлен его репрезентативностью для нижнего течения реки, где формируются окончательные сроки ледовых процессов, важные для навигации.

Для прогнозирования использовались данные метеостанции Тарко-Сале, как наиболее репрезентативной для бассейна реки Пур. Период анализа составил 57 лет (1967–2023 гг.). В качестве прогнозируемых параметров использовались фактические даты начала и окончания ледовых явлений.

Для достижения целевой заблаговременности в качестве предикторов предполагается использовать факторы, характеристики которых формируются задолго до наступления прогнозируемых явлений. Соответственно предикторный горизонт охватывает данные за предшествующие сезоны, в частности среднесуточные значения за период с 1 сентября предшествующего года до 28 февраля года, для которого создается прогноз. В качестве входных данных используются следующие параметры по метеорологической станции Тарко-Сале³: температура воздуха, атмосферные осадки, средняя скорость ветра, высота снежного покрова, температура поверхности почвы, атмосферное давление на уровне станции, дефицит насыщения водяного пара, относительная влажность, температура точки росы. Дополнительно используются индекс арктической осцилляции (АО), индекс североатлантического колебания (NAO) и ежедневные данные уровня воды реки Пур в створе Уренгой за тот же промежуток времени. Индексы североатлантического колебания (NAO) и арктического колебания (АО) получены с сайтов https://www.cpc.ncep.noaa.gov/products/precip/CWlink/daily_ao_index/ao.shtml и <https://www.cpc.ncep.noaa.gov/products/precip/CWlink/pna/nao.shtml>.

Реализованы и протестированы пять архитектур машинного обучения:

1) сверточная нейронная сеть (CNN) для выявления пространственно-временных зависимостей данных;

2) полносвязная нейронная сеть (Dense) как базовый подход глубокого обучения;

3) многослойный перцептрон (MLP) с оптимизацией числа скрытых слоев;

4) метод опорных векторов (SVR) с радиально-базисной функцией ядра;

5) случайный лес (Random Forest) как представитель ансамблевых методов.

Для количественной оценки точности прогнозов использовались метрики:

– MAE (Mean Absolute Error) — средняя абсолютная ошибка;

– RMSE (Root Mean Square Error) — среднеквадратичная ошибка;

– R^2 — коэффициент детерминации.

Дополнительно рассчитывалась «Осредненная модель» как базовый уровень для сравнения эффективности сложных алгоритмов. Все модели тестировались на тестовой выборке, не участвовавшей в обучении. Использовалась k -кратная перекрестная валидация ($k = 5$) для обеспечения статистической значимости результатов. Предобработка данных включала нормализацию параметров и устранение выбросов.

Реализация моделей выполнена в среде Python 3.9 с использованием библиотек scikit-learn, TensorFlow и Keras для обеспечения воспроизводимости результатов.

Результаты (Results)

Ряды наблюдений за среднесуточными датами ледовых явлений по створу Самбург за период 1937–2023 гг. получены по материалам^{4,5}. Для приведения временных меток к числовому формату, пригодному для обработки алгоритмами машинного обучения, выполнено преобразование календарных дат начала и окончания ледовых явлений в порядковые номера дней года. В данной системе

³ Свидетельство о государственной регистрации базы данных 2020621470 Российская Федерация. Научно-прикладной справочник «Климат России» / В. Н. Разуваев, О. Н. Булыгина, Н. Н. Коршунова [и др.]; заяв. и патентобл. Федеральное государственное бюджетное учреждение «Всероссийский научно-исследовательский институт гидрометеорологической информации — Мировой центр данных». № 2020620899; заявл. 09.06.2020; опубл. 18.08.2020. EDN MXYBEY.

⁴ Гидрологический ежегодник. Т. 6, вып. 0-9. Л.: Гидрометеониздат, 1936–2012.

⁵ Автоматизированная информационная система государственного мониторинга водных объектов [Электронный ресурс]: Режим доступа: <https://gmvo.skniivh.ru> (дата обращения 01.09.2025).

отсчета 1 января соответствует значение 1; 31 декабря — значение 365 (или 366 для високосного года). Данное преобразование позволяет линеаризовать временные данные, исключить циклическую природу календарных дат, упростить вычисление временных интервалов между событиями, повысить эффективность обучения моделей за счет работы с непрерывными числовыми признаками. Все дальнейшие расчеты и прогнозы выполнялись в данной системе координат с обратным преобразованием в календарный формат для интерпретации конечных результатов.

Для выявления структурных изменений в исследуемых временных рядах применен непараметрический критерий Петтитта (Pettitt's test), который является инструментом для обнаружения единственной точки изменения в последовательности данных. Данный критерий не требует предположений о нормальности распределения исходных данных и устойчив к выбросам. Уровень значимости установлен на стандартном уровне $\alpha = 0,05$.

Результаты применения критерия Петтитта для ряда дат окончания ледовых явлений на реке Пур в створе Самбург выявили наличие статистически значимой структурной точки перелома (рис. 1): статистика критерия $K = 289,45$; год изменения 1990; p-value составляет 0,0048. Полученное значение p-value (0,0048) существенно ниже критического уровня значимости 0,05, что позволяет с высокой степенью достоверности отвергнуть нулевую гипотезу об однородности временного ряда и принять альтернативную гипотезу о наличии структурного изменения.

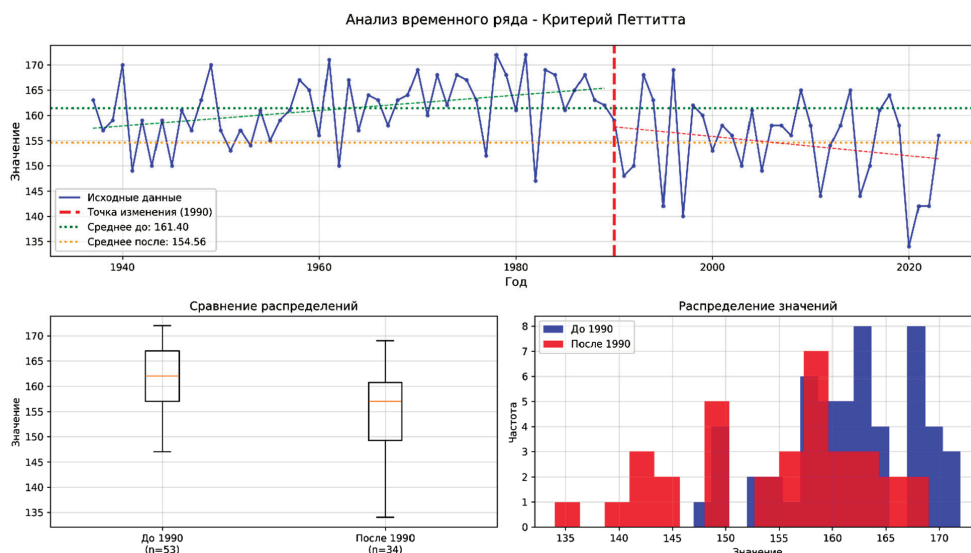


Рис. 1. Результаты применения критерия Петтитта для дат очищения ото льда на реке Пур в створе Самбург

По данным анализа рис. 1 и табл. 2 видно, что наблюдается статистически значимое снижение среднего значения показателя на 6,84 дня: с 12 июня по 5 июня. Стандартное отклонение увеличилось на 35,75 %, что свидетельствует о существенном росте изменчивости данных после 1990 г. Обнаруженная точка изменения указывает на смену режима функционирования исследуемой системы, что может быть связано с изменением внешних факторов или внутренних процессов в 1990 г.

Таблица 2

Сравнительный анализ статистических показателей до и после точки изменения

Параметр	До 1990 г.	После 1990 г.	Изменение
Среднее значение	161,40 (12 июня)	154,56 (5 июня)	–6,84 дня
Стандартное отклонение	6,32	8,58	+35,75 %

Результаты применения критерия Петтитта для ряда дат появления ледовых явлений на реке Пур в створе Самбург (рис. 2) выявили наличие статистически значимой структурной точки перегиба: статистика критерия (K) составила 827,0; год изменения 1993; p-value равно 0,00422.

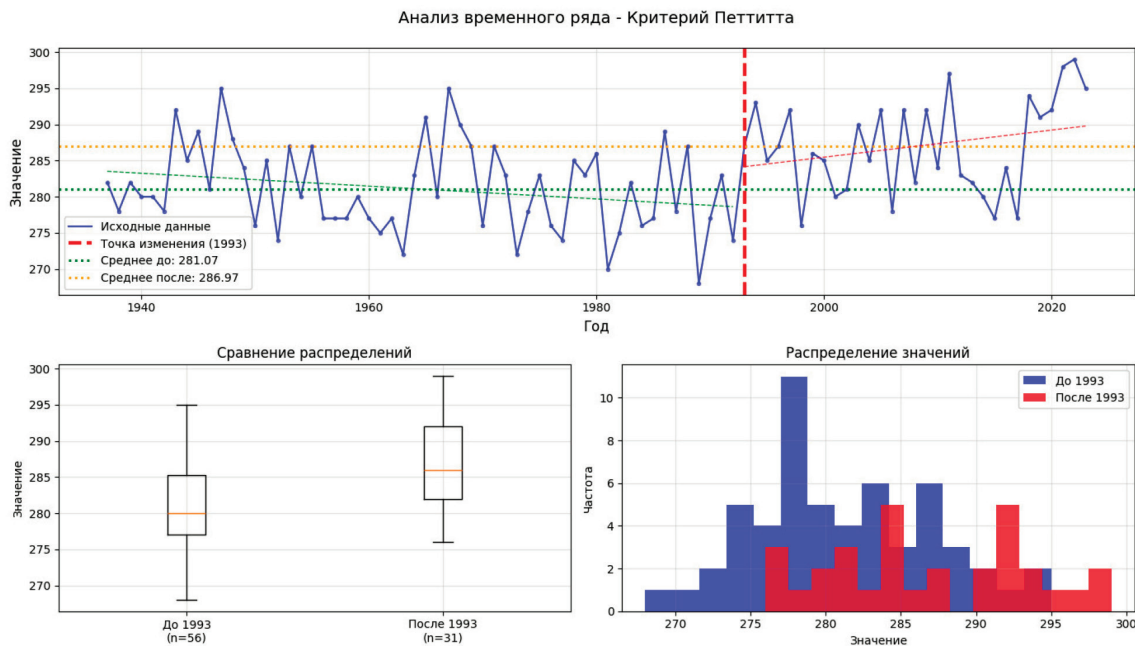


Рис. 2. Результаты применения критерия Петтитта для дат появления ледовых явлений на реке Пур в створе Самбург

По данным анализа (рис. 2, табл. 3) видно, что наблюдается достоверное смещение среднего значения показателя на 5,9 дней: с 9 октября по 15 октября. Стандартное отклонение увеличилось на 6,14 %, что свидетельствует об умеренном росте изменчивости данных после 1993 г. Высокая статистическая значимость результата ($p < 0,01$) позволяет с вероятностью 99,58 % утверждать, что обнаруженное изменение не является случайным. Величина статистики $K = 827,0$ указывает на выраженность структурного сдвига, что подтверждает надежность полученных результатов.

Таблица 3

Сравнительный анализ статистических показателей до и после точки изменения

Параметр	До 1993 г.	После 1993 г.	Изменение
Среднее значение	281,07 (9 октября)	286,97 (15 октября)	+5,90 дней
Стандартное отклонение	6,09	6,47	+6,14 %

Исходные данные сведены в таблицы по годам. Для примера фрагмент прогнозной модели представлен в табл. 4. Для формирования обучающей, проверочной и тестовой выборок разработан алгоритм, выбирающий только те векторы входных / выходных значений, в которых отсутствуют пропуски значений параметров.

Реализованные архитектуры имеют следующие параметры:

- 1) сверточная нейронная сеть (CNN): три сверточных слоя с возрастающей размерностью (128, 256, 512 фильтров), слой BatchNormalization и Dropout для регуляризации; MaxPooling для уменьшения размерности, полносвязные слои для финального прогнозирования;
- 2) полносвязная нейронная сеть (Dense): шесть полносвязных слоев с уменьшающейся размерностью (1024 → 32 нейронов), BatchNormalization и Dropout для предотвращения переобучения; адаптация под различное количество признаков;
- 3) многослойный перцептрон (MLP): архитектура адаптивная в зависимости от количества признаков, для 12 признаков 512–256–128–64 нейронов, активация ReLU, оптимизатор Adam;
- 4) метод опорных векторов (SVR): ядро радиально-базисное (RBF), регуляризация адаптивный параметр C, кэширование 1000 МБ для ускорения вычислений;
- 5) случайный лес (Random Forest): количество деревьев 200–300; глубина деревьев 20–25; критерий разделения адаптивный в зависимости от количества признаков.

Таблица 4

Фрагмент таблицы исходных данных для построения прогнозной модели

Дата	Температура воздуха	Атмосферные осадки	Средняя скорость ветра	Снежный покров	Температура поверхности почвы	Атмосферное давление на уровне станции	Дефицит насыщения водяного пара	Относительная влажность	Температура точки росы	Ao_index_cdas	Naо_index_cdas	Уровень воды, Урентой
01 сентября	7,4	1,2	4,0	0	7,25	993	2,35	78	3,5	-0,71955	-0,842	463
02 сентября	3,2	2,6	3,9	0	3,62	1004	1,16	86	0,8	-0,19214	-0,908	460
03 сентября	3,5	4,3	3,6	0	3,87	1005	0,7	91	2,2	0,07598	-0,941	455
04 сентября	3,4	0	3,4	0	3,62	1016	1,73	81	0	0,335344	-0,851	451
05 сентября	4,2	1,1	3,1	0	3,37	1017	1,47	85	1,3	0,68633	-0,657	446
06 сентября	8,8	5,2	2,9	0	7,62	1006	0,58	95	8,1	0,726644	-0,13	444
07 сентября	4,7	0	2,4	0	4,62	1014	1,73	81	1,5	0,690463	0,332	439

Для построения и валидации прогнозной модели применяется комплексный подход, включающий стратегию обучения с адаптивными механизмами регуляризации и многоаспектную оценку качества. В основу процесса обучения нейронной сети, реализованного в функции (Train_and_Evaluate_Model), заложено использование двух ключевых механизмов обратной связи: ранней остановки (EarlyStopping) и динамического снижения скорости обучения (ReduceLROnPlateau).

Для обеспечения устойчивости процесса обучения все входные признаки и целевые переменные подвергаются стандартизации с использованием метода StandardScaler, который приводит распределение данных к виду с нулевым математическим ожиданием и единичной дисперсией. Исходные данные разделяются на три независимые подвыборки: обучающую (80 %), валидационную (10 %) и тестовую (10 %). Разделение гарантирует объективную оценку обобщающей способности модели и минимизирует риск информационной утечки.

Качество прогнозов оценивалось с использованием трех стандартных метрик:

1) MAE (Mean Absolute Error) — средняя абсолютная ошибка, характеризующая среднее отклонение прогноза от истинного значения в абсолютной шкале;

2) RMSE (Root Mean Square Error) — среднеквадратическая ошибка, обладающая повышенной чувствительностью к значительным выбросам, что позволяет выявлять случаи существенных систематических ошибок;

3) R^2 (коэффициент детерминации) — показатель, определяющий долю дисперсии зависимой переменной, объясняемую моделью, и служащий индикатором ее общей адекватности.

Алгоритм работы программы представлен на рис. 3.

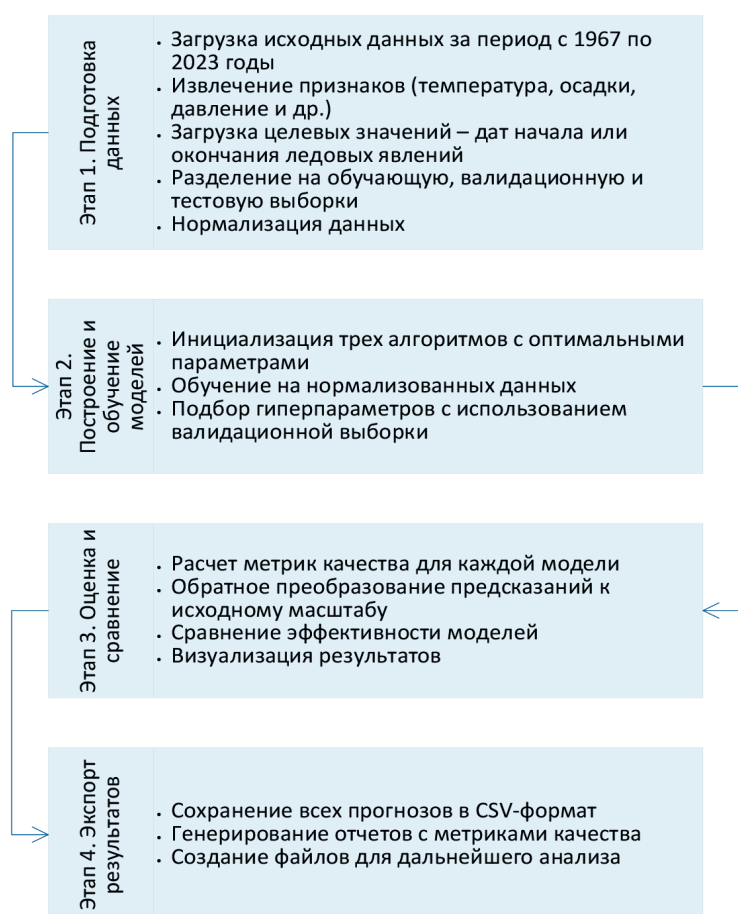


Рис. 3. Алгоритм работы программы

Для повышения точности, устойчивости и обобщающей способности прогнозов дат начала и окончания ледовых явлений реализована стратегия ансамблирования на основе усреднения пред-

сказаний независимо обученных моделей. Ансамблирование позволяет преодолеть ограничения отдельных моделей, различающихся архитектурой, параметрами и склонностью к переобучению или смещению.

К преимуществам ансамблирования относятся:

- снижение дисперсии ошибки, поскольку усреднение прогнозов компенсирует случайные отклонения отдельных моделей, что эффективно при наличии шума в исходных данных;
- повышение устойчивости к выбросам, так как аномальные прогнозы, вызванные нестандартными погодными условиями в отдельные сезоны, нивелируются за счет коллективного решения;
- балансировка систематических смещений, поскольку различные архитектуры нейронных сетей обладают разными типами смещений, которые при усреднении частично компенсируются, обеспечивая более сбалансированный и надежный результат;
- улучшение обобщающей способности, так как ансамбли демонстрируют более стабильное качество на независимых данных (тестовой выборке и при межгодовом прогнозировании), превосходя отдельные модели в условиях климатической изменчивости.

При условии некоррелированности ошибок моделей дисперсия среднего прогноза уменьшается пропорционально количеству моделей N .

На рис. 4–6 представлены результаты прогнозирования.




Рис. 4. Хронологический график хода дат очищения ото льда и результаты прогнозирования




Рис. 5. Хронологический график хода дат очищения ото льда и осредненные результаты прогнозирования




Рис. 6. Хронологический график хода дат появления ледовых явлений:
а — результаты прогнозирования; б — осредненные результаты прогнозирования

В табл. 5 по результатам прогнозирования выполнено сравнение качества разных моделей.

Таблица 5

Сравнение качества прогнозирования дат по разным моделям

Модель	Метрики качества прогноза дат окончания ледовых явлений			Метрики качества прогноза дат начала ледовых явлений		
	MAE	RMSE	R2	MAE	RMSE	R2
CNN	6,68	7,57	0,014	4,64	5,73	-0,267
Dense	5,18	5,97	0,387	4,56	4,65	0,164
MLP	7,33	7,88	-0,069	3,59	4,21	0,315
SVR	6,47	7,47	0,039	4,42	5,09	-0,003
Random_Forest	6,32	7,80	-0,047	4,53	4,73	0,137
Ансамблевая	3,72	4,99	0,026	3,12	4,00	0,485

По табл. 5 видно, что для прогноза окончания ледовых явлений наилучшие результаты показывает модель Dense ($MAE = 5,18$, $RMSE = 5,97$, $R^2 = 0,387$), наихудшие — модель MLP ($MAE = 7,33$, $RMSE = 7,88$, $R^2 = -0,069$). Все модели демонстрируют относительно низкое качество ($R^2 < 0,4$).

Для прогноза начала ледовых явлений наилучшие результаты показала ансамблевая модель ($MAE = 3,12$, $RMSE = 4,00$, $R^2 = 0,485$), хорошие результаты — модель MLP ($MAE = 3,59$, $RMSE = 4,21$,

$R^2 = 0,315$), наихудшие результаты — модель CNN ($MAE = 4,64$, $RMSE = 5,73$, $R^2 = -0,267$). Следовательно, ансамблевая модель является наиболее универсальным решением, особенно для прогноза появления ледовых явлений. Полносвязная сеть (Dense) оптимальна для прогноза очищения ото льда. CNN архитектура показала наихудшие результаты и не рекомендуется к использованию. Прогноз начала ледовых явлений в целом более точен, чем прогноз их окончания. Разброс ошибок (RMSE) существенно превышает среднюю ошибку (MAE), что указывает на наличие значительных выбросов в прогнозах. Наилучшей стратегией является использование ансамблевого подхода для появления ледовых явления и Dense сети для дат очищения ото льда либо применение ансамблевой модели для обоих типов прогнозов.

На основании полученных прогнозов дат начала и окончания ледовых явлений также рассчитана прогнозируемая продолжительность безледоставного периода для каждой модели как разность между датой окончания и датой начала ледовых явлений (рис. 7).




Рис. 7. Хронологический график продолжительности безледоставного периода и результаты прогнозирования

Результаты оценки точности прогнозирования данного интегрального показателя представлены в табл. 6.

Таблица 6

Сравнение качества прогнозирования продолжительности безледоставного периода по разным моделям

Модель	MAE	RMSE	R2
CNN	10,40	13,91	-22,81
Dense	6,66	8,76	0,692
MLP	9,82	12,49	0,592
SVR	5,26	7,45	0,082
Random Forest	7,63	10,50	-4,636
Ансамблевая	4,43	6,19	0,580

Анализ результатов демонстрирует существенный разброс в точности прогнозирования продолжительности навигационного периода между различными архитектурами.

Наилучшие результаты по метрикам MAE (4,43 дня) и RMSE (6,19 дней) показала ансамблевая модель, что свидетельствует о ее высокой надежности для оценки длительности безледоставного периода. Модель Dense продемонстрировала наивысшее значение коэффициента детерминации R^2 (0,692), что указывает на ее способность объяснять большую долю дисперсии в данных.

В то же время модели CNN и Random Forest показали статистически неадекватные результаты ($R^2 = -22,813$ и $-4,636$ соответственно), что свидетельствует о их неприменимости для решения данной конкретной задачи в использованной конфигурации.

Полученные результаты свидетельствуют о том, что высокая точность прогноза отдельных ледовых фаз (начала и окончания) не гарантирует столь же точного прогноза их разности — продолжительности периода. Кумуляция ошибок, неизбежно возникающая при расчете разности двух спрогнозированных дат, становится критическим фактором, определяющим итоговое качество прогноза навигационного окна.

Обсуждение (Discussion)

Проведенное исследование выявило существенную зависимость точности прогнозирования от типа решаемой задачи. Полученные результаты демонстрируют, что для различных ледовых характеристик оптимальными оказываются разные модели. Так, модель MLP показала наилучшие результаты для прогноза начала ледовых явлений, в то время как для прогноза даты очищения ото льда наиболее эффективной оказалась полносвязная нейронная сеть Dense. Это свидетельствует о том, что физические процессы, определяющие начало и окончание ледовых явлений, имеют разную природу и требуют индивидуального подхода к их прогнозированию.

Интерес представляет анализ точности прогноза продолжительности безледоставного периода. Наилучшие результаты по комплексным метрикам показала ансамблевая модель, что указывает на кумулятивный характер ошибок при расчете разности дат. Данный факт имеет практическое значение, поскольку свидетельствует о необходимости использования специализированных моделей для прогнозирования непосредственно продолжительности навигации, а не вычисления ее как разности двух прогнозов.

Установленная заблаговременность прогноза в 3–6 месяцев представляет значительную практическую ценность. Возможность формирования прогноза в первой декаде марта на основе данных до 28 февраля позволяет оперативно планировать всю навигационную кампанию. Такой временной горизонт достаточен для заключения договоров, планирования логистических цепочек и распределения ресурсов.

Следует отметить, что исследование выявило ограниченную применимость сложных архитектур, таких как CNN и Random Forest, для решения данной задачи. Это может быть связано как с недостаточным объемом данных для обучения сложных моделей, так и с особенностями самих ледовых процессов. Перспективным направлением дальнейших исследований представляется разработка ансамблевых моделей, сочетающих преимущества простых и сложных архитектур.

Заключение (Conclusion)

В результате проведенного исследования разработана и апробирована методика долгосрочного прогнозирования сроков ледовых явлений на арктических судоходных реках на примере реки Пур. Для прогнозирования использовался комплекс гидрометеорологических данных, включающий 12 параметров (среднесуточная температура воздуха, сумма осадков, скорость ветра, высота снежного покрова и другие) по данным метеостанции Тарко-Сале.

Особенностью методики является ее значительная заблаговременность. Использование данных, актуальных на 28 февраля, позволяет сформировать прогноз в первой декаде марта с опережением от 3 до 6 месяцев относительно наступления прогнозируемых событий. На основе этих данных получен прогноз дат начала ледостава, окончания ледохода и, как следствие, продолжительности безледоставного периода.

Сравнительный анализ пяти архитектур машинного обучения показал следующее:

- для прогноза появления ледовых явлений наилучшие результаты показывает многослойный перцептрон (MLP) с ошибкой 3,59 дня;
- для прогноза очищения ото льда наиболее эффективной оказалась полносвязная нейронная сеть (Dense) с ошибкой 5,18 дней;

– прогноз продолжительности безледоставного периода наиболее точен при использовании осредненной модели (ошибка 4,43 дня).

Полученные результаты демонстрируют практическую применимость методов машинного обучения для решения задач гидрологического прогнозирования в Арктическом регионе. Разработанная методика может быть адаптирована для других арктических рек с аналогичными гидрологическими характеристиками и использована для оптимизации навигационного планирования и повышения безопасности судоходства. Для каждой реки необходим предварительный анализ факторов, влияющих на продолжительность безледоставного периода, и определение репрезентативных метеорологических станций.

Результаты исследования готовы к оперативному внедрению в практику гидрологического прогнозирования и могут быть использованы органами управления транспортным комплексом, нефтегазовыми компаниями и другими заинтересованными организациями, осуществляющими деятельность в Арктической зоне Российской Федерации.

Перспективы дальнейших исследований связаны с расширением набора прогностических параметров за счет включения данных дистанционного зондирования, а также с разработкой ансамблевых моделей, комбинирующих преимущества отдельных алгоритмов для повышения общей точности прогноза.

СПИСОК ЛИТЕРАТУРЫ

1. *Миронов Е. У.* Современное состояние и перспективы исследований ледяного покрова морей российской Арктики / Е. У. Миронов, С. В. Клячкин, В. М. Смоляницкий [и др.] // Российская Арктика. — 2020. — № 10. — С. 13–29. DOI: 10.24411/2658-4255-2020-12102. — EDN BIXTPF.
2. *Айзель Г. В.* Применение методов машинного обучения для моделирования толщины снежного покрова / Г. В. Айзель // Лёд и снег. — 2017. — Т. 57. — № 1. — С. 34–44. DOI: 10.15356/2076-6734-2017-1-34-44. — EDN YIXTRF.
3. *Волкова Н. А.* Анализ многолетних колебаний уровня воды реки Пур для обеспечения безопасности судоходства / Н. А. Волкова // Природные и техногенные риски (физико-математические и прикладные аспекты). — 2025. — № 2(54). — С. 6–22. DOI: 10.61260/2307-7476-2025-2-6-22. — EDN DLTELK.
4. *Волкова Н. А.* Подход к прогнозированию гидрологических явлений в Арктической зоне Российской Федерации и пути повышения достоверности прогнозов в условиях изменения климата / Н. А. Волкова // Гидротехника. — 2024. — № 4(77). — С. 21–27. — EDN OCMLYG.
5. *Волкова Н. А.* Комплексный подход к снижению аварийности на внутренних водных путях арктического региона России / Н. А. Волкова // Известия Петербургского университета путей сообщения. — 2025. — Т. 22. — № 3. — С. 761–775. DOI: 10.20295/1815-588X-2025-3-761-775. — EDN DENABG.
6. *Канахин С. А.* Применение методов машинного обучения для прогноза осенних ледовых явлений на реке Умбе / С. А. Канахин // Известия Иркутского государственного университета. Серия: Науки о Земле. — 2025. — Т. 52. — С. 52–64. DOI: 10.26516/2073-3402.2025.52.52. — EDN WQBGBW.
7. *Иглин С. М.* Прогнозирование редких гидрологических явлений методами машинного обучения на примере ледовых заторов на реке Печоре / С. М. Иглин, В. М. Морейдо, К. И. Головнин // Вестник Московского университета. Серия 5: География. — 2025. — Т. 80. — № 1. — С. 87–97. DOI: 10.55959/MSU0579-9414.5.80.1.6. — EDN FVTANO.
8. *Ангудович Я. И.* О применении нейронных сетей в задачах оперативного прогнозирования уровня воды в акватории Обской губы / Я. И. Ангудович, Ю. А. Татаренко // Гидрометеорология и экология. — 2025. — № 78. — С. 42–65. DOI: 10.33933/2713-3001-2025-78-42-65. — EDN KGFCIC.
9. *Zakharov I.* Review of River Ice Observation and Data Analysis Technologies / I. Zakharov, T. Puestow, A. A. Khan, R. Briggs, P. Barrette // Hydrology. — 2024. — Vol. 11. — Is. 8. DOI: 10.3390/hydrology11080126.
10. *Zhao Y.* Water environment risk prediction method based on convolutional neural network-random forest / Y. Zhao, L. Zhang, Y. Chen // Marine Pollution Bulletin. — 2024. — Vol. 209. — Pp. 117228. DOI: 10.1016/j.marpolbul.2024.117228.
11. *Williams B. S.* Measuring the skill of an operational ice jam flood forecasting system / B. S. Williams, A. Das, P. Johnston, B. Luo, K-E. Lindenschmidt // International Journal of Disaster Risk Reduction. — 2021. — Vol. 52. — Pp. 102001. DOI: 10.1016/j.ijdrr.2020.102001.

12. Журавлева Н. А. Выбор оптимизатора для обучения сверточной нейронной сети: задача классификации лесных пожаров / Н. А. Журавлева // StudNet. — 2022. — Т. 5. — № 5. — С. 160. — EDN XUJGWR.
13. Костромитинов А. В. Метод прогнозирования тумана с использованием сверточных нейронных сетей / А. В. Костромитинов, И. А. Яременко // Труды Военно-космической академии имени А. Ф. Можайского. — 2022. — № S685. — С. 186–193. — EDN NHFICC.
14. Астраханцева И. А. Метод градиентного бустинга при прогнозировании управленческих решений в многослойной криогенной системе / И. А. Астраханцева, Т. Е. Котенев, С. В. Горев [и др.] // Современные наукоемкие технологии. Региональное приложение. — 2024. — № 2(78). — С. 50–58. DOI: 10.6060/snt.20247802.0007. — EDN CDNSYQ.
15. Мади А. Й. Методы опорных векторов и нелинейной регрессии для расчета коэффициента фильтрации / А. Й. Мади, Е. В. Шеин // Вестник Московского университета. Серия 17: Почвоведение. — 2018. — № 3. — С. 42–47. — EDN XMGCCT.
16. Нгуен Т. В. Анализ и прогноз тенденций использования терминов в компьютерных науках на основе нейросетевых моделей / Т. В. Нгуен, К. Х. Т. Зьонг, А. Г. Кравец // Вестник компьютерных и информационных технологий. — 2021. — Т. 18. — № 2(200). — С. 24–38. DOI: 10.14489/vkit.2021.02. pp.024–038. — EDN ASJCNA.

REFERENCES

1. Mironov, E. U. et. al. “Current state and perspectives of ice cover studies in the Russian Arctic seas.” *Russian Arctic* 10 (2020): 13–29. DOI: 10.24411/2658-4255-2020-12102.
2. Ayzel, G. V. “Use of machine learning techniques for modeling of snow depth.” *Ice and Snow* 57.1 (2017): 34–44. DOI: 10.15356/2076-6734-2017-1-34-44.
3. Volkova, N. A. “Analysis of long-term fluctuations in the Pur River water level to ensure navigation safety.” *Prirodnye I Tekhnogennye Riski (Fiziko-Matematicheskie I Prikladnye Aspekty) = Natural and Man-Made Risks (Physico-Mathematical and Applied Aspects)* 2(54) (2025): 6–22. DOI: 10.61260/2307-7476-2025-2-6-22.
4. Volkova, N. A. “An approach to forecasting hydrological phenomena in the Arctic zone of the Russian Federation and ways to increase the reliability of forecasts in the conditions of climate change.” *Hydrotehnika* 4 (77) (2024): 21–27.
5. Volkova, N. A. “An integrated approach to reducing accidents on inland waterways in the Arctic region of Russia.” *Proceedings of Petersburg Transport University* 22.3 (2025): 761–775. DOI: 10.20295/1815-588X-2025-3-761-775.
6. 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* 52 (2025): 52–64. DOI: 10.26516/2073-3402.2025.52.52.
7. Iglin, S. M., V. M. Moreydo and K. I. Golovnin. “Forecasting rare hydrological events by machine learning methods: case study of ice jams on the Pechora River.” *Lomonosov Geography Journal* 80.1 (2025): 87–97. DOI: 10.55959/MSU0579-9414.5.80.1.6.
8. Angudovich, Ya. I. and Yu. A. Tatarenko. “On the application of neural networks in the tasks of operational water level forecasting in the gulf of Ob.” *Hydrometeorology and Ecology* 78 (2025): 42–65. DOI: 10.33933/2713-3001-2025-78-42-65.
9. Zakharov, I., P. Barrette, et al. “Review of River Ice Observation and Data Analysis Technologies.” *Hydrology* 11.8 (2024). DOI: 10.3390/hydrology11080126.
10. Zhao, Y., L. Zhang and Y. Chen. “Water environment risk prediction method based on convolutional neural network-random forest.” *Marine Pollution Bulletin* 209 (2024): 117228. DOI: 10.1016/j.marpolbul.2024.117228.
11. Williams, B. S., K-E. Lindenschmidt, et al. “Measuring the skill of an operational ice jam flood forecasting system.” *International Journal of Disaster Risk Reduction* 52 (2021): 102001. DOI: 10.1016/j.ij-drr.2020.102001.
12. Zhuravleva, N. A. “Choice optimizer for training a convolutional neural network: forest fires classification problem.” *StudNet* 5.5 (2022): 160.
13. Kostromitinov, A. V. and I. A. Yaremenko. “Metod prognozirovaniya tumana s ispol'zovaniem svertochnykh neyronnykh setey.” *Trudy VoЕННО-kosmicheskoy akademii imeni A. F. Mozhayskogo* S685 (2022): 186–193.
14. Astrakhanseva, I. A., T. E. Kotenev, S. V. Gorev et al. “Gradient boosting method in predicting management decisions in the multilayer cryogenic systems.” *Sovremennye naukoemkie tekhnologii. Regional'noe prilozhenie* 2(78) (2024): 50–58. DOI: 10.6060/snt.20247802.0007.

15. Madi, A. Y. and E. V. Shein. "Support vector machine and non-linear regressions methods to calculate saturation conductivity." *Vestnik Moskovskogo Universiteta. Seriya 17: Pochvovedenie* 3 (2018): 42–47.

16. Nguen, T. V., K. Kh. T. Zyong and A. G. Kravets. "Analysis and prediction of trends in the use of terms in computer science based on neural network models." *Vestnik Komp'yuternykh I informatsionnykh Tekhnologii* 18.2(200) (2021): 24–38. DOI: 10.14489/vkit.2021.02.pp.024-038.

ИНФОРМАЦИЯ ОБ АВТОРАХ

Волкова Надежда Александровна —
кандидат физико-математических наук,
доцент кафедры водно-технических изысканий
ФГБОУ ВО «Российский государственный
гидрометеорологический университет»
192007, Россия, Санкт-Петербург,
Воронежская улица, 79;
старший научный сотрудник отдела гидрологии
устьев рек и водных ресурсов
ФГБУ «Арктический и антарктический
научно-исследовательский институт»
199397, Россия, Санкт-Петербург, ул. Беринга, 38
E-mail: navolkova@aari.ru

INFORMATION ABOUT THE AUTHORS

Volkova Nadezhda A. —
PhD in Physics and Mathematics
Associate Professor of the Department
of Water–Engineering Surveys
Russian State Hydrometeorological University
79, Voronezhskaya Street, Saint Petersburg,
Russian Federation, 192007;
Senior Researcher of the Department of Hydrology
of River Mouths and Water Resources,
Arctic and Antarctic Research Institute,
38, Bering Street, Saint Petersburg,
Russian Federation, 199397
E-mail: navolkova@aari.ru

Статья поступила в редакцию 13 октября 2025

Received: Oct. 13, 2025