

Гидрометеорология и экология. 2025. № 78. С. 42—65.
Hydrometeorology and Ecology. 2025;(78):42—65.

ОКЕАНОЛОГИЯ

Научная статья
УДК 004.8:[556.54:551.461.2](268.52)
doi: 10.33933/2713-3001-2025-78-42-65

О применении нейронных сетей в задачах оперативного прогнозирования уровня воды в акватории Обской губы

Яромир Игоревич Ангудович, Юрий Алексеевич Татаренко

Российский государственный гидрометеорологический университет, Санкт-Петербург,
Россия, yaromir.angudovich@mail.ru

Аннотация. Статья посвящена разработке и применению новой модели для прогнозирования колебаний уровня воды в акватории Обской губы — ключевой зоны транспортировки нефтепродуктов по Северному морскому пути. Модель SSA-LR-LSTM объединяет методы сингулярного спектрального анализа, линейной регрессии и нейронных сетей с долгой краткосрочной памятью (LSTM). Гибридный метод позволяет учитывать сложные взаимосвязи между метеорологическими параметрами и уровнем воды. Выполнено моделирование гидрологического режима Обской губы с ежечасной дискретностью, что позволило прогнозировать уровень воды с заблаговременностью до 12 часов. Результаты показали, что нейронная модель точно описывает основные тенденции и закономерности исходного ряда, значительно снижает ошибку и повышает точность прогнозирования.

Ключевые слова: нейронные сети, машинное обучение, уровень воды, прогнозирование, компьютерное моделирование, Обская губа.

Для цитирования: Ангудович Я. И., Татаренко Ю. А. О применении нейронных сетей в задачах оперативного прогнозирования уровня в акватории Обской губы // Гидрометеорология и экология. 2025. № 78. С. 42—65. doi: 10.33933/2713-3001-2025-78-42-65.

OCEANOLOGY

Original article

On the application of neural networks in the tasks of operational water level forecasting in the Gulf of Ob

Yaromir I. Angudovich, Yuri A. Tatarenko

Russian State Hydrometeorological University, Saint Petersburg, Russia

Summary. The article is devoted to the development and application of a new model for predicting water level fluctuations in the Gulf of Ob, a key area for the transportation of petroleum products in the

© Ангудович Я. И., Татаренко Ю. А., 2025

Northern Sea Route. The SSA-LR-LSTM model combines methods of singular spectral analysis (Caterpillar-SSA), linear regression, and long-term short-term memory (LSTM) neural networks. The hybrid method allows for the consideration of complex relationships between meteorological parameters and water levels. The use of a bidirectional layer (BiLSTM) allowed the network to better assimilate information and describe complex patterns between input variables. The model was tested in real conditions and implemented for operational support of navigation in the area of the village of cape Kamenny. The hydrological regime of the Gulf of Ob was modeled with hourly discreteness, which made it possible to predict the water level up to 12 hours in advance. It is shown that the use of the Caterpillar-SSA method works effectively to smooth out meteorological characteristics and highlight the trend and periodic component in daily fluctuations in water levels. Refinement of forecast values using linear regression minimizes the amplitude error of tidal and surge fluctuations. The results showed that the neural model accurately describes the main trends and patterns of the initial series, and the use of modern machine learning technologies significantly reduces error and improves prediction accuracy. The experiments performed showed the smallest model validation error when using 3 hidden LSTM layers and one BiLSTM layer with 128 neurons. It has been shown that when the lead time is increased by more than 12 hours, the validation error increases significantly.

Keywords: neural networks, machine learning, water level, forecasting, computer modeling, gulf of Ob.

For citation: Angudovich Ya. I., Tatarenko Yu. A. On the application of neural networks in the tasks of operational level forecasting in the Gulf of Ob. *Gidrometeorologiya i Ekologiya = Journal of Hydrometeorology and Ecology*. 2025;(78):(42—65). doi: 10.33933/2713-3001-2025-78-42-65. (In Russ.).

Введение

В условиях современных глобальных климатических изменений Арктика с каждым годом приобретает всё большее экономическое значение. Новые методы сбора, обработки и анализа данных все чаще используются для решения различных задач арктических районов, в том числе более широкое распространение получают нейросетевые алгоритмы. Несмотря на то, что самым ценным в Арктике остаётся человеческий потенциал, современные технологии позволяют в значительной степени упростить расчеты и сделать их эффективнее. В настоящее время нейронные сети используются во многих сферах человеческой деятельности: от информационных систем до промышленного производства. Одним из ключевых направлений в Арктике, имеющим наиболее важное экономическое значение, является непрерывное обеспечение судового транспортного коридора. Ежегодно по Северному морскому пути (СМП) перевозят огромные запасы нефтепродуктов, сжиженный природный газ, полезные ископаемые и различное продовольствие. Обеспечение эффективности в судовых грузоперевозках во многом зависит от заблаговременного принятия грамотного решения в транспортно-логистических операциях и от достоверности гидрометеорологических прогнозов, в том числе оперативных прогнозов колебаний уровня воды.

В акватории Обской губы, у поселка мыс Каменный, круглогодично с 2016 г. проводятся наблюдения за уровнем моря с целью оперативного обеспечения судоходства и функционирования терминала беспричальной отгрузки нефти «*Ворота Арктики*». Разработка прогностической модели уровня для Обской губы является нетривиальной задачей. На ее результат влияет мелководность района, сильная внутрисезонная изменчивость уровня и мощные стонно-нагонные явления, в три раза превышающие по амплитуде приливные колебания [1]. Прогнозированию колебаний уровня в Обской губе посвящено довольно много работ.

Одной из фундаментальных для настоящего исследования является работа [2], в которой описан комбинированный метод оперативного прогнозирования с использованием трехмерной гидродинамической совместной модели циркуляции и льдов Северного Ледовитого океана AARI—IOCM [3] и предвычисления приливных колебаний по методике [4]. Использование данной модели получило широкое распространение в полярных широтах благодаря её адаптированности к системе циркуляции вод Северного Ледовитого океана. По мнению авторов модели, вероятность того, что ошибка прогнозируемого уровня в районе мыса Каменный с заблаговременностью прогноза 12 часов не превысит ± 5 см, составляет 44 %. С увеличением допустимой ошибки до ± 10 см, вероятность ошибки увеличивается примерно в полтора раза и составляет 74 %.

Фундаментальные работы [5—6] посвящены исследованию структуры непериодических колебаний уровня в арктических морях. Авторами выявлены типы барических образований над акваторией Обской Губы, а также предложена методология расчета сгонно-нагонных колебаний в различных пунктах СМП на основе эмпирических прогностических уравнений. В основе методологии лежит использование эмпирических зависимостей колебаний уровня с анемобарическим режимом. Весьма успешно модель проявила себя у мыса Ям-Сале, расположенного в южной части Обской губы, вблизи устья реки Обь. Позже результаты были подтверждены в работе [7]. Авторы, применив гармонический анализ приливов по МНК [8—9], выявили связь уровня на гидрологическом посту Ям-Сале с градиентами атмосферного давления между о. Белый и Усть-Енисейским портом. Результаты показали существенный прогностический потенциал такой связи с заблаговременностью до 18 часов.

В основу исследований [10] легла также работа [5]. Использование ежечасных наблюдений за колебаниями уровня показало, что изменчивость непериодических колебаний в Обской губе у мыса Каменный варьируется в широких пределах. Однако попытка авторов построить модель на статистической основе с точностью до ± 5 см и заблаговременностью до 3—9 часов оказалась неудачной. Градиентный метод прогнозирования уровня с помощью осциляции давления в различных точках, подробно описанный в работе [6], также существенно не улучшил оправдываемость прогнозов. Отметим, что авторы [10] заметили высокую инерционность колебаний уровня Обской губы, однако применение инерционного метода прогнозирования показало, что он способен воспроизвести будущие колебания уровня с оправдываемостью 90 % только на первые 2 часа.

Помимо гидродинамического моделирования и статистического подхода к решению прогнозов колебаний уровня в Обской губе, активно проводились исследования по внедрению комплексных систем, одной из которых является CARDINAL [11]. Комплекс позволяет моделировать нестационарные гидродинамические процессы, распространение растворенных и взвешенных загрязняющих веществ, температуру, соленость и транспорт донных наносов. Для решения гидродинамических моделей система использует численные конечно-разностные методы. Использование данной системы во многом обосновано простотой реализации двумерной задачи по прогнозированию колебаний уровня, а также удобным

развитым интерфейсом. Попытка реализации комплекса CARDINAL в работе [12] позволила достаточно неплохо смоделировать основные тенденции хода уровня и фазовые переходы приливных колебаний. Поочередное включение атмосферного воздействия и касательного напряжения ветра значительно улучшало результаты. Однако при моделировании сгонно-нагонных колебаний модель выдавала серьезную ошибку. Кроме того, реализация комплекса CARDINAL нуждалась в высоком разрешении сетки, что практически невозможно при отсутствии больших вычислительных мощностей. Вследствие этого результаты, полученные в ходе исследований, не позволяют оперативно обеспечивать судоходство в районе мыса Каменный.

Похожий модельный комплекс Delft3D был адаптирован для акватории Обской губы в работе [13]. Комплекс представляет собой модульную структуру, позволяющую подключать к расчету различные блоки в зависимости от решаемой задачи. Для акватории Обской губы авторами построена расчетная сетка с пространственным разрешением до 50 м, а также были заданы поля метеорологических элементов, включающих в себя атмосферный форсинг. Валидация расчетов колебаний уровня проводилась за летний период 2016 г. При этом модельные расчеты приливных колебаний полностью совпали по фазе с фактическими значениями. Несмотря на различия в амплитуде колебаний, комплекс Delft3D оказался приемлемым для навигационных нужд. Однако авторы отметили, что максимальная ошибка в 30 см не обеспечивает достаточной точности для оперативного обеспечения судоходства и модель требует дополнительного подбора управляющих параметров.

В связи с этим разработка новой модели колебаний уровня для акватории Обской губы является бесспорно актуальной задачей. Весьма перспективной представляется идея применения нейронных моделей в прогнозировании уровня, хотя она до настоящего времени не имеет строгой методологии, а большинство исследований выполняется в экспериментальных рамках. Так, работа [14] направлена на повышение точности прогнозирования уровня в прилегающих морях Китая. Авторам удалось существенно добиться увеличения точности прогнозирования, применяя методику гибридной модели сингулярного спектрального анализа (англ. SSA — Singular spectrum analysis), известного также как метод «Гусеница» [15—16], совместно с рекуррентными нейронными сетями с длинной краткосрочной памятью (Long Short-Term Memory — LSTM) [17—19].

Аналогичным образом сети LSTM применялись и в настоящей работе. С помощью метода SSA авторы преобразовали исходный одномерный ряд в многомерный вектор данных с последующим применением метода главных компонент [20]. Результаты показали, что использование данного метода разложения при прогнозировании одномерного ряда колебаний уровня существенно увеличивает оправдываемость прогнозов в сравнении с классическим применением моделей LSTM для одномерного ряда. После проведения многочисленных экспериментов модельные расчеты смогли описать 98 % дисперсии исходного ряда. Однако полученная авторами модель характеризуется малой заблаговременностью, всего на 1 шаг вперед, а увеличение заблаговременности сильно сказывается

на оправдываемости прогнозов. Авторами работы [21] проводились успешные эксперименты по воспроизведению с помощью модели LSTM динамической системы атмосфера-океан, которая представляет собой нелинейную, хаотичную динамику модели Lorenz63. В ходе экспериментов установлена очевидная зависимость увеличения ошибки валидации модели при увеличении заблаговременности.

Аналогичный метод составления гибридных моделей был описан в работе [22]. Авторы дополнили свёрточную нейронную сеть CNN (англ. Convolution Neural Network) [23—25] моделью LSTM для анализа пространственных зависимостей колебаний уровня в северной и экваториальной частях Тихого океана. Это позволило получить наименьшую ошибку при валидации. Разработанная модель на основе матрицы колебаний уровня исследуемого района прогнозирует будущие значения для каждого установленного узла сетки. Выходным прогнозом является карта распределения средних для следующего месяца значений колебаний уровня. При этом в сравнении с классическим методом LSTM время, затрачиваемое на машинное обучение, более чем в 2 раза больше при использовании разработанной гибридной модели и составляет 18 часов. По мнению авторов, разработанный метод может быть применен не только в других локальных регионах, но и в глобальном масштабе, что, несомненно, повышает ее значимость для арктического сектора.

В задачах гидрометеорологии высокий приоритет имеет прогноз траектории движения исследуемой характеристики для анализа ее изменчивости в будущем с заданной дискретностью и заблаговременностью. В работе [26] перед авторами стояла цель тестирования алгоритмов машинного обучения по среднесуточным колебаниям уровня воды в реке Тисе в центральной Европе за период 2006—2020 гг. для составления прогностической траектории изменчивости уровня в течение последующих семи дней. Применение модели LSTM позволило получить наилучшие результаты для заданных временных диапазонов, чем классическая модель персептрона [27—28]. Так, 68,5—76,1 % прогнозов оправдались в заданных интервалах точности.

Целью работы является построение гибридной модели, основанной на совмещенном применении метода сингулярного спектрального анализа (SSA), линейной регрессии и нейронной модели долгой-краткосрочной памяти LSTM (англ. Long Short—Term Memory), а также реализация её для акватории Обской губы в районе мыса Каменного. Отметим, что полученная в данном исследовании модель уже является рабочим прототипом, помогающим в составлении ежедневных оперативных прогнозов с заблаговременностью 12 часов с декабря 2023 г.

1. Материалы и методы

1.1. Гидрографические особенности Обской губы

Объект исследования — акватория Обской губы в районе поселка мыс Каменный (рис. 1), которая является крупным эстуарием Оби и заливом Карского моря, расположенным между полуостровами Ямал и Гыданский на северо-западе




Рис. 1. Район исследования. Село мыс Каменный. Обская губа.

Fig. 1. The research area. The village of cape Kamenny. The Gulf of Ob.

Сибири. Обская губа омывает берега Ямало-Ненецкого автономного округа и простирается примерно на 800 км вдоль побережья. Максимальная ширина залива составляет около 50—60 км, а берега покрыты тундрой и заболочены, что характерно для арктической зоны. Данный регион характеризуется суровым арктическим климатом. Зимние температуры могут опускаться до $-40\text{ }^{\circ}\text{C}$, а летом редко превышают $+10\text{ }^{\circ}\text{C}$.

Обская губа является одним из важнейших источников пресноводного стока в Арктике. Вода имеет низкую соленость из-за большого притока пресной воды р. Оби, причем ежегодный объем стока в Карское море достигает 530 км^3 [29—31]. Гидрологический режим во многом осложнен системой взаимодействия речного стока, морских приливов и ветровых воздействий, что делает данный регион особенно сложным для реализации прогностической модели. Тем не менее, амплитуда самих приливных колебаний невелика и обычно не превышает одного метра.

Важной особенностью гидрологического режима Обской губы является сильная внутрисезонная изменчивость. Её основными факторами служат речной сток, приливные явления, значительный атмосферный форсинг, проявляющийся в виде стонно-нагонных явлений, которые по амплитуде в 2—3 раза превышают

приливные колебания [1]. Формирование сгонно-нагонных колебаний в Обской губе сильно зависит от барических образований над акваторией. Центры циклонов, расположенных к востоку от губы, вызывают нагонные северные ветра, а антициклоны, центры которых находятся к западу, — сгонные южные ветра [32]. Бесспорно, одним из важнейших факторов, влияющих на внутрисезонную изменчивость, является ледовый покров. Большую часть года акватория Обской губы покрыта однолетним льдом. Формирование устойчивого ледового покрова начинается в первой половине октября, а его окончательное становление в среднем приходится на ноябрь [33]. Максимальное развитие припайного льда наблюдается в апреле-мае, а средняя толщина льда на конец апреля достигает 1,4—1,7 м [34]. Разрушение ледового покрова начинается в южной части Обской губы и приходится на конец мая. Только в начале июня в северной части под воздействием сильных ветров и волнения взламывается припай [35]. После становления устойчивого льда формируется подлёдный пограничный слой, который замедляет приливную волну и делает её значительно слабее. За счёт этого уменьшается как высота самого прилива, так и скорость приливных течений [2].

Отметим, что Обская губа имеет важное экономическое значение. Через неё проходит Северный морской путь, связывающий порты Европы и Азии через окраинные моря Северного Ледовитого океана. Залив также служит базой для рыболовства и добычи полезных ископаемых, таких как нефть и газ. В последние годы наблюдается увеличение интереса к развитию инфраструктуры в регионе, включая строительство портов и терминалов для транспортировки углеводородов, одним из которых как раз и является нефтеналивной терминал «*Ворота Арктики*» у поселка мыс Каменный.

1.2. Исходные данные

В качестве входных данных для нейронной модели использовались показания гидрометеорологических приборов, установленных в районе поселка мыс Каменный. Беспроводная метеостанция DAVIS Instruments Vantage Pro 2, предназначенная для измерения и мониторинга погодных условий, передаёт основные метеорологические характеристики на специально разработанный портал. Метеостанция фиксирует множество параметров атмосферы и выбор тех или иных параметров зависит от поставленной задачи. В числе основных предикторов использовались ежечасные измерения направления и скорости ветра, давления и температуры воздуха (табл. 1). Отметим, что учитывались только максимальные порывы скорости ветра за час наблюдений, так как они отражают динамические изменения в атмосфере, которые могут быть связаны с турбулентностью, фронтальными зонами, конвективными процессами и другими атмосферными явлениями. Средняя скорость ветра сглаживает эти изменения, за счёт чего теряется часть важной информации по внутренней структуре ряда, которая могла быть полезной для повышения точности прогнозирования.

Мгновенные данные уровня воды поступали с регистрационно-передающей системы МП-РПС-01 на специальный web-портал. Датчик установлен на жесткой

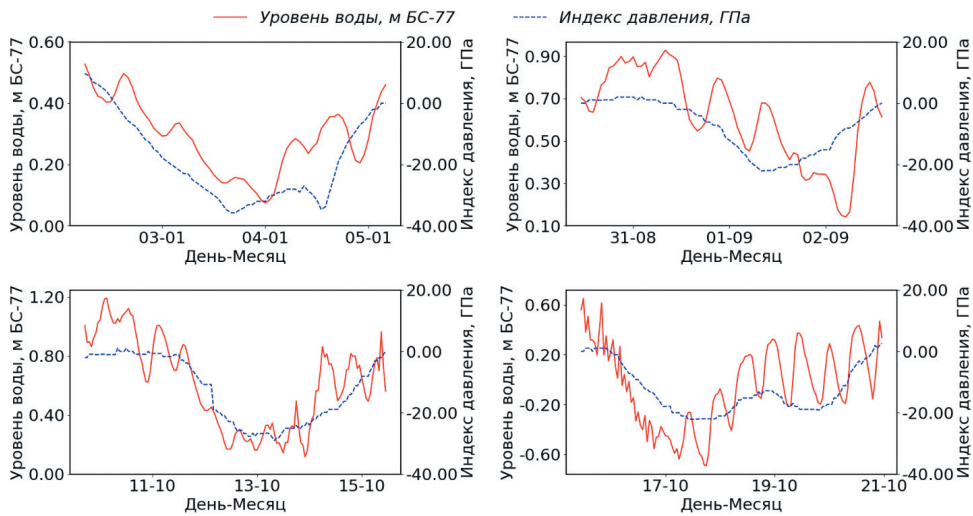


Рис. 2. Сопоставление взаимосвязи колебаний уровня в Обской губе с градиентом давления между Ханты-Мансийском и портом Сабетта при его отрицательной фазе.

Fig. 2. Comparison of the relationship of the level fluctuations in the Gulf of Ob with the pressure gradient between Khanty-Mansiysk and the port of Sabetta during its negative phase.

причальной стенке в защитной металлической трубе для предотвращения его повреждения в периоды ледостава, что позволило получить бесперебойное поступление данных в период с 23 декабря 2023 г. по настоящее время. Измеренные данные приводятся к балтийской системе высот (БСВ-77) с учётом поправки к наиминимуму теоретическому уровню (НТУ). Размер выборки наблюдений за колебанием уровня и метеорологическими характеристиками составляет более 7 тыс. значений. Отметим, что колебания уровня воды использовались также в качестве предиктора, что существенно помогло нейронной модели распознать сложные внутренние связи и закономерности временного ряда.

Поскольку колебания уровня в Обской губе подвержены атмосферному форсингу, то в качестве дополнительных предикторов использован градиент давления между портом Сабетта и Ханты-Мансийском. Значения давления в этих точках находятся в открытом доступе на портале RP5 [36—37]. Было выявлено, что переход его в отрицательную фазу (увеличение давления на юге и уменьшение его на севере), сопровождается формированием устойчивых южных ветров, что приводит к сгонным явлениям в районе мыса Каменный. На рис. 2 представлены оценки взаимосвязи колебаний уровня в Обской губе с градиентом давления между Ханты-Мансийском и портом Сабетта при его отрицательной фазе. Действительно, при повышении отрицательного градиента давления уровень понижается.

Метеорологические параметры использованные
для построения модели колебаний уровня в Обской губе

Meteorological parameters used to build a model of level fluctuations in the Gulf of Ob

Предикторы модели SSA-LR-LSTM	Ед. изм.	Описание
Направление ветра	град.	Среднее значение направления ветра за час измерений
Атмосферное давление	гПа	Среднее значение атмосферного давления за час измерений
Температура воздуха	°С	Минимальное значение температуры за час измерений
Скорость ветра	м/с	Максимальные порывы скорости ветра за час измерений
Индекс давления	гПа	Разность давления между пунктами Ханты-Мансийск и Сабетга
Фактический уровень воды	м	Мгновенный уровень воды с уровнемера в БСВ с учетом поправки к НТУ
Трендовая компонента уровня воды	м	Трендовая компонента, рассчитанная методом «Гусеница-SSA»
Периодическая компонента уровня воды	м	Периодическая компонента рассчитанная методом «Гусеница-SSA»

1.3. Метод сингулярного спектрального анализа Гусеница-SSA

«Гусеница-SSA» (англ. SSA — Singular spectrum analysis) является мощным методом анализа временных рядов. Например, методика совместного использования гусеницы и рекуррентных нейронных моделей для прогнозирования колебаний уровня воды успешно применялась авторами в работе [14]. Подробно данный метод изложен в работах [15—16]. Он получил широкое распространение благодаря своей эффективности при анализе нелинейных и недетерминированных временных рядов. Суть его состоит в следующем: сначала из исходного одномерного временного ряда составляется многомерный вектор данных; выбирается «длина окна» (или глубина вложения) L ($1 < L < N$) для выборки $X = (X_1, X_2, \dots, X_N)$ длиной N , где $N > 1$, а X — не нулевая последовательность. Обычно длина окна выбирается исходя из особенностей временного ряда, в частности, основываясь на его периодической составляющей, которую можно легко выделить вейвлет-разложением или же любыми другими стандартными статистическими методами. Для среднемесячных данных длина окна выбирается обычно равной 12 мес. Ширина окна вычисляется, как $K = N - L + 1$. Таким образом, одномерный временной ряд преобразуется в многомерный вектор данных, также называемый траекторной матрицей:

$$X = (X_1, X_2, \dots, X_N) = \begin{bmatrix} X_1 & X_2 & \dots & X_L \\ X_2 & X_3 & \dots & X_{L+1} \\ \vdots & \vdots & \ddots & \vdots \\ X_K & X_{L+1} & \dots & X_N \end{bmatrix}.$$

Аналогично методу главных компонент создается подобие автокорреляционной матрицы $S = X \cdot X^T$. Далее происходит сингулярное разложение этой матрицы:

$$X = \sum V_i,$$

где $V_i = U_i \cdot U_i^T \cdot X$, $i = 1, \dots, L$. U_i — ортонормированная система собственных векторов матрицы S . Результатом этого этапа являются собственные числа и соответствующие им собственные векторы, которые используются для выделения значимых компонент временного ряда. Их последующая группировка позволяет выделить в исходных данных такие составляющие как тренд, сезонные колебания и шум. Таким образом, выбираются наиболее значимые матрицы V_i и переводятся в ряд длины N . Результатом является разложение временного ряда на интерпретируемые аддитивные составляющие [38]. Метод «Гусеница-SSA» нашел широкое применение в таких задачах, как выделение тренда, периодических компонент, сглаживание нестационарных рядов и т. д.

1.4. Нейронные сети

В работе для построения нейронной модели Обской губы в районе поселка мыс Каменный использовалось машинное обучение [39—44]. Основная идея машинного обучения заключается в том, чтобы позволить компьютеру автоматически находить закономерности в данных и использовать их для решения задач без явного программирования. В работе применялось обучение с учителем (supervised learning) [43], где на основе известных входных и выходных данных строится функция, аппроксимирующая зависимость $f: X \rightarrow Y$. Проверкой степени аппроксимации является наименьшая величина ошибки между фактическими и модельными значениями. Оптимизация сложных функций осуществляется с помощью метода градиентного спуска, широко используемого в нейронных сетях [45—47].

Построение архитектуры нейронной сети — нетривиальная задача, особенно для нелинейных гидрометеорологических характеристик. Существующие нейронные сети имеют различную структуру обучения, способы определения весовых коэффициентов, параметры, определяющие отклик нейронов сети на входные данные (функции активации) и т.д. [48]. В работе использовались рекуррентные нейронные сети (RNN) [49] и их модификации, такие как долгая краткосрочная память (LSTM) [17, 50] и двунаправленная LSTM (BiLSTM) [51]. Эти архитектуры эффективны для обработки временных рядов, так как способны учитывать долговременные зависимости и обрабатывать данные в двух направлениях. В работе [21] было показано, что применение слоя BiLSTM способствует снижению ошибки валидации модели.

Для повышения устойчивости моделей применяются методы регуляризации, такие как Dropout, который случайным образом отключает нейроны, предотвращая переобучение [52]. Однако применение метода Dropout не всегда улучшает результаты. Эксперименты в настоящей работе показали, что использование Dropout не улучшило результаты, а лишь увеличило время обучения.

Функция активации напрямую определяет то, как нейроны сети будут реагировать на входные данные [53]. Наиболее часто используются линейная функция, гиперболический тангенс и сигмоида. В настоящей работе в скрытых слоях использовался гиперболический тангенс, который центрирует данные вокруг нуля и упрощает обучение. В выходном слое применялась сигмоидная функция, нормализующая данные в диапазоне от 0 до 1. Стоит отметить, что выбор функций активации и параметров архитектуры не имеет строгой методологии и осуществлялся индивидуально, исходя из задач исследования.

2. Результаты и их обсуждение

Моделирование прогностических колебаний уровня воды в Обской губе можно разделить на несколько этапов. В начале первого этапа происходит первичная обработка исходного ряда. Поскольку в расчетах используются натурные характеристики с ежечасной дискретностью, то выборки данных сильно зашумлены и имеют многочисленные выбросы. Для сглаживания значений успешно применялся статистический метод Гусеница-SSA. Благодаря известной библиотеке «pyts» (Python) и её модулю Singular-Spectrum-Analysis исходную выборку можно легко разбить на три основные статистические составляющие: тренд, периодические колебания и шум.

Преимущество метода «Гусеница-SSA» заключается в способности эффективно справляться с нелинейными и недетерминированными временными рядами, что позволяет реконструировать любую выборку данных с удаленным в ней шумом. Как правило, к сглаженной группе компонент относятся первые собственные векторы, определяющие тренд или тенденцию временного ряда, поэтому на первом этапе моделирования необходимо избавиться от лишнего шума, который может привести к существенным ошибкам во время машинного обучения нейронной сети. При малой величине длины окна L , метод «Гусеница-SSA» позволил получить сглаженный ежечасный ход метеорологических характеристик. В качестве примера на рис. 3 представлен график температуры воздуха на мысе Каменный за первые три недели с начала наблюдений. Отметим, что глубина вложения L соответствует величине заблаговременности модели и полусуточной динамике колебаний уровня воды, которая составляет 12 ч. Действительно, сглаженный ряд очень хорошо аппроксимирует фактические значения температуры, отсекая шумовую компоненту.

Аналогичным образом из фактических данных колебаний уровня воды выделяются трендовая и циклическая компоненты, которые в последующем используются в качестве предикторов модели. На рис. 4 представлен пример разложения колебаний уровня воды на отдельные составляющие методом сингулярного спектрального анализа с длиной окна $L = 12$. По сути, было выполнено разложение МНК матрицы размером 12×7089 . Из рис. 4 видно, что 1 ГК отражает в основном длительную тенденцию изменений уровня, 2 ГК — полусуточную периодичность приливных колебаний, а 3 ГК — шумовую компоненту. Сумма первых двух компонент описывает 97 % дисперсии временного ряда, 3 ГК — 3 % дисперсии, поэтому она не учитывалась в дальнейших расчётах.




Рис. 3. Сопоставление фактических срочных значений температуры воздуха на м. Каменном с их сглаженными значениями метода «Гусеница-SSA» за 25.12.2023—13.01.2024.

Fig. 3. Comparison of actual urgent air temperature values at Cape Kamennoye with their smoothed values using the “Caterpillar-SSA” method for 12.25.2023—01.13.2024.




Рис. 4. Результаты разложения фактических ежечасных значений уровня воды на м. Каменном за январь 2024 г. методом главных компонент:

a) — фактический уровень, *б)* — 1ГК, *в)* — 2ГК, *г)* — 3ГК.

Fig. 4. The results of the decomposition of the actual hourly values of the water level at cape Kamenny in January 2024 by the method of main components:

a) — the actual level, *b)* — 1PC, *c)* — 2PC, *d)* — 3PC.

Перед созданием архитектуры нейронной сети следует этап препроцессинга, который включает в себя нормирование входных данных. Функция `MinMaxScaler` (Python) нормализует исходные данные в промежутке от 0 до 1. Масштабирование данных можно представить следующей формулой:

$$x' = \frac{(X - X_{\min})}{(X_{\max} - X_{\min})}.$$

Далее формируется матрица входных данных, которая используется в машинном обучении. Матрица включает в себя пять сглаженных методом «Гусеница-SSA» метеорологических параметров, задающих основные тенденции атмосферного воздействия, исходный ряд колебаний уровня воды и его трендовые и периодические аддитивные составляющие. Исходная матрица данных (7100 значений) разделяется на обучающую (5700) и валидационную (1420) выборки в отношении 8:2. Эксперименты показали, что гидрологический блок Обской губы достаточно быстро реагирует на изменчивость атмосферы. Для прогнозирования колебаний уровня с заблаговременностью 12 часов достаточно использовать всего 12 предшествующих гидрометеорологических значений. Увеличение количества данных, подаваемых на вход модели, приводит к усложнению архитектуры и созданию более сложных внутренних зависимостей, которые увеличивают ошибки валидации.

Этап реализации архитектуры нейронной сети состоит в правильном выборе количества нейронов, скрытых слоёв, методов регуляризации и оптимизации данных. В настоящей работе построена сеть LSTM, которая включает в себя входной слой, три скрытых слоя LSTM, один скрытый слой BiLSTM с функцией гиперболического тангенса и выходной слой с сигмоидной функцией активации. В ходе многочисленных экспериментов установлено, что такое количество скрытых слоев является оптимальным для описания исходной функции. На рис. 5 представлена схема архитектуры нейронной модели LSTM.

На производительность нейронной сети влияет применение подходящего оптимизатора, роль которого заключается в поиске наилучших весов нейронной сети и в минимизации функции потерь путем настраивания параметров модели. Одним из наиболее эффективных алгоритмов оптимизации для обучения рекуррентных нейронных сетей служит оптимизатор «adam», который использовался в настоящей работе. Он эффективно работает с большими и малыми градиентами, помогает ускорить сходимость и является достаточно устойчивым [54].

Выбор числа эпох необходимого для машинного обучения напрямую определяет качество итоговой модели. Однако до сих пор не существует чёткого ответа на вопрос о правильном выборе оптимального количества эпох. Небольшое их количество может привести к недообучению, так как в этом случае модель будет слишком простой для усвоения всех закономерностей и внутренних связей между предикторами. И, наоборот, большое количество эпох может привести к переобучению, поскольку модель, кроме основных закономерностей, будет усваивать случайный шум в данных. Как правило, такие модели хорошо обучаются, однако при работе с тестовой выборкой создаются большие ошибки. Единственной мерой,




Рис. 5. Схематичное представление архитектуры нейронной сети LSTM.

Fig. 5. Schematic representation of the architecture of the LSTM neural network.

позволяющей определять оптимальное количество эпох, является анализ графика функции потерь. Обычно он состоит из двух функций: потери во время обучения и потери во время валидации, которые находятся вычислением среднеквадратической ошибки в конце каждой эпохи. В настоящей работе было установлено, что наличие 50 эпох для машинного обучения является более чем достаточным. На рис. 6 представлен совмещенный график распределения функций потерь. Видно, что к концу обучающего периода веса модели обновляются на достаточно малую величину. Итоговая модель выбирались с помощью метода ModelCheckpoint (Python), который позволяет сохранять веса во время обучения с наименьшим значением ошибки валидации.

Количество нейронов напрямую определяет взаимодействие модели с данными. Обычно входной слой имеет число нейронов, соответствующее размерности входных данных. Однако в случаях, когда нужно распознать более сложные взаимосвязи между предикторами, число нейронов повышают. Отметим, что создаваемая модель имеет дело с мелкой дискретностью реальных гидрометеорологических параметров, которые по своей природе являются недетерминированными. Рассматривая ежечасную взаимосвязь колебаний уровня с параметрами атмосферы, коэффициент корреляции не сможет выявить наличие связи, так как атмосфера является нелинейной динамической системой. Анализ наличия линейной связи ежечасных колебаний уровня с атмосферными параметрами показал её отсутствие. Данная связь проявляется только в отдельных локальных случаях. Таким образом, эмпирически было выявлено, что для входного слоя оптимальным будет




Рис. 6. Зависимость функций потерь от количества эпох в процессе машинного обучения. Модель имеет 3 скрытых слоя LSTM, 1 скрытый слой BiLSTM, 128 нейронов в скрытых слоях.

Fig. 6. The dependence of loss functions on the number of epochs in the machine learning process. The model has 3 hidden LSTM layers, 1 hidden BiLSTM layer, 128 neurons in hidden layers.

наличие 256 нейронов. Это позволяет лучше усвоить сложные структуры входных переменных и оценить их взаимосвязи с прогнозируемой функцией. Отметим, что дальнейшее увеличение нейронов не приводит к улучшению результатов, а даже ухудшает их, создавая случайные нежелательные связи. Выходной слой имеет только 1 нейрон, отвечающий за формирование интервального прогноза на 12 часов вперёд. Наиболее неопределенным остается количество нейронов в скрытых слоях. В табл. 2 показано, как меняется ошибки валидации модели в зависимости от числа нейронов и количества скрытых слоев.

Таблица 2

Средняя квадратическая (RMSE) и средняя абсолютная (MAE) ошибки масштабированных колебаний уровня воды, рассчитанные по валидационным данным. Заблаговременность прогнозов составляет 12 часов

The mean square (RMSE) and mean absolute (MAE) errors of scaled water level fluctuations calculated from validation data. The lead time for the run-through is 12 hours

Кол-во скрытых слоёв	16 нейронов		128 нейронов	
	RMSE	MAE	RMSE	MAE
BiLSTM	0,023	0,015	0,020	0,014
LSTM, BiLSTM	0,020	0,013	0,019	0,014
LSTM (x2), BiLSTM	0,018	0,012	0,017	0,011
LSTM (x3), BiLSTM	0,018	0,012	0,015	0,010

Выявлено, что наличие 128 нейронов в четырех скрытых слоях даёт наименьшую ошибку валидации модели. Мерой ошибки служит функция потерь, которая представляет собой средний квадрат ошибки прогноза (англ. Mean Squared Error, MSE). Дополнительно для анализа результатов оценивалась средняя абсолютная ошибка (англ. Mean Absolute Error, MAE) и среднеквадратическая ошибка (англ. Root Mean Squared Error, RMSE). Это наиболее популярные метрики для оценки точности моделей машинного обучения, особенно в задачах регрессии. Их можно представить следующими формулами:

$$MSE = \frac{1}{k} \sum_{i=1}^k (\phi_{A,i} - \hat{\phi}_{A,i})^2, \quad RMSE = \sqrt{MSE}, \quad MAE = \frac{1}{k} \sum_{i=1}^k |\phi_{A,i} - \hat{\phi}_{A,i}|.$$

На рис. 7 а представлено распределение фактических значений колебаний уровня и модельных значений, полученных при валидации модели. Отметим, что колебания уровня для удобства представлены относительно Балтийской системы высот (БСВ-77). Как и следовало ожидать, наибольшие трудности модель испытывает при описании сгонно-нагонных явлений. Однако, использование совмещенного метода SSA и LSTM позволяет хорошо описать основные закономерности и тенденции исходного ряда за счет дополнительного учета трендовой и периодической компонент колебаний уровня воды, минимизируя ошибку. На сегодняшний день, основной и наиболее актуальной проблемой является увеличение заблаговременности. Наибольшие ошибки приходится на период с ноября по декабрь. Связано это с еще несформированным на Обской губе ледовым покровом, который в значительной степени снижает атмосферное воздействие на поверхность воды и уменьшает амплитуды приливных колебаний. Отметим, что большая часть данных, подаваемых модели на обучение, характеризовались наличием устойчивого однолетнего льда в области проводимых исследований. Очевидно, увеличение размера выборки в будущем позволит лучше усваивать эти взаимосвязи и уменьшит ошибку модели в летний период.

Итоговым этапом расчета прогностических значений колебаний уровня, является использования статистического метода парной линейной регрессии, который в общем виде можно представить как $y = ax + b + \varepsilon$, где y — зависимая переменная, в качестве которой используются фактические значения уровня, x — независимая переменная, полученная по модельным расчетам уровня. Рассчитанные для каждого прогноза коэффициенты регрессии a и b учитываются для их корректировки. Использование регрессионного анализа существенно снижает образование случайных выбросов в прогнозах, а также минимизирует ошибку. На рис. 7 б показано, что с учетом корректировки итогового прогноза методом парной линейной регрессии повысилась точность описания сгонно-нагонных явлений, а также предсказания амплитуды приливных колебаний воды. Так, среднеквадратическая ошибка (RMSE) уменьшилась почти в полтора раза и составила 0,012.

В прогнозирование гидрометеорологических параметров решающую роль имеет максимально возможный прогностический потенциал модели. Повышение заблаговременности особенно в таком экономически значимом районе, как Обская губа может играть критическую роль для своевременного планирования судовых




Рис. 7. Временной ход фактических и модельных значений колебаний уровня, приведенного к БС-77 в районе мыса Каменного до применения парной линейной регрессии (а) и после (б).

Fig. 7. Distribution of actual and model values of fluctuations in the level reduced to BS-77 in the cape Kamenny area before the application of paired linear regression (a) and after (b).

логистических операций. В табл. 3 представлено изменение ошибки в зависимости от повышения заблаговременности. Отметим, что повышение количества данных на выходе модели приводит к эквивалентному увеличению размерности матрицы, подаваемой на вход. Кроме того, результаты расчетов свидетельствуют

об увеличении ошибок модели в зависимости от увеличения горизонта планирования. При прогнозе более чем на 12 часов ошибка модели резко повышается. Расширение гидрометеорологической сети в районе Обской губы и дополнение модели новыми гидрометеорологическими параметрами может существенно усилить её прогностический потенциал.

Таблица 3

Средняя квадратическая (RMSE) и средняя абсолютная (MAE) ошибки масштабированных колебаний уровня воды, в зависимости от заблаговременности модели

The mean square (RMSE) and mean absolute (MAE) errors of scaled water level fluctuations, depending on the timing of the model

Заблаговременность, ч	RMSE	MAE
6	0,014	0,007
12	0,015	0,010
24	0,197	0,040
48	0,100	0,074

Заключение

В настоящей работе была представлена современная методика прогнозирования колебаний уровня воды в акватории Обской губы, важной части Северного морского пути и ключевой зоны для транспортировки нефтепродуктов и других стратегических грузов. Модель SSA-LR-LSTM основана на совместном использовании метода сингулярного спектрального анализа (SSA), линейной регрессии и нейронных сетей с долгой краткосрочной памятью (LSTM). Эти методы позволяют учитывать сложные взаимосвязи между метеорологическими параметрами и уровнем воды, что важно для повышения точности прогнозов. Модель была протестирована в реальных условиях и внедрена для оперативного обеспечения судоходства в районе поселка мыс Каменный. Модель SSA-LR-LSTM способна прогнозировать уровень воды с заблаговременностью до 12 часов и имеет значительный потенциал для улучшения своих показателей. Анализ ошибок показал, что модель хорошо описывает основные тенденции и закономерности исходного ряда, несмотря на сложные гидрометеорологические условия. Основной проблемой является увеличение ошибки валидации при увеличении заблаговременности. Решением может служить накопление размера выборки входных данных на основе будущих гидрометеорологических наблюдений и добавление новых предикторов за счет расширения сети гидрометеорологических наблюдений в акваториях Северного морского пути. Внедрение модели в существующие информационные системы для принятия решений оперативного судоходства могло бы значительно снизить риски, связанные с неожиданными возникновениями сгонно-нагонных колебаний.

Таким образом, сочетание традиционных методов анализа данных с современными технологиями машинного обучения может значительно повысить точность прогнозирования колебаний уровня воды для таких сложных гидрографических

условий, как Обская губа. Разработанная модель уже используется в оперативном обеспечении судоходства, и дальнейшее ее совершенствование и расширение возможностей может привести к значительным преимуществам в областях экономики и безопасности судоходства в Арктическом регионе.

Список литературы

1. Лапин С. А. Гидрологическая характеристика Обской губы в летне-осенний период // *Океанология*. 2011. Т. 51. № 6. С. 1—10.
2. Войнов Г. Н., Головин Н. В., Кубышкин Н. В. и др. К решению проблемы прогноза уровня моря у мыса Каменный в Обской губе // *Проблемы Арктики и Антарктики*. 2023. Т. 69. № 1. С. 29—43. doi:10.30758/0555-2648-2023-69-1-29-43.
3. Кулаков М. Ю., Макштас А. П., Шутин С. В. AARI—IOCM — совместная модель циркуляции вод и льдов Северного Ледовитого океана // *Проблемы Арктики и Антарктики*. 2012. Т. 92. № 2. С. 6—18.
4. Войнов Г. Н. Гармонический анализ морских приливов по срочным наблюдениям за уровнем моря. // *Метеорология и гидрология*. 2009. № 7. С. 79—91.
5. Корт В. Г. Непериодические колебания уровня воды в Арктических морях и способы их прогноза. М.: Труды ААНИИ, 1941. Т. 175. 163 с.
6. Лабзовский Н. А. Непериодические колебания уровня моря. М.: Гидрометеорологическое издательство. Ленинград, 1971. 237 с.
7. Войнов Г. Н., Пискун А. А. Приливные и сгонно-нагонные колебания уровня у мыса Ям-Сале (Обская губа) // *Проблемы Арктики и Антарктики*. 2016. Т. 110. №4. С. 51—66.
8. Войнов Г. Н. Методика контроля и редакции многолетних временных рядов уровня моря // *Проблемы Арктики и Антарктики*. 2011. № 4. С. 51—61.
9. Кондрин А. Т. Методы гармонического анализа приливов // *Вестник Московского университета. География*. 2008. № 5. С. 26—30.
10. Ягвкина Е. А., Хаймина О. В. Непериодические колебания уровня моря у мыса Каменный (Обская губа Карского моря). Закономерности изменчивости и возможность прогноза // *Труды II Всероссийской конференции «Гидрометеорология и экология: достижения и перспективы развития»*. 2019. С. 734—738.
11. Клеванный К. А. Смирнова Е. В. Использование программного комплекса Cardinal // *Вестник государственного университета морского и речного флота им. адмирала С. О. Макарова*. 2009. № 1. С. 152—160.
12. Сидорова Л. Д., Хаймина О. В. Моделирование колебаний уровня моря в Обской губе с использованием программного комплекса Cardinal // *Морские исследования и образование (MARESEDU)-2022: Труды XI Международной научно-практической конференции*. Москва. 2022. С. 257—260.
13. Чанцев В. Ю., Гудошников Ю. П., Плешанов Д. А. и др. Многофункциональная комплексная модель водной системы Обской губы // *Современные подходы и перспективные технологии в проектах освоения нефтегазовых месторождений российского шельфа*. 2018. Т. 36. № 4. С. 139—148.
14. Xie Y., Zhou S., Wang F. Prediction analysis of sea level change in the China Adjacent seas based on Singular Spectrum Analysis and Long Short-Term Memory Network // *Marine Science and Engineering*. 2024. Vol. 12. № 1397. P. 1—13. doi:10.3390/jmse12081397.
15. Голядина Н. Э. Метод «Гусеница—SSA»: анализ временных рядов: Учеб. Пособие. — СПб, 2004. 76 с.
16. Golyadina N., Osipov E. The «Caterpillar»—SSA method for analysis of time series with missing values // *Journal of Statistical Planning and Inference*. 2007. Vol. 137. № 8. P. 2642—2653. doi:10.1016/j.jspi.2006.05.014.
17. Hochreiter S., Schmidhuber J. Long Short-Term Memory // *Neural Computation*. 1997. Vol. 9. № 8. P. 1735—1780. doi: 10.1162/neco.1997.9.8.1735.

18. Sak H., Senior A., Beaufays F. Long Short-Term Memory based recurrent neural network architectures for large vocabulary speech recognition // ArXiv. 2014. doi: 10.48550arXiv.1402.1128
19. Gers F. A., Schmidhuber J., Cummins F. Learning to Forget: Continual Prediction with LSTM // Neural Computation. 2000. Vol. 12. № 10. P. 2451—2471. doi: 10.1162/089976600300015015.
20. Малинин В. Н., Гордеева С. М. Физико-статистический метод прогноза океанологических характеристик (на примере Северо-Европейского бассейна). М.: Российский государственный гидрометеорологический университет. Мурманск: ПИНРО, 2003. 164 с.
21. Soldatenko S., Angudovich Y. Using Machine Learning for Climate Modeling: Application of Neural Networks to a Slow-Fast Chaotic Dynamical System as a Case Study // Climate 2024. Vol. 12. № 189. doi:10.3390/cli12110189. 13 p.
22. Braakmann-Folgmann A., Roscher R., Wenzel S., et al. Sea Level Anomaly Prediction using Recurrent Neural Networks // Proceedings of the 2017 conference on Big Data from Space. 2017. doi: 10.48550/arXiv.1710.07099.
23. Stutz D. Understanding Convolutional Neural Networks // Seminar Report, Current Topics in Computer Vision and Machine Learning, Visual Computing Institute, RWTH Aachen University. 2014. 23 p.
24. Zeiler D. M., Fergus R. Visualizing and Understanding Convolutional Networks // Conference: European Conference on Computer. 2014. Vol. 8689. P. 818—833. doi: 10.1007/978-3-319-10590-1_53.
25. Lin S., Zhang J. Generalization Bounds for Convolutional Neural Networks // ArXiv. 2019. 30 p. doi: 10.48550/arXiv.1910.01487.
26. Vizi Z., Batki B., Rátki, L. et al. Water level prediction using long short-term memory neural network model for a lowland river: a case study on the Tisza River, Central Europe // Environmental Sciences Europe. 2023. Vol. 35. № 92. 19 p. doi: 35.10.1186/s12302-023-00796-3.
27. Сергеев А. П., Тарасов Д. А. Введение в нейросетевое моделирование: учебное пособие. М.: Екатеринбург: Уральский федеральный университет имени первого Президента России Б. Н. Ельцина, 2017. 128 с.
28. Вакуленко С. А., Жихарева А. А. Практический курс по нейронным сетям: учебное пособие. М.: СПб: Университет ИТМО, 2018. 71 с.
29. Иванов В. В. Водный баланс и водные ресурсы суши Арктики // Труды ААНИИ. 1976. Т. 323. С. 4—24.
30. Иванов В. В. Гидрологический режим низовьев и устьев рек Западной Сибири и проблема оценки его изменений под влиянием территориального перераспределения водных ресурсов // Проблемы Арктики и Антарктики. 1980. № 55. С. 20—43.
31. Иванов В. В., Осипова И. В. Сток Обских вод в море и его многолетняя изменчивость // Труды ААНИИ. 1972. Т. 297. С. 86—91.
32. Пискун, А. А., Войнов Г. Н. Сгонно-нагонные колебания уровня воды в Новом Порту (Обская губа) // Проблемы Арктики и Антарктики. 2020. Т. 66. № 1. С. 20—37. doi: 10.30758/0555-2648-2020-66-1-20-37.
33. Войнов Г. Н., Налимов Ю. В., Пискун А. А. и др. Основные черты гидрологического режима Обской и Тазовской губ (лед, уровни, структура вод). М.: СПб.: Нестор-История, 2017. 192 с.
34. Ким С. Д., Финагенов О. М., Уварова Т. Э. Определение ледовых нагрузок на сооружения континентального шельфа по нормам различных стран // Вести газовой науки. 2013. Т. 14. № 3. С. 97—103.
35. Тарасенко А. Д., Селюженков В. В., Сандалюк Н. В. и др. Исследование ледовой обстановки Обской губы по современным спутниковым данным в 2007—2017 гг // Проблемы Арктики и Антарктики. 2022. Т. 68. № 1. С. 48—63. doi: 10.30758/0555-2648-2021-68-1-48-63. EDN JVPINB.
36. RP5.ru — Расписание Погоды. [Электронный ресурс]. Режим доступа: [https://rp5.ru/Погода_в_Сабетте_\(аэропорт\)](https://rp5.ru/Погода_в_Сабетте_(аэропорт)). (дата обращения: 21.12.2024).
37. RP5.ru — Расписание Погоды. [Электронный ресурс]. Режим доступа: [https://rp5.ru/Погода_в_Ханты-Мансийске_\(аэропорт\)](https://rp5.ru/Погода_в_Ханты-Мансийске_(аэропорт)). (дата обращения: 21.12.2024).
38. Вохмянин С. В., Сенашов С. И. Метод «Гусеница—SSA» как инструмент прогнозирования состояния финансового рынка // Актуальные проблемы авиации и космонавтики. 2010. Т. 1. № 6. С. 409—410.
39. Flach P. Machine Learning: The Art and Science of Algorithms That Make Sense of Data. Cambridge University Press. 2012. doi: 10.1017/CBO9780511973000.

40. Laurent Y. Introduction to Machine Learning. ArXiv. 2024. 649 p. doi: 10.48550/arXiv.2409.02668.
41. Stephen M. Machine Learning: An Algorithmic Perspective. Chapman and Hall/CRC. 2014. 457 p. doi: 10.1201/b17476.
42. Mohri M., Rostamizadeh A., Talwalkar A. Foundations of Machine Learning. Massachusetts Institute of Technology. 2012. 504 p.
43. Миронов А. М. Машинное обучение. Часть 1: учебное пособие. М.: Москва: МГУ, 2018. 83 с.
44. Trask W. A. Grokking Deep Learning. Manning Publications. 2019. 336 p.
45. Tapkir A. A Comprehensive Overview of Gradient Descent and its Optimization Algorithms // IARJSET. 2023. P. 37—45. doi: 10.10.17148/IARJSET.2023.101106.
46. Ruder S. An overview of gradient descent optimization algorithms. ArXiv. 2016. 12 p. doi: 10.48550/arXiv.1609.04747.
47. Гасников А. В. Современные численные методы оптимизации. Метод универсального градиентного спуска. 2 издание, дополненное. М.: Москва: МФТИ (государственный университет), 2018. 181 с.
48. Anthony M., Bartlett P. L. Neural Network Learning: Theoretical Foundations. Cambridge University Press. 1999. doi:10.1017/CBO9780511624216
49. Bianchi F. M., Maiorino E., Kampffmeyer M. et al. An overview and comparative analysis of Recurrent Neural Networks for Short Term Load Forecasting. ArXiv: Neural and Evolutionary Computing. 2017. 41 p. doi: 10.48550/arXiv.1705.04378.
50. Van Houdt G., Mosquera C., Nápoles G. A. Review on the Long Short—Term Memory Model // Artificial Intelligence Review. 2020. Vol. 53. P. 5929—5955. doi: 10.1007/s10462-020-09838-1.
51. Graves A., Schmidhuber J. Framewise phoneme classification with bidirectional LSTM networks / Proceedings of the International Joint Conference on Neural Networks. 2005. Vol. 4. P. 2047—2052. doi:10.1109/IJCNN.2005.1556215.
52. Nusrat I., Sung-Bong J. A Comparison of Regularization Techniques in Deep Neural Networks // Symmetry. 2018. Vol. 10. № 11. doi: 10.648.10.3390/sym10110648.
53. Akgül İ. Activation functions used in artificial Neural Networks // Academic Studies in Engineering. 2023. P. 42—58.
54. Jais I. K. M., Ismail R. A., Nisa S. Q, N, Adam Optimization Algorithm for Wide and Deep Neural Network // Knowledge Engineering and Data Science. 2019. Vol. 2. № 1. P. 41—46. doi: 10.17977/um018v2i12019.

References

1. Lapin S. A. Hydrological characteristics of the Ob Bay in the summer-autumn period. *Okeanologiya = Oceanology*. 2011;51(6): (1—10). (In Russ.).
2. Voynov G. N., Golovin N. V., Kubyshev N.V., et al. Towards solving the problem of sea level forecast near cape Kamenny in the Ob Bay. *Problemy Arktiki i Antarktiki = Problems of the Arctic and Antarctic*. 2023;69(1): (29—43). doi:10.30758/0555-2648-2023-69-1-29-43. (In Russ.).
3. Kulakov M. Yu., Makshtas A. P., Shutilin S. V. AARI—IOCM — joint model of water and ice circulation in the Arctic Ocean. *Problemy Arktiki i Antarktiki = Problems of the Arctic and Antarctic*. 2012;92(2): (6—18). (In Russ.).
4. Voynov G. N. Harmonic analysis of marine tides from regular sea level observations. *Meteorologiya i gidrologiya = Meteorology and hydrology*. 2009;(7): (79—91). (In Russ.).
5. Kort V. G. *Nepiodicheskie kolebaniya urovnya vody v Arkticheskikh moryakh i sposoby ikh prognoza = Non-periodic fluctuations of water level in the Arctic Seas and methods of their prediction*. Moscow: ANII Transactions, 1941: 163 p. (In Russ.).
6. Labzovskiy N. A. *Nepiodicheskie kolebaniya urovnya moray = Non-periodic fluctuations of sea level*. Leningrad: Hydrometeorological publishing house, 1971: 237 p. (In Russ.).
7. Voynov G. N., Piskun A. A. Tidal and wind-driven sea level oscillations near Yam-Sale cape (Ob Bay). *Problemy Arktiki i Antarktiki = Problems of the Arctic and Antarctic*. 2016;110(4): (51—66). (In Russ.).
8. Voynov G. N. Methodology for control and editing long-term sea level time series. *Problemy Arktiki i Antarktiki = Problems of the Arctic and Antarctic*. 2011;(4): (51—61). (In Russ.).

9. Kondrin A. T. Methods of harmonic tide analysis. *Vestnik Moskovskogo Universiteta. Geografiya = Bulletin of Moscow University. Geography*. 2008;(5): (26—30). (In Russ.).
10. Yagovkina E. A., Khaymina O. V. Non-periodic sea level fluctuations near cape Kamenny (Kara Sea, Ob Bay). Patterns of variability and predictability. *Trudy II Vserossiyskoy konferentsii «Gidrometeorologiya i ekologiya: dostizheniya i perspektivy razvitiya» = Proceedings of the II All-Russian Conference “Hydro-meteorology and Ecology: Achievements and Prospects”*. 2019: (734—738). (In Russ.).
11. Klevenny K. A., Smirnova E. V. Use of the Cardinal software package. *Vestnik gosudarstvennogo universiteta morskogo i rechnogo flota im. admirala S.O. Makarova = Herald of the State University of Maritime and River Fleet named after Admiral S.O. Makarov*. 2009;1: (152—160). (In Russ.).
12. Sidorova L. D., Khaymina O. V. Modeling Sea level fluctuations in the Ob Bay using the Cardinal software complex. *Morskie issledovaniya i obrazovanie (MARESEDU)—2022: Trudy XI Mezhdunarodnoy nauchno-prakticheskoy konferentsii = Marine Research and Education (MARESEDU)—2022: Proceedings of the XI International Scientific—Practical Conference*. 2022: (257—260). (In Russ.).
13. Chantsev V. Yu., Gudoshnikov Yu. P., Pleshnikov D. A., et al. Multifunctional integrated model of the Ob Bay aquatic system. *Modern approaches and promising technologies in projects for the development of oil and gas fields on the Russian shelf*. 2018;36(4): (139—148). (In Russ.).
14. Xie Y., Zhou S., Wang F. Prediction analysis of sea level change in the China Adjacent seas based on Singular Spectrum Analysis and Long Short-Term Memory Network. *Marine Science and Engineering*. 2024;12(1397):1—13. doi:10.3390/jmse12081397.
15. Golyadina N. E. *Metod «Gusenitsa» — SSA: analiz vremennykh ryadov = “Caterpillar”—SSA method: Time series analysis*. St. Petersburg, 2004: 76 p. (In Russ.).
16. Golyadina N., Osipov E. The “Caterpillar”—SSA method for analysis of time series with missing values. *Journal of Statistical Planning and Inference*. 2007;137(8):2642—2653. doi: 10.1016/j.jspi.2006.05.014.
17. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation*. 1997;9(8):1735—1780. doi: 10.1162/neco.1997.9.8.1735.
18. Sak H., Senior A., Beaufays F. Long Short-Term Memory based recurrent neural network architectures for large vocabulary speech recognition. *ArXiv*. 2014: 1—5 p. doi: 10.48550arXiv.1402.1128.
19. Gers F. A., Schmidhuber J., Cummins F. Learning to Forget: Continual Prediction with LSTM. *Neural Computation*. 2000;12(10):2451—2471. doi: 10.1162/089976600300015015.
20. Malinin V. N., Gordeeva S. M. *Fiziko-statisticheskiiy metod prognoza okeanologicheskikh kharakteristik (na primere Severo-Evropeyskogo basseyna) = Physico-statistical method for predicting oceanic characteristics (on the example of the North European Basin)*. Murmansk: PINRO, 2003: 164 p. (In Russ.).
21. Soldatenko S., Angudovich Y. Using Machine Learning for Climate Modelling: Application of Neural Networks to a Slow-Fast Chaotic Dynamical System as a Case Study. *Climate*. 2024;12(189):1—13. doi: 10.3390/cli12110189.
22. Braakmann-Folgmann A., Roscher R., Wenzel S., Uebbing B., Kusche J. Sea Level Anomaly Prediction using Recurrent Neural Networks. *Proceedings of the 2017 conference on Big Data from Space*. 2017:1—4. doi: 10.48550/arXiv.1710.07099.
23. Stutz D. Understanding Convolutional Neural Networks. *Seminar Report. Current Topics in Computer Vision and Machine Learning*. 2014:1—23.
24. Zeiler D. M., Fergus R. Visualizing and Understanding Convolutional Networks. *Conference: European Conference on Computer*. 2014;(8689):818—833. doi: 10.1007/978-3-319-10590-1_53.
25. Lin S., Zhang J. Generalization Bounds for Convolutional Neural Networks. *ArXiv*. 2019:1—30. doi: 10.48550/arXiv.1910.01487.
26. Vizi Z., Batki B., Rátki, L., et al. Water level prediction using long short-term memory neural network model for a lowland river: a case study on the Tisza River, Central Europe // *Environmental Sciences Europe*. 2023;35(92):1—19. doi: 35.10.1186/s12302-023-00796-3.
27. Sergeev A. P., Tarasov D. A. *Vvedenie v neyrosetevoe modelirovanie: uchebnoe posobie = Introduction to Neural Network Modeling*. Ekaterinburg: Ural Federal University named after the first President of Russia B.N. Yeltsin, 2017: 128 p. (In Russ.).
28. Vakulenko S. A., Zhikhareva A. A. *Prakticheskiiy kurs po nejronnym setyam: uchebnoe posobie = Practical Course on Neural Networks*. St. Petersburg: ITMO University, 2018: 71 p. (In Russ.).

29. Ivanov V. V. Water balance and terrestrial water resources of the Arctic. *Trudy AANII = Proceedings of the AARI*. 1976;323: (4—24). (In Russ.).
30. Ivanov V. V. Hydrological regime of the lower reaches and mouths of rivers in Western Siberia and the problem of assessing its changes under the influence of territorial redistribution of water resources. *Problemy Arktiki i Antarktiki = Problems of the Arctic and Antarctic*. 1980;55: (20—43). (In Russ.).
31. Ivanov V. V., Osipova I. V. Runoff of Ob waters into the sea and its long-term variability. *Trudy AANII = Proceedings of the AARI*. 1972;297: (86—91). (In Russ.).
32. Piskun, A. A., Voynov G. N. Surge-and-drain water level oscillations in Novy Port (Ob Bay). *Problemy Arktiki i Antarktiki = Problems of the Arctic and Antarctic*. 2020;66(1): (20—37). doi: 10.30758/0555-2648-2020-66-1-20-37. (In Russ.).
33. Voynov G. N., Nalimov Y. V., Piskun A. A. et al. *Osnovnye cherty gidrologicheskogo rezhima Obskoy i Tazovskoy gub (led, urovni, struktura vod) = Main features of the hydrological regime of the Ob and Taz bays (ice, levels, water structure)*. St. Petersburg: Nestor—History, 2017: 192 p. (In Russ.).
34. Kim S. D., Finagenov O. M., Uvarova T. E. Determination of ice loads on structures of the continental shelf according to standards of various countries. *Vesti gazovoy nauki = Gas Science News*. 2013;3(14):(97—103). (In Russ.).
35. Tarasenko A. D., Selyuzhenok V. V., Sandalyuk N. V. et al. Study of ice conditions in the Ob Bay based on modern satellite data for 2007—2017. *Problemy Arktiki i Antarktiki = Problems of the Arctic and Antarctic*. 2022;68(1):(48—63). doi: 10.30758/0555-2648-2021-68-1-48-63. (In Russ.).
36. RP5.ru — Raspisanie pogody. Available at: [https://rp5.ru/Погода_в_Сабетте_\(аэропорт\)](https://rp5.ru/Погода_в_Сабетте_(аэропорт)). (accessed on: 21.12.2024).
37. RP5.ru — Raspisanie pogody. Available at: [https://rp5.ru/Погода_в_Ханты-Мансийске_\(аэропорт\)](https://rp5.ru/Погода_в_Ханты-Мансийске_(аэропорт)). (accessed on: 21.12.2024).
38. Vokhmyanin S. V., Senashov S. I. The “Caterpillar”-SSA method as a tool for predicting the state of the financial market. *Aktual'nye problemy aviatsii i kosmonavtiki = Current Issues in Aviation and Cosmonautics*. 2010;1(6):(409—410). (In Russ.).
39. Flach P. Machine Learning: The Art and Science of Algorithms That Make Sense of Data. *Cambridge University Press*. 2012. doi: 10.1017/CBO9780511973000.
40. Laurent Y. Introduction to Machine Learning. *ArXiv*, 2024: 649 p. doi: 10.48550/arXiv.2409.02668.
41. Stephen M. Machine Learning: An Algorithmic Perspective. *Chapman and Hall/CRC*, 2014: 457 p. doi: 10.1201/b17476.
42. Mohri M., Rostamizadeh A., Talwalkar A. Foundations of Machine Learning. Massachusetts Institute of Technology, 2012: 504 p.
43. Mironov A. M. *Mashinnoe obuchenie. Chast' 1 = Machine Learning. Part 1*. Moscow: MSU, 2018: 83 p. (In Russ.).
44. Trask W. A. Grokking Deep Learning. *Manning Publications*, 2019: 336 p.
45. Tapkir A. A Comprehensive Overview of Gradient Descent and its Optimization Algorithms. *IARJSET*. 2023;37—45. doi:10.1017/IARJSET.2023.101106.
46. Ruder S. An overview of gradient descent optimization algorithms. *ArXiv*. 2016:1—12. doi: 10.48550/arXiv.1609.04747.
47. Gasnikov A. V. *Sovremennyye chislennyye metody optimizatsii. Metod universal'nogo gradientnogo spуска. 2 izdanie, dopolnennoe = Modern Numerical Methods of Optimization. Universal Gradient Descent Method. 2nd edition, expanded*. Moscow State University, 2018: 181 p. (In Russ.).
48. Bartlett P. L., Anthony M. Learning in neural networks: theoretical foundations. *Cambridge University Press*, 1999. 404 p. doi:10.1017/CBO9780511624216.
49. Bianchi F. M., Maiorino E., Kampffmeyer M., et al. An overview and comparative analysis of Recurrent Neural Networks for Short Term Load Forecasting. *ArXiv: Neural and Evolutionary Computing*. 2017:1—41. doi: 10.48550/arXiv.1705.04378.
50. Van Houdt G., Mosquera C., Nápoles G. A Review on the Long Short-Term Memory Model. *Artificial Intelligence Review*. 2020;(53):5929—5955 doi: 10.1007/s10462-020-09838-1.
51. Graves A., Schmidhuber J. Framewise phoneme classification with bidirectional LSTM networks. *Proceedings of the International Joint Conference on Neural Networks*. 2005;4:2047—2052 doi:10.1109/IJCNN.2005.1556215.

52. Nusrat I., Sung-Bong J. A Comparison of Regularization Techniques in Deep Neural Networks. *Symmetry*. 2018;10(11). doi: 10.648. 10.3390/sym10110648.
53. Akgül İ. Activation functions used in artificial Neural Networks. *Academic Studies in Engineering*. 2023:42—58.
54. Jais I. K. M., Ismail R. A., Nisa S. Q, N, Adam Optimization Algorithm for Wide and Deep Neural Network. *Knowledge Engineering and Data Science*. 2019;2(1):41—46. doi: 10.17977/um018v2i12019

Информация об авторах

Ангудович Яромир Игоревич, магистр, аспирант, инженер управления научных и инновационных исследований, Российский государственный гидрометеорологический университет, кафедра океанологии, yaгомir.angudovich@mail.ru.

Татаренко Юрий Алексеевич, магистр, аспирант, старший преподаватель, Российский государственный гидрометеорологический университет, кафедра океанологии, tatarenko.yal@yandex.ru.

Information about authors

Angudovich Yaromir Igorevich, Master's degree, Postgraduate Student, Engineer of the Department of Scientific and Innovative Research, Russian State Hydrometeorological University, Department of Oceanology.

Tatarenko Yuri Alekseevich, Master's degree, Postgraduate Student, Senior Lecturer, Russian State Hydrometeorological University, Department of Oceanology.

Конфликт интересов: конфликт интересов отсутствует.

Статья поступила 28.01.2025

Принята в печать 20.02.2025

The article was received on 28.01.2025

The article was accepted on 20.02.2025