

DOI: <https://doi.org/10.37162/2618-9631-2026-2-143-168>

УДК 556.06:556.535+004.032.26+004.8

Современные методы прогнозирования водного режима с разной заблаговременностью

А.В. Романов, Э.Р. Акмаев, Н.К. Семенова

*Гидрометеорологический научно-исследовательский центр
Российской Федерации, г. Москва, Россия
alexey.romanov@mecom.ru, akmaew1@gmail.com*

Выполнено сопоставление современных методов прогнозирования водного режима с разной заблаговременностью, основанных на использовании технологии нейронных сетей, и усовершенствованных статистических методов. В процедуре сопоставления использовались данные стандартных гидрометеорологических наблюдений для пяти тестовых водосборов, расположенных в различных физико-географических зонах формирования речного стока по классификации Б.Д. Зайкова (II-й тип (реки с половодьем в тёплую часть года), II-й Дальневосточный тип, I-й Восточноевропейский тип и два водосбора III-го Северокавказского типа).

Несмотря на ограниченный объём исходной гидрометеорологической информации, что существенно ограничивало эффективность использования технологии нейросетевых моделей, стандартный критерий ошибки метода прогноза (отношение среднеквадратической погрешности к среднеквадратическому изменению за период заблаговременности прогноза) на базе глубокого обучения (DL) оказался существенно лучше в сравнении с использованными статистическими методами. Для трёх тестовых водосборов этот критерий для DL дал удовлетворительный результат, дифференцированный по заблаговременности прогноза от одних до десяти суток. Для статистических методов такой результат был получен только для одного тестового водосбора (II-й тип (реки с половодьем в тёплую часть года)) с заблаговременностью одни сутки. Таким образом, выполненная работа, использующая технологии нейронных сетей, демонстрирует обоснованность расширения спектра научных работ, связанных с физико-статистическим математическим моделированием процесса формирования стока.

Выделены перспективы развития данного подхода при переходе к разработке принципиально новой автоматизированной нейросетевой системы выпуска гидрологических прогнозов разной заблаговременности для всех имеющихся на территории Российской Федерации водосборов, представляющих интерес для экономики страны.

Ключевые слова: краткосрочные и среднесрочные гидрологические прогнозы, нейронные сети, модель глубокого обучения, экстраполяция гидрографа уровня воды, статистические методы, уровень воды

Modern methods of water regime forecasting with different forecast lead times

A.V. Romanov, E.R. Akmaev, N.K. Semenova

*Hydrometeorological Research Center of Russian Federation,
Moscow, Russia
alexey.romanov@mecom.ru, akmaew1@gmail.com*

An analysis comparing modern methods for forecasting water regimes with different lead times was performed, contrasting neural networks with advanced statistical methods. The comparison utilized data of routine hydrometeorological observations for five test watersheds located in different physiographic zones of river runoff formation according to the classification by B.D. Zaikov (type II (rivers with flooding during the warm season), Far Eastern type II, East European type I and two catchments of North Caucasian type III).

Despite limited hydrometeorological data, which constrained the effectiveness of neural network modeling, the standard forecast error criterion (the ratio of the root-mean-square error to the root-mean-square change over the forecast lead-time) based on deep learning (DL) turned out to be significantly better than the statistical methods used. For three test catchments DL models gave satisfactory skill scores differentiated by forecast lead times from one to ten days. For time-tested statistical methods such a result was obtained only for one test catchment (type II (rivers with flooding during the warm season)) with a forecast lead time of one day. The completed work, utilizing neural network technologies, demonstrates the validity of expanding the scope of scientific research related to physico-statistical mathematical modeling of streamflow generation.

The prospects for developing this approach are highlighted in the transition toward a fundamentally new automated neural network system for producing operational hydrological forecasts with varying lead times for all gauged watersheds in the Russian Federation that are of economic importance.

Keywords: short- and medium-term hydrological forecasts, neural networks, deep learning model, extrapolation of the water level hydrograph, statistical methods, water level

Введение

Непрерывное развитие новых аналитических и связанных с ними технологических возможностей ставит перед гидрологией суши задачу постоянного совершенствования методов прогнозирования водных ресурсов, что обусловлено необходимостью эффективного планирования водохозяйственной деятельности и своевременного реагирования на возможные бедствия, вызванные наводнениями или засухами, с разной заблаговременностью по времени.

В настоящее время многочисленными исследованиями доказано, что при работе с устойчивыми гидрологическими режимами использование традиционных методов может быть оправдано, однако они существенно ограничены в случае нелинейных зависимостей и практически не имеют перспектив развития в случае привлечения новых исходных данных. В последние годы активно развиваются методы с использованием нейросетевых технологий, демонстрирующие перспективные результаты в задачах прогнозирования временных рядов с разной заблаговременностью [11, 15, 17, 19, 20, 24, 25].

В этих условиях совершенно естественно возникла задача выполнить сопоставление эффективности проверенных временем методов прогнозов водного режима с методами, использующими современные математические и технологические подходы на базе глубокого машинного обучения. В последние годы процесс широкой автоматизации процесса выпуска всех видов гидрометеорологических прогнозов привёл к необходимости выполнения в ФГБУ «Гидрометцентр России» большой работы, связанной

с адаптацией простейших статистических методов краткосрочного и среднесрочного прогноза водного режима. Такая работа с использованием усовершенствованного метода экстраполяции гидрографа [12, 21] была выполнена практически для всего ансамбля водосборов Российской Федерации, насчитывающего около 3000 водпостов. При этом в рамках её выполнения была сформирована и апробирована исходная база данных по основным гидрометеорологическим характеристикам, позволяющая использовать её при разработке современных методов гидрологических прогнозов на базе нейросетевых технологий.

Задача сопоставления эффективности проверенных временем методов прогнозов водного режима с методами, использующими современные подходы на базе глубокого машинного обучения, является только первым этапом решения существенно более сложной по масштабам проблемы, связанной с совершенствованием процесса автоматизации гидрометеорологических прогнозов на базе вычислительного комплекса ФГБУ «ГВЦ Росгидромета». Предполагается, что при наличии положительного эффекта от сопоставления методов на базе модели глубокого обучения с уже реализованными методами для небольшого числа тестовых водосборов, расположенных в различных физико-географических зонах формирования речного стока, должен произойти переход к разработке принципиально новой автоматизированной нейросетевой системы выпуска гидрологических прогнозов. Данная система должна будет ежедневно автоматически выпускать прогноз уровня воды с разной заблаговременностью для всех выделенных водпостов по территории Российской Федерации. При этом её архитектура должна позволять управлять нейросетевыми моделями, отслеживать их работу и поддерживать систему в рабочем состоянии.

1. Характеристика тестовых водосборов, выбранных для сопоставления эффективности двух методологических подходов

При выборе тестовых водосборов использовались два основных критерия:

1) водосборы должны были быть расположены в разных физико-географических зонах, отражающих различные условия формирования речного стока;

2) по водосборам должен быть подготовлен архив стандартной гидрометеорологической информации, позволяющий реализовать нейросетевую модель глубокого обучения для разработки методов прогноза водного режима с разной заблаговременностью.

На рис. 1 представлена схема размещения выбранных пяти тестовых водосборов по территории Российской Федерации, а также ещё трёх водосборов, предполагаемых для развития нейросетевого подхода в ближайшем будущем.




Рис. 1. Схема размещения тестовых водосборов по территории Российской Федерации для двух этапов проведения тестирования. Первый этап (2025 г., отмечены красным цветом): р. Большая Воровская (с. Соболево), Камчатское УГМС (1); р. Малиновка (с. Ракитное), Приморское УГМС (2); р. Сылва (пгт. Шамары), Уральское УГМС (3); р. Белая (пгт. Каменномостский), Северо-Кавказское УГМС (4); р. Малка (с. Каменномостское), Северо-Кавказское УГМС (5). Следующий этап (отмечены синим цветом): р. Поной (с. Краснощелье), Мурманское УГМС (1); р. Варзуга (с. Варзуга), Мурманское УГМС (2); р. Умба (пор. Паялка), Мурманское УГМС (3).

Fig. 1. Locations of test catchments across the Russian Federation for the two testing phases. First phase (2025, marked in red): Bolshaya Vorovskaya River (Sobolevo village), Kamchatka UGMS (1); Malinovka River (Rakitnoye village), Primorsky UGMS (2); Sylva River (Shamary urban-type settlement), Ural UGMS (3); Belaya River (Kamennomostsky urban-type settlement), North Caucasus UGMS (4); Malka River (Kamennomostskoe village), North Caucasus UGMS (5). Next phase (marked in blue): Ponoj River (Krasnoshele village), Murmansk UGMS (1); Varzuga River (Varzuga village), Murmansk UGMS (2); Umba River (Payalka rapids), Murmansk UGMS (3).

Выбор тестовых водосборов связан с работой [2], в рамках которой была выполнена оценка оправдываемости разработанных методов прогноза водного режима на базе нескольких статистических и концептуальных моделей с использованием систематизированной архивной гидрометеорологической информации за разные периоды времени.

В табл. 1 приведены все основные гидрографические характеристики для пяти тестовых водосборов, позволяющие в первом приближении оценить исходную информацию и дифференцировать её по типам внутригодового распределения стока.

Таблица 1. Основные гидрографические характеристики для пяти тестовых водосборов
Table 1. Hydrographic characteristics of the five test catchments.

Основные гидрографические характеристики	Тестовый водосбор				
	р. Большая Воровская (с. Соболево)	р. Малиновка (с. Ракитное)	р. Сылта (пгт Шарары)	р. Белая (пгт Каменно-мостский)	р. Малка (с. Каменно-мостское)
1. Индекс	2177	5287	76692	83348	84192
2. GPS координаты (град.)	54.18 и 155.57	45.38 и 134.16	57.21 и 58.13	44.17 и 40.11	43.44 и 43.04
3. Нуль графика поста (м)	7.96	92.40	208.98	373.09	792.72
4. Расстояние от наиболее удалённой точки речной системы (км)	154	169	205	93	81
5. Расстояние от истока (км)	154	169	205	93	81
6. Уклон реки – средний (в промилле)	8.5	4.4	1.1	22	32
7. Уклон реки – средневзвешенный (в промилле)	3.9	2.8	0.5	9.9	23
8. Площадь водосбора (км ²)	3630	4730	3130	1850	1540
9. Средняя высота водосбора (м)	610	373	322	1330	2000
10. Средний уклон водосбора (в промилле)	-	-	-	-	-
11. Заболоченность (%)	10	4	-	-	-
12. Лесистость (%)	75	96	85	80	10
13. УГМС	Камчатское УГМС	Приморское УГМС	Уральское УГМС	Северо-Кавказское УГМС	Северо-Кавказское УГМС

В качестве классификационной системы, позволяющей распределить фиксированные тестовые водосборы по группам, была выбрана классификационная система Б.Д. Зайкова [13], позволяющая распределить

выбранные реки по группам в зависимости от особенностей внутригодового распределения стока. Предполагается по мере расширения числа тестовых водосборов существенно усложнить выбранную классификационную систему, используя данные по основным гидрографическим характеристикам (табл. 1) и особенностям водного режима (классификация А.В. Огиевского). Такой подход позволит упростить процедуру дифференцированного выбора архитектуры нейросетевой модели, которая априори должна быть как-то связана с гидрографическими характеристиками и типом водного режима рек. В табл. 2 приведена краткая характеристика водного режима по всем тестовым водосборам и их классификация по Б.Д. Зайкову [3, 5–8, 10].

В ранее выполненной работе, связанной с использованием нейросетевой модели глубокого обучения для разработки метода долгосрочного прогноза максимального уровня воды р. Исеть [1], показано существенное улучшение (на 30 %) стандартного критерия S/σ (S – среднеквадратическая погрешность проверочных прогнозов, σ – среднеквадратическое отклонение) при использовании данных наблюдений за уровнем грунтовых вод на подземных скважинах. Учитывая это обстоятельство, была проделана большая работа по систематизации таких данных наблюдений, которыми располагает ФГБУ «Гидроспецгеология», входящая в систему Федерального агентства по недропользованию.

В табл. 3 приводится общая характеристика полученных из ФГБУ «Гидроспецгеология» данных наблюдений за уровнями грунтовых вод на подземных скважинах ГМСН (Государственного мониторинга состояния недр), расположенных в относительной близости от пяти выбранных тестовых водосборов. Анализ полученных гидрогеологических материалов показывает, что в силу разных причин, носящих как объективный, так и субъективный характер (в том числе массовые случаи вандализма), плотность таких данных наблюдений в пространстве и во времени носит ограниченный характер и в нашем случае не удовлетворяет критериям их использования в нейросетевой модели глубокого обучения.

В то же время необходимо отметить, что концепция использования уровней грунтовых вод в качестве новой исходной информации при реализации нейросетевой модели глубокого обучения является одним из реальных преимуществ глубоких нейросетей, которые достаточно легко интегрируют разнородные исходные данные и при этом улучшают качество прогнозов [14, 16, 18, 22, 26, 27].

В рамках развития этого подхода сформирована база гидрометеорологических и гидрогеологических данных по трём водосборам, расположенным на Кольском полуострове и относящимся к сфере деятельности ФГБУ «Мурманское УГМС». Сформированная база данных не уступает базе данных, сформированной для пяти тестовых водосборов, а по некоторым параметрам (уровни грунтовых вод) даже её превосходит.

Таблица 2. Характеристика водного режима по пяти тестовым водосборам и их классификация по Б.Д. Зайкову
Table 2. Water regime characteristics and flow type classification (after B.D. Zaikov) for the five test catchments

Тестовый водосбор	Характеристика водного режима	Классификация по Б.Д. Зайкову
р. Большая Воровская (с. Соболево)	Водный режим этой реки включает в себя следующие основные характеристики: 1) смешанный тип питания, но с преобладанием подземного стока. В водопроницаемых вулканических породах образуются большие запасы грунтовых вод, которые интенсивно питают реку; 2) высокое половодье наблюдается в тёплую часть года. Это обусловлено не только снеговым и ледниковым питанием, но и летними паводками, вызванными обильными дождями	р. Большая Воровская, относится к II типу (реки с половодьем в тёплую часть года). Дальневосточный тип
р. Малиновка (с. Ракитное)	Водность реки в тёплую часть года (IV – IX) зависит от талых вод в период весеннего половодья и дождевых вод – во время прохождения паводков (суммарно это составляет примерно 83 % годового стока). Весеннее половодье обычно выражено довольно отчётливо и по своему объёму не уступает отдельным паводкам. Однако в его формировании значительное место занимают дождевые воды, накладывающиеся на спад половодья	р. Малиновка относится к II типу (реки с половодьем в теплую часть года)
р. Сылва (пгт Самары)	Внутригодовое распределение речного стока характеризуется чётко выраженным весенним половодьем, летне-осенними дождевыми паводками и длительной устойчивой зимней меженью. Режим формирования весеннего половодья определяется таянием снега, а также дождевым питанием. Для данной реки характерно сильное влияние карста, которое приводит к уменьшению неравномерности распределения сезонного стока	р. Сылва относится к I типу (реки с весенним половодьем). Восточноевропейский тип рек
р. Белая (пгт Каменно-мостский)	Водный режим этой реки является как бы переходным от высокогорного юго-восточного к западному. Начало половодья приходится на вторую декаду марта – начало апреля, а окончание – на первую декаду августа. На половодный подъём накладываются значительные дождевые паводки. Основной источник питания составляет приток воды за счёт таяния снега и ледников. Сток за половодье составляет 60 % от годового стока	р. Белая относится к III типу (реки с паводочным режимом). Северокавказский тип рек
р. Малка (с. Каменно-мостское)	Основное питание формируется в тёплый период за счёт таяния ледников, высокогорных и сезонных снегов. Режим реки характеризуется значительными подъёмами уровней воды, начинающимися в конце апреля-мае, половодьем в тёплый период года и довольно устойчивой меженью в осенне-зимний период	р. Малка относится к III типу (реки с паводочным режимом). Северокавказский тип рек

Таблица 3. Характеристика данных наблюдений за уровнями грунтовых вод на подземных скважинах по ГМСН в системе ГОНС (Государственной опорной наблюдательной сети), отражающих формирование водного режима на пяти тестовых водосборах

Table 3. Groundwater level observations from monitoring wells in the State Reference Observation Network (GOSN), reflecting water regime formation across the five test catchments

Тестовый водосбор	Кол-во подземн. скважин по ГМСН	Характеристика подземных скважин ГОНС, примыкающих к опорным водпостам тестовых водосборов	Период наблюдений
р. Большая Воровская (с. Соболево)	–	Нет примыкающих скважин	–
р. Малиновка (с. Ракитное)	–	Нет примыкающих скважин	–
р. Сылта (пгт Шамары)	2	№ 5710048 – Пермский край, юго-восточнее д. Долматы, за пределами жилой постройки, в долине р. Сылта	6 лет (2020-2025)
		№ 5710049 – Пермский край, юго-восточнее д. Долматы, за пределами жилой постройки, в долине р. Сылта, в 48 м юго-восточнее скв. № 12	6 лет (2020-2025)
р. Белая (пгт Каменно-мостский)	1	№ 7911443 – Республика Адыгея, Майкопский район, ст-ца Кужорская, северо-восточная окраина	12 лет (2012-2023)
р. Малка (с. Каменно-мостское)	3	№ 0710075 – Ставропольский край, Кировский р-н, в 4,75 км к северу от ст. Старопавловской, 6.25 км. от р. Малка	16 лет (2010-2025)
		№ 0710073 – Ставропольский край, Кировский р-н, в 100 м к югу от ст. Старопавловской	16 лет (2010-2025)
		№ 0710076 – Ставропольский край, Кировский р-н, в 8,75 км к северу от ст. Старопавловской и в 2 км к югу от г. Новопавловска	16 лет (2010-2025)

На рис. 2 показано расположение трёх предполагаемых для следующего этапа тестирования тестовых водосборов на Кольском полуострове и их привязка к метеорологической и гидрогеологической информации.

По аналогии с пятью тестовыми водосборами для продолжения данной работы вся необходимая информация по трём водосборам представлена в табл. 4, 5 и 6 [4, 9].




Рис. 2. Схема размещения трёх тестовых водосборов по территории Кольского полуострова с отметками подземных скважин для следующего этапа тестирования.

Fig. 2. Locations of the three pilot catchments on the Kola Peninsula with groundwater well sites for the next testing phase.

Таблица 4. Основные гидрографические характеристики для трёх тестовых водосборов на следующем этапе тестирования

Table 4. Hydrographic characteristics of the three pilot catchments for the next testing phase

Основные гидрографические характеристики	Тестовый водосбор		
	р. Варзуга (с. Варзуга)	р. Умба (пор. Паялка)	р. Поной (с. Краснощелье)
1. Индекс	71186	71199	71165
2. GPS координаты (град.)	66.40 и 36.63	66.68 и 34.32	67.35 и 37.03
3. Нуль графика поста (м)	8.71	3.43	148.06
4. Расстояние от наиболее удалённой точки речной системы (км)	240	195	136
5. Расстояние от истока (км)	231	119	136
6. Уклон реки – средний (в промилле)	0.7	1.4	1.0
7. Уклон реки – средневзвешенный (в промилле)	0.7	1.1	0.6
8. Площадь водосбора (км ²)	7940	6470	3810
9. Средняя высота водосбора (м)	160	210	220
10. Средний уклон водосбора (в промилле)	-	-	-
11. Заболоченность (%)	50	30	30
12. Лесистость (%)	45	50	25
13. УГМС	Мурманское УГМС	Мурманское УГМС	Мурманское УГМС

Таблица 5. Характеристика водного режима по трем тестовым водосборам и их классификация по Б.Д. Зайкову

Table 5. Water regime characteristics and flow type classification (after B.D. Zaikov) for the three pilot catchments

Тестовый водосбор	Характеристика водного режима	Классификация по Зайкову Б.Д.
р. Варзуга (с. Варзуга)	Реки Кольского полуострова относятся к рекам снегового питания. Режим стока в годовом разрезе характеризуется высоким весенним половодьем, низкой зимней и летней меженью и относительно небольшими летне-осенними подъёмами, вызываемыми дождями	Реки Варзуга, Умба и Поной относятся к I типу (реки с весенним половодьем), Восточноевропейский тип рек
р. Умба (пор. Паялка)		
р. Поной (с. Краснощелье)		

Таблица 6. Характеристика данных наблюдений, отражающих формирование водного режима на трёх тестовых водосборах для следующего этапа тестирования

Table 6. Observation data reflecting water regime formation in the three pilot catchments for the next testing phase

Тестовый водосбор	Метеостанция (индекс)	Подземная скважина
р. Варзуга (с. Варзуга)	с. Кашкаранцы (22334)	Скважина № 7 Умба
р. Умба (пор. Паялка)	пгт Умба (22324)	Скважина № 7 Умба
р. Поной (с. Краснощелье)	с. Краснощелье, (22235)	Скважина № 5 Ловозеро
Состав гидрологических, метеорологических и гидрогеологических данных наблюдений за 31 год (1993–2023): 1. Уровень воды (за два срока наблюдений), в см над «0» гр. поста 2. Среднесуточная температура воздуха, в град. С 3. Высота снежного покрова, в см 4. Среднесуточная скорость ветра, в м/сек 5. Минимальное суточное значение температуры точки росы 6. Суточная сумма осадков, в мм 7. Уровень грунтовых вод на подземных скважинах (с измерениями один раз в трое суток), в см		

2. Исходная архивная информация и её адаптация для использования в нейросетевой модели глубокого обучения

2.1. Состав исходных данных

Исходные данные для пяти тестовых водосборов включают гидрологические наблюдения (уровень воды) и метеорологические характеристики: высота снежного покрова (H_{snow}), осадки (P), относительная влажность (RH), температура воздуха (T), температура почвы (T_{soil}), скорость ветра (wind_speed) и максимальная скорость ветра (wind_max_speed). Период обучения: исторические данные до 2016 г. (объём исторических данных не меньше 12 лет). Период валидации: 2016–2020 гг. (5 лет).

Под наличием данных понималось одновременное присутствие метеорологических и гидрологических наблюдений. Данные с частотой выше суточной агрегировались по дням: для всех признаков применялось усреднение, за исключением осадков, которые суммировались.

2.2. Распознавание аномальных значений

Для выявления выбросов применялся метод анализа локальной окрестности точки. Пусть y_t – значение признака в момент t ; y_{t-1} и y_{t+1} – соседние значения. Точка y_t признаётся аномальной при одновременном выполнении условий:

$$\max\left(\frac{|y_t - y_{t-1}|}{\max(|y_t|, |y_{t-1}|)}, \frac{|y_{t+1} - y_t|}{\max(|y_t|, |y_{t+1}|)}\right) > \theta_d,$$

$$\frac{|y_{t+1} - y_{t-1}|}{\max(|y_{t+1}|, |y_{t-1}|)} < \theta_s,$$

где $\theta_d = 0.5$ – порог отклонения от соседей; $\theta_s = 0.1$ – порог схожести соседей между собой.

Физический смысл распознавания: точка считается выбросом, если она резко отклоняется от соседних значений, в то время как сами соседи близки друг к другу. Количество выявленных аномалий не превышало 0.5 % от общего объёма данных для каждого водпоста.

2.3. Процедура заполнения пропусков

После удаления выбросов пропуски заполнялись методом кубической сплайн-интерполяции, сохраняющей монотонность и гладкость временного ряда.

2.4. Конструирование признаков

Для учёта сезонности применялось тригонометрическое кодирование временных признаков:

$$\begin{aligned} day_x &= \sin\left(\frac{2\pi \cdot d}{365}\right), & day_y &= \cos\left(\frac{2\pi \cdot d}{365}\right) \\ month_x &= \sin\left(\frac{2\pi \cdot m}{12}\right), & month_y &= \cos\left(\frac{2\pi \cdot m}{12}\right) \end{aligned}$$

где d – день года, m – номер месяца.

Базовый набор признаков включал: `day_x`, `day_y`, `month_x`, `month_y`, `P`, `T`, `Hsnow`, `wind_speed`. Для отдельных водпостов набор расширялся дополнительными признаками (`RH`, `T_soil`, `wind_max_speed`) на основе предварительных экспериментов.

3. Выбор и сопоставление нескольких архитектур нейросетевой модели глубокого обучения

3.1. Обзор тестируемых архитектур

В рамках численных экспериментов проводилось сравнение четырёх архитектур нейронных сетей, широко используемых для прогнозирования временных рядов.

LSTM (Long Short-Term Memory) – рекуррентная архитектура с механизмом долгосрочной памяти, использующая три типа ворот (входной, забывания, выходной) для контроля информационного потока. Эта архитектура эффективна для последовательностей с долгосрочными зависимостями, однако характеризуется высокой вычислительной сложностью.

GRU (Gated Recurrent Unit) – упрощённая версия LSTM с двумя воротами (обновления и сброса). Она обеспечивает сопоставимое качество при меньшем числе параметров и более быстром обучении.

N-BEATS (Neural Basis Expansion Analysis for Time Series) – архитектура на основе полносвязных сетей с механизмом остаточных связей. Использует разложение временного ряда на базисные функции (обучаемые или заданные).

N-HiTS (Neural Hierarchical Interpolation for Time Series) – фактически представляет собой развитие N-BEATS с иерархической структурой и механизмом интерполяции. Важно отметить, что данная архитектура сокращает число параметров за счёт интерполяции прогноза на разных временных масштабах, ускоряя вычисления и снижая риск переобучения.

3.2. Архитектура GRU

По результатам экспериментов наилучшую точность продемонстрировала архитектура GRU [28] (рис. 3). Её выбор обусловлен балансом между выразительностью модели и вычислительной эффективностью: GRU требует меньше параметров по сравнению с LSTM при сохранении способности моделировать долгосрочные зависимости.

Для входного вектора x_t и предыдущего скрытого состояния h_{t-1} вычисления GRU-ячейки определяются следующим образом:

Ворота обновления: $z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z)$

Ворота сброса: $r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r)$

Кандидат скрытого состояния: $\tilde{h}_t = \tanh(W_h x_t + U_h (r_t \odot h_{t-1}) + b_h)$

Итоговое скрытое состояние: $h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t$

Здесь σ – сигмоидная функция активации; \odot – поэлементное умножение; W_* , U_* , b_* – обучаемые параметры.

3.3. Конфигурация модели

В табл. 7 приведены гиперпараметры нейросетевой модели архитектуры GRU.

Таблица 7. Гиперпараметры архитектуры GRU
Table 7. GRU architecture hyperparameters

Параметр	Значение	Описание
hidden_dim	384–512	Размерность скрытого состояния
n_rnn_layers	3	Количество рекуррентных слоёв
dropout	0.05	Дропаут
activation	ReLU / LeakyReLU	Функция активации
input_chunk_length	45	Длина входной последовательности (дней)
output_chunk_length	10	Горизонт прогноза (дней)

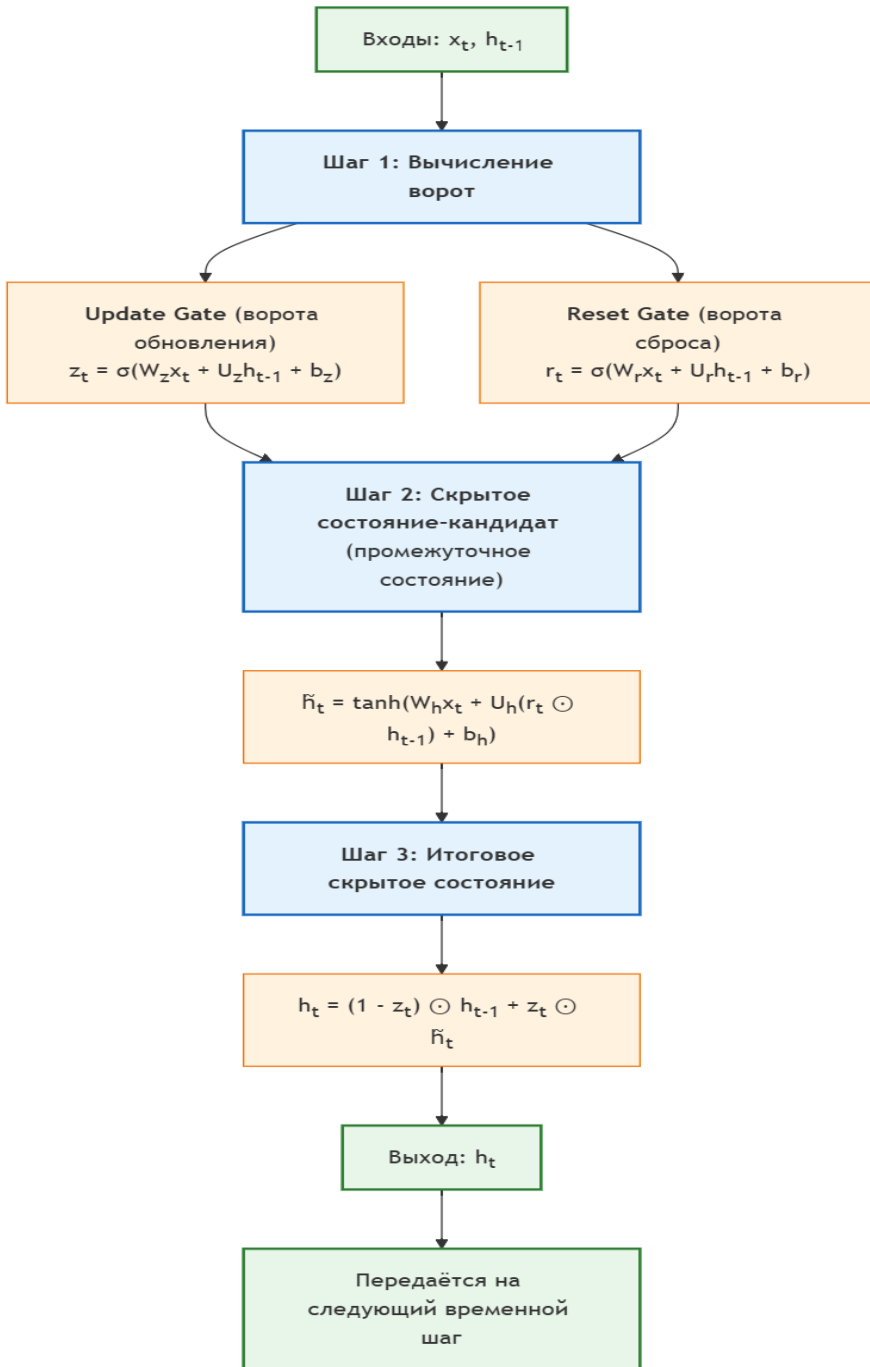


Рис. 3. Структура GRU-ячейки.
Fig. 3. GRU cell architecture.

3.4. Функции потерь

В качестве функций потерь использовались среднеквадратическая ошибка (MSE) и средняя абсолютная ошибка (MAE):

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2,$$

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|,$$

где y_i – фактическое значение; \hat{y}_i – прогнозируемое значение; N – количество примеров.

MSE штрафует большие отклонения сильнее за счёт квадратичной зависимости, что делает её чувствительной к выбросам. MAE обеспечивает более робастную оценку, однако она менее чувствительна к систематическим ошибкам.

3.5. Параметры обучения

В табл. 8 приведены гиперпараметры процесса обучения выбранной архитектуры нейросетевой модели глубокого обучения.

Таблица 8. Гиперпараметры процесса обучения
Table 8. Training process hyperparameters

Параметр	Значение	Описание
optimizer	Adam	Оптимизатор
learning_rate	0.0001–0.001	Начальная скорость обучения
n_epochs	40–70	Количество эпох
loss_function	MSE / MAE	Функция потерь
lr_schedule	StepLR	Планировщик скорости обучения
lr_gamma	0.15	Множитель снижения lr каждые 1/4 от общего числа эпох

Диапазоны гиперпараметров определены на основе предварительных экспериментов с целью сокращения пространства поиска оптимальной конфигурации.

4. Анализ результатов краткосрочных и среднесрочных прогнозов уровней воды по пяти тестовым водосборам

4.1. Критерий оценки качества прогнозов

Для оценки качества прогнозов использовался критерий оправданности S/σ_{Δ} , характеризующий отношение ошибки прогноза к естественной изменчивости процесса.

Пусть $Y_{act}(j)$ – фактический уровень воды в день j , $Y_{pred}(j+k)$ – прогнозируемый уровень на день $j+k$, k – заблаговременность прогноза, тогда:

Изменчивость процесса: $\Delta_j(k) = Y_{act}(j) - Y_{act}(j+k)$

Стандартное отклонение изменчивости:

$$\sigma_{\Delta}(k) = \sqrt{\frac{1}{N-1} \sum_{j=1}^N (\Delta_j(k) - \bar{\Delta}(k))^2},$$

где $\bar{\Delta}(k)$ - среднее арифметическое значение изменчивости процесса для k -й заблаговременности.

Среднеквадратическая ошибка прогноза:

$$S(k) = \sqrt{\frac{1}{N} \sum_{j=1}^N (Y_{act}(j+k) - Y_{pred}(j+k))^2}$$

Критерий оправдываемости: $S(k)/\sigma_{\Delta}(k)$

Прогноз считается оправдавшимся при $S/\sigma_{\Delta} < 0.80$, что означает превосходство модели над инерционным прогнозом, основанным на естественной изменчивости процесса.

4.2. Результаты по пяти тестовым водосборам с использованием модели глубокого обучения

В табл. 9 приведены значения критерия оправдываемости для различных значений заблаговременности прогноза (от 1 до 10 суток).

Таблица 9. Значения критерия S/σ_{Δ} для различных заблаговременностей прогноза Δ (в сутках) – глубокое машинное обучение

Table 9. S/σ_{Δ} values for forecast lead times Δ (days) – deep learning model

Название реки (водпост)	Значения S/σ_{Δ} для разной заблаговременности прогноза									
	$\Delta=1$	$\Delta=2$	$\Delta=3$	$\Delta=4$	$\Delta=5$	$\Delta=6$	$\Delta=7$	$\Delta=8$	$\Delta=9$	$\Delta=10$
р. Большая Воровская (с. Соболево)	0.82	0.88	0.90	0.89	0.88	0.87	0.87	0.86	0.86	0.84
р. Малиновка (с. Ракитное)	0.70	0.77	0.81	0.84	0.86	0.88	0.89	0.90	0.91	0.91
р. Сытва (пгт Самары)	0.83	0.79	0.76	0.75	0.73	0.69	0.68	0.67	0.66	0.66
р. Белая (пгт Каменно-мостский)	0.88	0.85	0.84	0.83	0.83	0.82	0.81	0.80	0.80	0.79
р. Малка (с. Каменно-мостское)	0.97	0.95	0.92	0.91	0.89	0.89	0.89	0.89	0.88	0.88

Примечание. Жирным шрифтом выделены значения S/σ_{Δ} , удовлетворяющие критерию оправдываемости $S/\sigma_{\Delta} < 0.80$ (удовлетворительное качество прогноза).

На рис. 4 представлены зависимости S/σ_{Δ} от заблаговременности прогноза для пяти тестовых водосборов.




Рис. 4. График зависимости S/σ_{Δ} от заблаговременности прогноза для пяти тестовых водосборов.

Fig. 4. S/σ_{Δ} criterion as a function of forecast lead time for the five test catchments.

4.3. Комплексный анализ результатов сопоставления двух выделенных гидрогеологических подходов в задаче прогнозирования водного режима

Модель глубокого обучения

Из пяти тестовых водосборов три для модели глубокого обучения демонстрируют удовлетворительное качество прогнозов по критерию S/σ_{Δ} :

1) р. Сылта (пгт Шамары) – наилучший результат. Критерий выполняется для заблаговременности от двух до десяти суток, с минимальным значением 0.66 на 10-й день. При этом характерно улучшение качества с ростом заблаговременности, что может объясняться особенностями формирования водного режима для данного тестового водосбора (река I типа с весенним половодьем – Восточноевропейский тип; табл. 2);

2) р. Малиновка (с. Ракитное) – критерий выполняется для краткосрочного прогноза от 1 до 2 дней с минимальным значением 0.70 (река II типа с половодьем в тёплую часть года, табл. 2). В данном случае наблюдается типичная картина снижения качества оправдываемости с увеличением заблаговременности прогноза;

3) р. Белая (пгт Каменномостский) – критерий выполняется для среднесрочного прогноза от 2 до 10 суток с минимальным значением 0.79 (река III типа с паводочным режимом – Северокавказский тип рек, табл. 2).

На рис. 5, 6 и 7, 8 показано сопоставление прогнозных и фактических значений уровня воды для, соответственно: р. Сылва (пгт Шамары) с заблаговременностью 2, 10 суток и р. Малиновка (с. Ракитное) с заблаговременностью 1, 2 суток.

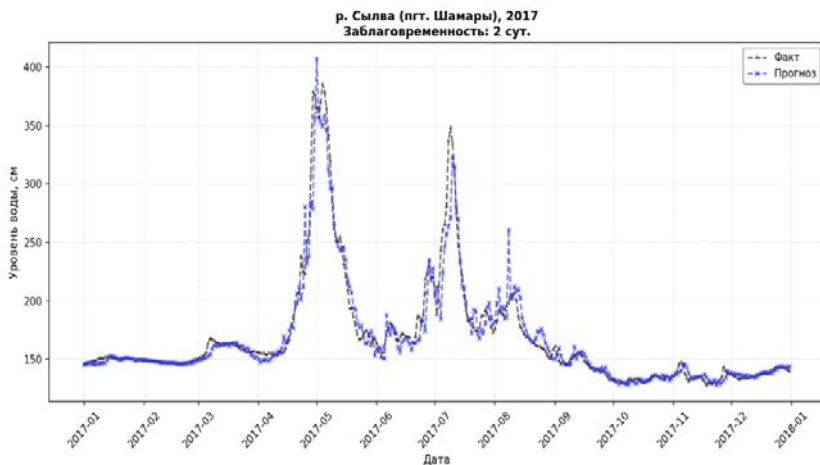


Рис. 5. Пример прогноза уровня воды для р. Сылва (пгт Шамары): сравнение прогнозируемых и фактических значений с заблаговременностью двое суток для 2017 г. (модель глубокого обучения).

Fig. 5. Water level forecast for the Sylva River (Shamary): predicted vs. observed values at a 2-day lead time, 2017 (deep learning model).

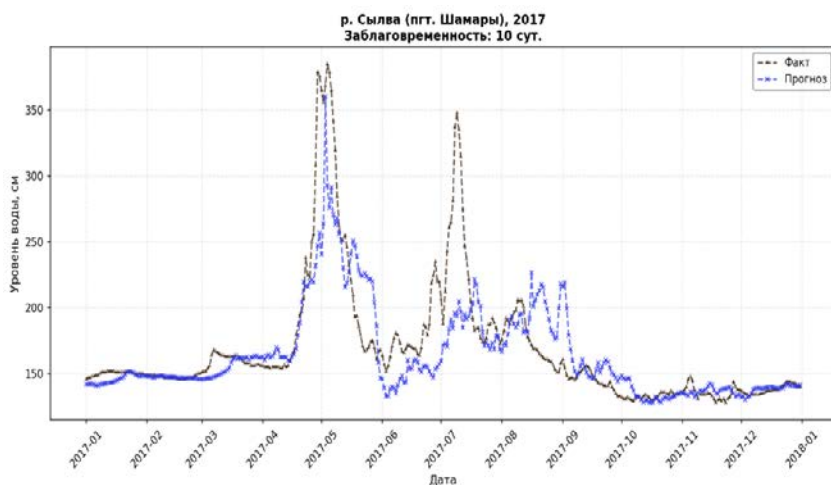


Рис. 6. Пример прогноза уровня воды для р. Сылва (пгт Шамары): сравнение прогнозируемых и фактических значений с заблаговременностью 10 суток для 2017 г. (модель глубокого обучения).

Fig. 6. Water level forecast for the Sylva River (Shamary): predicted vs. observed values at a 10-day lead time, 2017 (deep learning model).




Рис. 7. Пример прогноза уровня воды для р. Малиновка (с. Ракитное): сравнение прогнозируемых и фактических значений с заблаговременностью 1 сутки для 2017 г. (модель глубокого обучения).

Fig. 7. Water level forecast for the Malinovka River (Rakitnoye): predicted vs. observed values at a 1-day lead time, 2017 (deep learning model).




Рис. 8. Пример прогноза уровня воды для р. Малиновка (с. Ракитное): сравнение прогнозируемых и фактических значений с заблаговременностью двое суток для 2017 г. (модель глубокого обучения).

Fig. 8. Water level forecast for the Malinovka River (Rakitnoye): predicted vs. observed values at a 2-day lead time, 2017 (deep learning model).

Для тестовых водосборов р. Большая Воровская (с. Соболево) и р. Малка (с. Каменноостокское) удовлетворительное значение критерия оправдываемости S/σ_{Δ} не достигается ни при одной заблаговременности, что указывает на необходимость расширения набора входных признаков,

включения дополнительных факторов или применения альтернативных подходов к моделированию.

Модель экстраполяции гидрографа

Анализ выполненных расчётов показал, что из пяти тестовых водосборов только для одного (р. Малиновка (с. Ракитное)) модель экстраполяции гидрографа демонстрирует удовлетворительное качество прогнозов по критерию S/σ_{Δ} для заблаговременности прогноза в одни сутки (табл. 10). Полученный результат подтверждает целесообразность развития нейросетевого подхода с учётом всех аспектов, описанных ранее.

Таблица 10. Значения критерия S/σ_{Δ} для различных заблаговременностей прогноза Δ (в сутках) – модель экстраполяции гидрографа

Table 10. S/σ_{Δ} values for forecast lead times Δ (days) – hydrograph extrapolation model

Название реки (водпост)	Значения S/σ_{Δ} для разной заблаговременности прогноза									
	$\Delta=1$	$\Delta=2$	$\Delta=3$	$\Delta=4$	$\Delta=5$	$\Delta=6$	$\Delta=7$	$\Delta=8$	$\Delta=9$	$\Delta=10$
р. Большая Воровская (с. Соболево)	0.89	0.96	0.97	0.97	0.96	0.96	0.95	0.94	0.94	0.93
р. Малиновка (с. Ракитное)	0.77	0.88	0.91	0.92	0.93	0.92	0.92	0.91	0.91	0.90
р. Сылва (пгт Самары)	0.86	0.90	0.91	0.92	0.92	0.92	0.91	0.91	0.90	0.89
р. Белая (пгт Каменно-мостский)	0.86	0.90	0.89	0.90	0.90	0.89	0.88	0.88	0.88	0.87
р. Малка (с. Каменно-мостское)	0.99	0.98	0.97	0.97	0.97	0.96	0.97	0.97	0.97	0.97

Примечание. Жирным шрифтом выделены значения S/σ_{Δ} , удовлетворяющие критерию оправдываемости $S/\sigma_{\Delta} < 0.80$ (удовлетворительное качество прогноза).

На рис. 9, 10 показано сопоставление прогнозных и фактических значений уровня воды для р. Малиновка (с. Ракитное) с заблаговременностью одни и двое суток для 2017 года.

Заключение

Выполненный комплекс исследований с использованием нейросетевой модели глубокого обучения, связанный с выбором оптимальных методов прогнозирования уровней воды разной заблаговременности для пяти тестовых водосборов, расположенных в различных физико-географических зонах формирования речного стока, и сопоставление их эффективности с проверенными методами прогнозов водного режима, позволяет сформулировать следующие выводы.




Рис. 9. Пример прогноза уровня воды для р. Малиновка (с. Ракитное): сравнение прогнозируемых и фактических значений с заблаговременностью одни сутки для 2017 г. (модель экстраполяции гидрографа).

Fig. 9. Water level forecast for the Malinovka River (Rakitnoye): predicted vs. observed values at a 1-day lead time, 2017 (hydrograph extrapolation model).

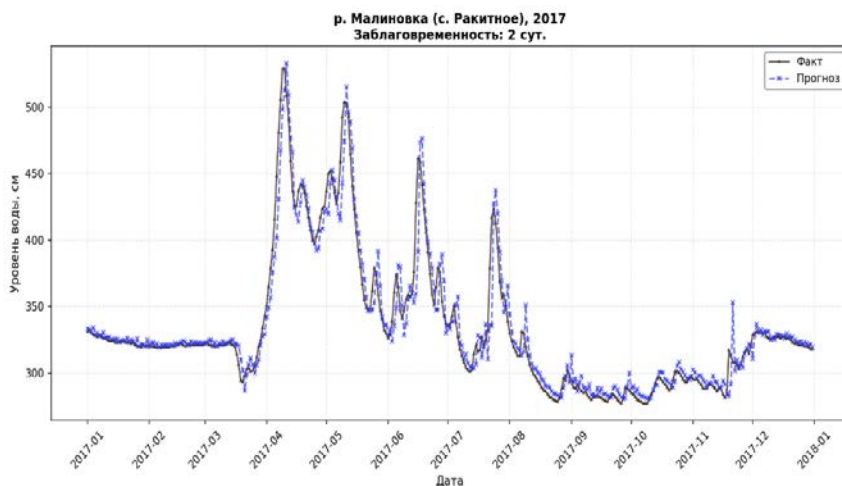


Рис. 10. Пример прогноза уровня воды для р. Малиновка (с. Ракитное): сравнение прогнозируемых и фактических значений с заблаговременностью двое суток для 2017 г. (модель экстраполяции гидрографа).

Fig. 10. Water level forecast for the Malinovka River (Rakitnoye): predicted vs. observed values at a 2-day lead time, 2017 (hydrograph extrapolation model).

Нейросетевой подход имеет определённые преимущества перед ставшими уже классическими статистическими методами, а также методами, базирующимися на концептуальных представлениях о процессе формирования стока. Отметим, что все они в той или иной степени подтверждены в многочисленных публикациях, объём которых непрерывно возрастает [23].

Преимущества перед классическими статистическими моделями

1) Нелинейность и сложность зависимостей

Нейросети способны выявлять нелинейные зависимости между переменными, что позволяет лучше учитывать сложную динамику природных явлений, таких как осадки, испарение, снеготаяние, скорость ветра, уровень грунтовых вод и ряд других характеристик. Тогда как традиционные методы часто основаны на линейных регрессиях или простых преобразованиях.

2) Автоматическое обучение

Современные архитектуры нейросетей позволяют автоматически находить оптимальные веса и коэффициенты, используя большие объемы исторических данных. Это снижает необходимость ручных настроек и повышает точность предсказания по мере увеличения объема данных.

3) Обработка больших объемов данных

Глубокие нейросети легко масштабируются и обрабатывают огромные массивы пространственно-временных данных (спутниковые снимки, метеостанционные наблюдения, данные наблюдения на подземных скважинах). Они эффективно интегрируют разнородные данные из разных источников, улучшая качество прогнозов.

4) Гибкость структуры сети

Архитектуры типа сверточных нейронных сетей и рекуррентных нейронных сетей специально разработаны для обработки изображений и временных рядов, что идеально подходит для анализа гидрологических данных, зависящих от пространства и времени.

5) Повышенная устойчивость к шумам и неопределенности

Благодаря механизмам регуляризации и регулярному обучению, нейросети устойчивее к зашумленным данным и вариациям в исходных данных, характерных для гидрометеорологии.

Преимущества перед концептуальными моделями

1) Отсутствие априорных предположений о физическом механизме процесса

Концептуальные модели требуют глубокого понимания физических законов, управляющих процессами формирования стока, включая почву, грунтовые воды, растительность и климат. Эти знания ограничены и несовершенны, особенно в сложных ландшафтах. Модели на основе нейросетей свободны от такого рода ограничений и извлекают закономерности непосредственно из данных.

2) Моделирование множества факторов одновременно

Для построения качественной концептуальной модели необходим глубокий анализ взаимосвязей между всеми элементами системы водосбора.

Нейросеть же способна учесть влияние всех значимых факторов сразу, минимизируя риск упущенных взаимодействий.

3) *Способность адаптироваться к изменениям условий*

Климатические изменения приводят к изменению характеристик осадков, температуры и иных климатических показателей. Нейросети быстрее адаптируются к новым условиям благодаря своей способности самообучаться на новых данных, тогда как концепция требует трудоемкого обновления теоретической базы и проверки соответствия физическим законам.

4) *Более точное моделирование пространственных изменений*

Использование дополнительных признаков, таких как изображения с помощью свёрточных нейросетей, позволяет учитывать пространственное распределение свойств водосборов: рельеф местности, типы почв, растительный покров, которое трудно (или даже невозможно) формализовать в традиционных моделях.

Таким образом, современные нейросетевые подходы обладают существенными преимуществами в области точности, гибкости и устойчивости, позволяя создавать более точные гидрологические прогнозы с разной заблаговременностью даже в условиях сложной динамики природной среды и нехватки детального физического описания происходящих процессов.

Реализация этих преимуществ в полном объёме в основном ограничивается: 1) недостатком архивного материала по времени наблюдения и 2) отсутствием некоторых гидрогеологических характеристик, связанных с формированием речного стока.

Однако, уже сейчас даже на уровне имеющегося объёма исходной информации на примере пяти тестовых водосборов отчётливо видно преимущество современных нейросетевых методов прогнозов водного режима перед проверенными временем решениями. В этих условиях переход к разработке принципиально новой автоматизированной нейросетевой системы выпуска гидрологических прогнозов разной заблаговременности становится насущной задачей гидрологии суши.

Список литературы

1. Акмаев Э.Р., Романов А.В. Метод долгосрочного прогноза максимального уровня воды р. Исеть на основе глубокого обучения // Гидрометеорологические исследования и прогнозы. 2024. № 4 (394). С. 90-108.
2. Борц С.В., Симонов Ю.А., Христофоров А.В. Прогнозирование стока рек России. М.: Гидрометцентр России, 2023. 200 с.
3. Государственный водный кадастр. Основные гидрологические характеристики (за 1971–1975 гг. и весь период наблюдений). Т. 18. Дальний Восток. Вып. 3. Приморье. Л.: Гидрометеиздат, 1978. 212 с.
4. Государственный водный кадастр. Основные гидрологические характеристики. (за 1971–1975 гг. и весь период наблюдений). Т. 1. Кольский полуостров. Л.: Гидрометеиздат, 1978. 147 с.
5. Ресурсы поверхностных вод СССР. Т. 20. Камчатка. Л.: Гидрометеиздат, 1973. 368 с.

6. Ресурсы поверхностных вод СССР. Основные гидрологические характеристики. Т. 20. Камчатка. Л.: Гидрометеиздат, 1967. 144 с.
7. Ресурсы поверхностных вод СССР. Основные гидрологические характеристики (за 1963–1970 гг. и весь период наблюдений). Т. 11. Средний Урал и Приуралье. Вып. 1. Кама. Л.: Гидрометеиздат, 1975. 476 с.
8. Ресурсы поверхностных вод СССР. Основные гидрологические характеристики (за 1963–1970 гг. и весь период наблюдений). Т. 8. Северный Кавказ. Л.: Гидрометеиздат, 1975. 248 с.
9. Ресурсы поверхностных вод СССР. Т. 1. Кольский полуостров. Л.: Гидрометеиздат, 1970. 316 с.
10. Ресурсы поверхностных вод СССР. Т. 8. Северный Кавказ. Л.: Гидрометеиздат, 1973. 448 с.
11. Романов А.В., Акмаев Э.Р., Червоненкис М.А. Глубокие нейронные сети архитектуры трансформер в задачах гидрологических прогнозов // Гидрометеорологические исследования и прогнозы. 2023. № 2 (388). С. 138-155.
12. Симонов Ю.А., Христофоров А.В., Юмина Н.М., Семенова Н.К., Волов И.С., Шевченко А.И. Краткосрочное и среднесрочное прогнозирование уровней воды на реках России на основе статистических методов // Гидрометеорологические исследования и прогнозы. 2025. № 4 (398). С. 114–128.
13. Чеботарёв А.И. Гидрологический словарь. Л.: Гидрометеиздат, 1978. 308 с.
14. Bai T., Tahmasebi P. Graph neural network for groundwater level forecasting // Journal of Hydrology. 2023. Vol. 616. P. 128792.
15. Chang F.J., Chen Y.C. A counterpropagation fuzzy-neural network modeling approach to real time streamflow prediction // Journal of Hydrology. 2001. Vol. 245, no. 1-4. P. 153-164.
16. Chen C.W. et al. Application of neural networks and optimization model in conjunctive use of surface water and groundwater // Water resources management. 2014. Vol. 28. P. 2813-2832.
17. Dawson C.W., Wilby R.L. An artificial neural network approach to rainfall-runoff modelling // Hydrological Sciences Journal. 1998. Vol. 43, no. 1. P. 47-66.
18. Djurovic N. et al. Comparison of groundwater level models based on artificial neural networks and ANFIS // The Scientific World Journal. 2015. No. 1. C. 742138.
19. Guimarães Santos C.A., Silva G.B.L. Daily streamflow forecasting using a wavelet transform and artificial neural network hybrid models // Hydrological Sciences Journal. 2014. Vol. 59, no. 2. P. 312-324.
20. Liu F., Xu F., Yang S. A flood forecasting model based on deep learning algorithm via integrating stacked autoencoders with BP neural network // 2017 IEEE third International conference on multimedia big data (BigMM). Ieee, 2017. P. 58-61.
21. Manual on Flood Forecasting and Warning // WMO-№ 1072. 2011. 138 p.
22. Mohanty S. et al. Using artificial neural network approach for simultaneous forecasting of weekly groundwater levels at multiple sites // Water Resources Management. 2015. Vol. 29. P. 5521-5532.
23. Muhammed Si., Bekir Zahit Demiray, Zhongrun Xiang, Gregory J. Ewing, Yusuf Sermet A comprehensive review of deep learning applications in hydrology and water resources // Water Science & Technology. 2020. Vol. 82, no. 12. P. 2635-2670. DOI: 10.2166/wst.2020.369
24. Oyeboode O., Stretch D. Neural network modeling of hydrological systems: A review of implementation techniques // Natural Resource Modeling. 2019. Vol. 32, no. 1. P. e12189.
25. Shen C., Lawson K. Applications of deep learning in hydrology // Deep Learning for the Earth Sciences: A Comprehensive Approach to Remote Sensing, Climate Science, and Geosciences. 2021. P. 283-297. <https://doi.org/10.1002/9781119646181.ch19>
26. Tao H. et al. Groundwater level prediction using machine learning models: A comprehensive review // Neurocomputing. 2022. Vol. 489. P. 271-308.
27. Wunsch A., Liesch T., Broda S. Groundwater level forecasting with artificial neural networks: a comparison of long short-term memory (LSTM), convolutional neural networks (CNNs),

and non-linear autoregressive networks with exogenous input (NARX) // *Hydrology and Earth System Sciences*. 2021. Vol. 25, no. 3. P. 1671-1687.

28. Ying Nie1, Kok Hwa Yu1, Yang Wang1, PeiSen Liu. Applications of machine learning and deep learning in hydrology from a bibliometric perspective: a comprehensive review // *Discover Artificial Intelligence*. 2025. Vol. 5, no. 242. <https://doi.org/10.1007/s44163-025-00471-x>

References

1. Akmaev E.R., Romanov A.V. Deep learning long-term method of maximum water level forecast of the Iset. *Gidrometeorologicheskie issledovaniya i prognozy* [Hydrometeorological Research and Forecasting], 2024, vol. 394, no. 4, pp. 90-108 [in Russ.].

2. Borsch S.V., Simonov Yu.A., Khristoforov A.V. Prognozirovaniye stoka rek Rossii [Stream-flow forecasting in Russia]. Moscow, Izd-vo FGBU «Gidrometcentr Rossii», 2023, 200 p. [in Russ.].

3. Gosudarstvennyy vodnyy kadastr. Osnovnye gidrologicheskie karakteristiki (za 1971–1975 gg. i ves' period nablyudeniya). T. 18. Dal'niy Vostok. Vyp. 3. Primor'e. Leningrad, Gidrometeoizdat publ., 1978, 212 p. [in Russ.].

4. Gosudarstvennyy vodnyy kadastr. Osnovnye gidrologicheskie karakteristiki. (za 1971–1975 gg. i ves' period nablyudeniya). Vol. 1. Kol'skiy poluostrov. Leningrad, Gidrometeoizdat publ., 1978. 147 p. [in Russ.].

5. Resursy poverhnostnykh vod SSSR. T. 20. Kamchatka. Leningrad, Gidrometeoizdat publ., 1973, 368 p. [in Russ.].

6. Resursy poverhnostnykh vod SSSR. Osnovnye gidrologicheskie karakteristiki. Vol. 20. Kamchatka. Leningrad, Gidrometeoizdat publ., 1967, 144 p. [in Russ.].

7. Resursy poverhnostnykh vod SSSR. Osnovnye gidrologicheskie karakteristiki (za 1963–1970 gg. i ves' period nablyudeniya). Vol. 11. Sredniy Ural i Priural'e. Vyp. 1. Kama. Leningrad, Gidrometeoizdat publ., 1975, 476 p. [in Russ.].

8. Resursy poverhnostnykh vod SSSR. Osnovnye gidrologicheskie karakteristiki (za 1963–1970 gg. i ves' period nablyudeniya). Vol. 8. Severniy Kavkaz. Leningrad, Gidrometeoizdat publ., 1975, 248 p. [in Russ.].

9. Resursy poverhnostnykh vod SSSR. Vol. 1. Kol'skiy poluostrov. Leningrad, Gidrometeoizdat publ., 1970, 316 p. [in Russ.].

10. Resursy poverhnostnykh vod SSSR. Vol. 8. Severniy Kavkaz. Leningrad, Gidrometeoizdat publ., 1973, 448 p. [in Russ.].

11. Romanov A.V., Akmaev E.R., Chervonenkis M.A. Deep neural networks of transformer architecture in problems of hydrological forecasts. *Gidrometeorologicheskie issledovaniya i prognozy* [Hydrometeorological Research and Forecasting], 2023, vol. 388, no. 2, pp. 138-155 [in Russ.].

12. Simonov Yu.A., Khristoforov A.V., Yumina N.M., Semenova N.K., Volov I.S., Shevchenko A.I. Short- and medium-range forecasting of water levels on Russian rivers based on statistical methods. *Gidrometeorologicheskie issledovaniya i prognozy* [Hydrometeorological Research and Forecasting], 2025, vol. 398, no. 4, pp. 114-128 [in Russ.].

13. Chebotarev A.I. *Gidrologicheskiy slovar'* [Hydrological dictionary]. Leningrad, Gidrometeoizdat publ., 1978, 308 p. [in Russ.].

14. Bai T., Tahmasebi P. Graph neural network for groundwater level forecasting. *Journal of Hydrology*, 2023, vol. 616, pp. 128792.

15. Chang F.J., Chen Y.C. A counterpropagation fuzzy-neural network modeling approach to real time streamflow prediction. *Journal of Hydrology*, 2001, vol. 245, no. 1-4, pp. 153-164.

16. Chen C.W. et al. Application of neural networks and optimization model in conjunctive use of surface water and groundwater. *Water resources management*, 2014, vol. 28, pp. 2813-2832.

17. Dawson C.W., Wilby R.L. An artificial neural network approach to rainfall-runoff modelling. *Hydrological Sciences Journal*, 1998, vol. 43, no. 1, pp. 47-66.

18. Djurovic N. et al. Comparison of groundwater level models based on artificial neural networks and ANFIS. *The Scientific World Journal*, 2015, no. 1, p. 742138.
19. Guimarães Santos C.A., Silva G.B.L. Daily streamflow forecasting using a wavelet transform and artificial neural network hybrid models. *Hydrological Sciences Journal*, 2014, vol. 59, no. 2, pp. 312-324.
20. Liu F., Xu F., Yang S. A flood forecasting model based on deep learning algorithm via integrating stacked autoencoders with BP neural network. 2017 IEEE third International conference on multimedia big data (BigMM). Ieee, 2017, pp. 58-61.
21. WMO-№ 1072. Manual on Flood Forecasting and Warning. WMO, Geneva, 2011, 138 p.
22. Mohanty S. et al. Using artificial neural network approach for simultaneous forecasting of weekly groundwater levels at multiple sites. *Water Resources Management*, 2015, vol. 29, pp. 5521-5532.
23. Muhammed Si., Bekir Zahit Demiray, Zhongrun Xiang, Gregory J. Ewing, Yusuf Sermet. A comprehensive review of deep learning applications in hydrology and water resources. *Water Science & Technology*, 2020, vol. 82, no. 12, pp. 2635-2670. DOI: 10.2166/wst.2020.369
24. Oyeboode O., Stretch D. Neural network modeling of hydrological systems: A review of implementation techniques. *Natural Resource Modeling*, 2019, vol. 32, no. 1, p. e12189.
25. Shen C., Lawson K. Applications of deep learning in hydrology // *Deep Learning for the Earth Sciences: A Comprehensive Approach to Remote Sensing, Climate Science, and Geosciences*, 2021, pp. 283-297. DOI: 10.1002/9781119646181.ch19
26. Tao H. et al. Groundwater level prediction using machine learning models: A comprehensive review. *Neurocomputing*, 2022, vol. 489, pp. 271-308.
27. Wunsch A., Liesch T., Broda S. Groundwater level forecasting with artificial neural networks: a comparison of long short-term memory (LSTM), convolutional neural networks (CNNs), and non-linear autoregressive networks with exogenous input (NARX). *Hydrology and Earth System Sciences*, 2021, vol. 25, no. 3, pp. 1671-1687.
28. Ying Nie1, Kok Hwa Yu1, Yang Wang1, PeiSen Liu. Applications of machine learning and deep learning in hydrology from a bibliometric perspective: a comprehensive review. *Discover Artificial Intelligence*, 2025, vol. 5, no. 242. DOI: 10.1007/s44163-025-00471-x.

*Поступила 10.02.2026; принята в печать 26.05.2026.
Submitted 10.02.2026; accepted for publication 26.05.2026.*