

## Исследование моделей рекуррентных нейронных сетей для прогнозирования уровня реки на примере данных о реке Амур

*Э.М. Вихтенко, М.С. Глеков*

*Тихоокеанский государственный университет, Хабаровск*

**Аннотация:** В работе исследуется применение рекуррентных нейронных сетей для прогнозирования уровня воды в реке Амур. Описаны преимущества использования таких сетей по сравнению с традиционными методами машинного обучения. Проведено сравнение различных архитектур рекуррентных сетей, выполнена оптимизация гиперпараметров модели. Разработанная модель, основанная на длинной краткосрочной памяти, продемонстрировала высокую точность прогнозирования, превосходящую традиционные методы. Полученные результаты могут быть использованы для повышения эффективности мониторинга водных ресурсов и предупреждения паводков.

**Ключевые слова:** анализ временных рядов, Амур, уровень воды, прогнозирование, нейронные сети, рекуррентная сеть

### Введение

Река Амур, одна из крупнейших водных артерий мира, протекает через территории России, Монголии и Китая и играет важную роль в экологии и экономике региона. Река длиной около 2824 километров служит жизненно важным ресурсом для миллионов людей, поддерживая сельское хозяйство, рыболовство и транспорт. Однако уровень воды в реке Амур подвержен значительным колебаниям. Амур – не очень типичная река для России, её колебания связаны не только с весенним половодьем, но и со многими другими факторами [1]. Колебания в русле реки составляют 10 метров в среднем и нижнем течении. Подобный гидрологический режим реки сильно влияет на жителей прибрежных городов. Так, ежегодно хабаровчане сталкиваются с резкими, неожиданными изменениями уровня воды. Регулярно от неожиданных наводнений страдают жители территорий дачных участков и домов, расположенных около берега реки.

Традиционные методы мониторинга уровня воды в реках часто основаны на данных, получаемых от гидрометрических станций и ручных измерений, которые могут быть трудоемкими, отнимать много времени и

иметь значительные погрешности. Эти методы часто не обладают возможностью предоставлять данные в реальном времени и прогнозную информацию, необходимую для эффективного управления водными ресурсами и повышения готовности к стихийным бедствиям. Поэтому существует острая необходимость в более совершенных и эффективных методах мониторинга и прогнозирования уровня воды в реке. Мы живем в эпоху стремительного развития цифровых информационных технологий. Одной из самых развивающихся сфер информационных технологий является Data Science. Data Science – это применение научных методов при работе с данными, включающие их обработку и анализ. Специалист в области Data Science работает с данными так же, как ученый в любой другой сфере. Он использует математические методы, логические принципы и современные инструменты визуализации, чтобы получить результат. В последнее время активно используются различные нейросетевые алгоритмы, хорошо зарекомендовавшие себя для задач анализа больших данных природных [2] и антропогенных систем [3, 4]. Большое внимание исследователи уделяют задачам контроля гидрологической ситуации, в том числе методами нейросетевого анализа спутниковых данных [5, 6].

Основная цель данного исследования заключается в изучении применения рекуррентных нейронных сетей (далее RNN) для мониторинга уровня воды в реке Амур. Рекуррентные нейронные сети – это сети с обратными или перекрестными связями между различными слоями нейронов. Архитектура RNN разработана для обработки последовательностей однотипных данных, т.е. хорошо подходит для выявления зависимостей во временных рядах. Эта особенность RNN сделала их популярными для исследований в различных областях [7-9].

Используя возможности RNN для моделирования временных рядов и выявления закономерностей в гидрологических данных, мы стремимся

---

разработать прогностическую модель, которая сможет обеспечить точные и своевременные прогнозы изменений уровня воды в реке. Это исследование направлено на демонстрацию того, что использование RNN может повысить точность и надежность систем мониторинга уровня воды, тем самым способствуя улучшению управления водными ресурсами и усилиям по смягчению последствий стихийных бедствий.

### Анализ научной литературы

В различных исследованиях изучалось применение моделей машинного обучения для мониторинга уровня реки Амур [10-12]. Регрессионные модели, полносвязные нейронные сети и градиентный бустинг (далее CatBoost) были тщательно проанализированы на предмет их потенциала для моделирования и прогнозирования уровня воды в реках. Каждая из моделей, использованных для прогнозирования паводков на реке Амур, имеет свои преимущества:

- 1) линейная регрессия: простота интерпретации результатов, меньшая склонность к переобучению на небольших объемах данных;
- 2) нейронные сети: способность распознавать сложные нелинейные закономерности в данных; гибкость в адаптации к различным типам данных и задач;
- 3) CatBoost: высокая производительность и точность прогнозирования, способность работать с большими объемами данных, эффективное использование признаков разного типа.

Несмотря на эти достижения, сохраняется необходимость более эффективно решать проблемы, присущие временным зависимостям гидрологических данных.

Авторы данной работы считают, что рекуррентные нейронные сети будут полезны для работы с гидрологическими данными, так как обладают рядом особенностей.

---

1) Обработка временных зависимостей. RNN специально разработаны для фиксации временных зависимостей в последовательных данных путем сохранения памяти о предыдущих входных данных посредством их повторяющихся соединений. Традиционные модели регрессии и полносвязные нейронные сети по своей сути не учитывают временной порядок точек данных, что делает их менее эффективными для анализа временных рядов.

2) Последовательная обработка данных. RNN обрабатывают входные данные последовательно, что позволяет им со временем выявлять скрытые закономерности и взаимосвязи. Градиентный бустинг хотя и эффективен для обработки нелинейных зависимостей, обычно лучше подходит для статических данных и не поддерживают последовательную обработку данных.

3) Сохранение памяти. RNN способны сохранять информацию из предыдущих временных шагов, что имеет решающее значение для точных прогнозов на основе прошлых событий. Полносвязные нейронные сети не имеют встроенного механизма сохранения памяти и часто требуют дополнительных шагов предварительной обработки для эффективной обработки последовательностей.

4) Динамически изменяющаяся длина входных данных. RNN могут обрабатывать входные последовательности различной длины, что делает их универсальными для разных типов данных временных рядов без необходимости использования входных векторов фиксированного размера. Регрессионные модели и полносвязные нейронные сети обычно требуют входных векторов фиксированного размера, что может ограничивать их гибкость при обработке временных рядов переменной длины.

5) Учет долгосрочных зависимостей. Варианты RNN, такие как сети с длинной краткосрочной памятью (далее LSTM) и GRU, предназначены для улавливания долгосрочных зависимостей и смягчения проблемы

---

исчезновения градиента. Другие методы, такие, как повышение градиента и традиционные нейронные сети, могут иметь проблемы с долгосрочными зависимостями в последовательных данных из-за их архитектурных ограничений.

б) Прогнозирование в реальном времени. RNN можно использовать для прогнозирования в реальном времени, постоянно обновляя их состояние новыми входными данными, что делает их подходящими для приложений, требующих немедленного реагирования. Такие методы, как градиентный бустинг, обычно требуют пакетной обработки и по своей сути не предназначены для приложений реального времени.

Благодаря таким особенностям, RNN могут предоставлять более точные и надежные прогнозы уровня воды в реке, тем самым повышая эффективность управления водными ресурсами и усилий по смягчению последствий стихийных бедствий.

### **Методология исследования**

Данные, использованные в этом исследовании, получены с веб-сайта Dvhub, на котором хранятся подробные данные об уровне воды в реке Амур у города Хабаровска [13]. Всего было собрано 3660 ежедневных записей уровня воды за период с 31.03.2014 по 11.04.2024. Этот обширный набор данных обеспечивает надежную основу для разработки и оценки прогностических возможностей модели рекуррентной нейронной сети RNN.

Для подготовки данных к анализу было предпринято несколько этапов предварительной обработки.

Этап 1. Нормализация данных. Собранные данные нормализуются с помощью MinMaxScaler, который преобразует данные в фиксированный диапазон, обычно [0, 1]. Преимущества использования MinMaxScaler включают в себя:

- сохранение распределения данных: сохраняется исходное распределение и взаимосвязи внутри данных, что имеет решающее значение для точного моделирования;
- улучшенная сходимость: нормализация может привести к более быстрой сходимости во время обучения, поскольку оно нормализует данные, что делает процесс оптимизации более эффективным.

Нормализованное значение вычисляется по следующей формуле:

$$X_{scaled} = \frac{X - X_{min}}{X_{max} - X_{min}},$$

где  $X$  – исходное значение;  $X_{min}$  – минимальное значение в наборе данных;  $X_{max}$  – максимальное значение в наборе данных;  $X_{scaled}$  – нормализованное значение.

Этап 2. Создание последовательности. Чтобы позволить RNN эффективно учиться на временных последовательностях, данные обработаны с помощью функции, предназначенной для создания последовательностей данных. Эта функция создает входные последовательности и соответствующие метки для модели RNN. Процедура следующая:

- генерация последовательности: функция перебирает нормализованные данные, создавая последовательности заданного размера окна. Для этого исследования использовался размер окна в 30 дней, то есть модель использует данные за последние 30 дней для прогнозирования уровня воды на следующий день;
- изменение формы входных данных RNN: сгенерированные последовательности изменяются в соответствии с входными требованиями RNN, в результате чего получается трехмерный массив, пригодный для обучения.

Этап 3. Разделение набора данных. Набор данных разделен на три подмножества: обучающий набор (60% от всего набора данных), набор

---

перекрестной проверки – кросс-валидации (20% от всего набора данных) и тестовый набор (20% от всего набора данных).

Обучающий набор – это подмножество, используемое для обучения модели RNN, содержит большую часть данных, что позволяет модели изучать основные закономерности и взаимосвязи. Набор перекрестной проверки используется в процессе обучения для настройки гиперпараметров и предотвращения переобучения. Набор перекрестной проверки позволяет корректировать параметры модели на основе обратной связи о производительности. Тестовый набор используется для оценки окончательной модели, обеспечивает объективную оценку прогнозных характеристик модели на не видимых ранее моделью данных.

Это разделение необходимо для обеспечения того, чтобы модель не только эффективно обучалась, но и хорошо обобщала выявленные зависимости на новые данные. Используя отдельные наборы для обучения, проверки и тестирования, можно точно оценить производительность модели и гарантировать ее устойчивость и надежность.

В ходе выполнения этапов предварительной обработки данные преобразованы в формат, который облегчает эффективное обучение с помощью модели RNN, тем самым повышая способность модели точно прогнозировать будущие уровни воды в реке Амур.

Для оценки производительности модели RNN использовались метрики средней абсолютной ошибки (далее MAE) и корня средней квадратичной ошибки (далее RMSE). MAE определяется как среднее значение модулей разности между прогнозируемыми и фактическими значениями. Она позволяет оценить средний уровень ошибки модели, игнорируя направление ошибки, что делает её легко интерпретируемой и интуитивно понятной. RMSE рассчитывается как квадратный корень из среднего значения квадратов ошибок. Эта метрика более чувствительна к большим отклонениям, поскольку

---

возведение в квадрат увеличивает значительные отклонения. Таким образом, RMSE предоставляет информацию о вариативности ошибок и может выявлять случаи, когда модель делает большие ошибки.

Использование обеих метрик в исследовании позволяет получить более полную картину производительности модели. MAE предоставляет общий уровень ошибок, в то время как RMSE акцентирует внимание на больших ошибках, помогая оценить надёжность и стабильность модели в условиях возможных экстремальных значений уровня реки.

Метрики рассчитываются по следующим формулам:

$$MAE = \frac{1}{m} \sum_{i=1}^m |\hat{y}^{(i)} - y^{(i)}|, \quad RMSE = \frac{1}{m} \sqrt{\sum_{i=1}^m (\hat{y}^{(i)} - y^{(i)})^2},$$

где  $m$  – количество наблюдений;  $\hat{y}^{(i)}$  – предсказанный уровень воды;  $y^{(i)}$  – фактическое значение воды.

В данном исследовании для оценки модели RNN на этапе кросс-валидации оценка ошибки выполняется по метрике MAE, а оптимизация модели производится по функции затрат, основанной на MAE.

Для тестирования модели используются обе метрики MAE и RMSE. MAE применяется для оценки среднего уровня ошибки модели, тогда как RMSE позволяет выявить и акцентировать внимание на значительных отклонениях в прогнозах. Совместное использование этих метрик предоставляет всестороннюю оценку производительности модели, учитывая как средний уровень ошибки, так и её вариативность.

Для решения задачи прогнозирования уровня воды в реке в работе используются сети с архитектурой, называемой длинной краткосрочной памятью (Long short-term memory; LSTM) [14], из-за их способности фиксировать временные зависимости и долгосрочные отношения в последовательных данных. Сети LSTM представляют собой

специализированную форму RNN, особенно эффективны в решении проблемы исчезающего градиента, которая часто встречается в стандартных RNN. Ключевые преимущества слоев LSTM включают в себя:

- 1) сохранение памяти – LSTM хранят информацию в длинных последовательностях, что важно для моделирования данных временных рядов, когда прошлые значения влияют на будущие прогнозы;
- 2) обработка нестационарных данных. Слои LSTM могут адаптироваться к изменениям в структуре данных с течением времени, что делает их пригодными для гидрологических данных, которые могут демонстрировать сезонные или нерегулярные изменения;
- 3) распознавание сложных образов. Путем объединения нескольких слоев LSTM модель может изучать сложные иерархические закономерности в данных, повышая свою прогностическую эффективность.

Предпоследний полносвязный слой играет решающую роль в архитектуре модели, выступая в качестве моста между уровнями LSTM и конечным выходным слоем. Его основные функции:

- 1) уменьшение размерности. Полносвязный слой уменьшает размерность выходных данных слоев LSTM, превращая изученные функции в более компактное представление;
- 2) нелинейное преобразование. Применяя функцию нелинейной активации, плотный слой может захватывать и преобразовывать изученные функции, повышая способность модели делать точные прогнозы;
- 3) интеграция изученных функций. Этот уровень объединяет временные функции, изученные слоями LSTM, позволяя модели делать обоснованные прогнозы на основе всей последовательности.

Для определения оптимальной конфигурации и гиперпараметров модели RNN использован KerasTuner. Этот инструмент облегчает

систематическое исследование гиперпараметров для повышения производительности модели.

Процесс настройки выполнен в два этапа. На первом этапе определена архитектура сети (построена модель сети), на втором проведена компиляция сети.

Для построения модели RNN создана пользовательская функция, позволяющая настраивать различные гиперпараметры:

- количество слоев LSTM варьировалось от 1 до 4; в каждом слое количество элементов настраивалось от 32 до 512 с шагом 32;
- добавлен полносвязный слой с функцией активации ReLU, количество нейронов в нем также изменялось от 32 до 512 с шагом 32 нейронов;
- для получения выходных данных был включен последний слой с одним нейроном.

Модель скомпилирована с использованием оптимизатора Adam, при этом скорость обучения настраивалась логарифмически в диапазоне от  $10^{-4}$  до  $10^{-2}$ . В качестве функции потерь использовалась метрика MAE.

Процесс настройки гиперпараметров выполнен с использованием стратегии случайного поиска. Всего проведено 50 испытаний, каждое испытание проводилось трижды для обеспечения надежности. Процесс настройки включал раннюю остановку для прекращения обучения в случае, когда потери при проверке переставали улучшаться в течение 10 эпох. Поиск проводился с использованием наборов данных обучения и перекрестной проверки с целью определить оптимальную конфигурацию гиперпараметров, которая минимизирует потери при проверке.

В результате перекрестной проверки проверены различные конфигурации гиперпараметров. В таблице 1 представлены результаты десяти лучших испытаний, упорядоченных по величине MAE.

В ходе проведенного тестирования выявлено, что наилучшие результаты достигаются при следующих гиперпараметрах:

1. входной LSTM-слой – 384 нейрона;
2. скрытый полносвязный слой – 416 нейронов с функцией активации ReLU;
3. выходной полносвязный слой – 1 нейрон;
4. скорость обучения – 0.000126;
5. размер батча – 32;
6. оптимизатор – Adam;
7. количество эпох обучения – 67.

Таблица № 1

Результаты кросс-валидации для определения конфигурации гиперпараметров модели

Количество слоев	Количество нейронов в слое 0	Количество нейронов в слое 1	Количество нейронов в слое 2	Количество нейронов в полносвязном слое	Скорость обучения	MAE
1	384	-	-	416	0.000126	0.0047
1	32	-	-	32	0.00052	0.0048
1	64	-	-	288	0.000577	0.0049
1	288	-	-	224	0.000259	0.0049
1	224	-	-	224	0.000191	0.0049
1	128	-	-	512	0.000538	0.0049
2	96	288	-	416	0.000921	0.005
3	128	32	384	288	0.001553	0.005
2	224	96	128	192	0.000131	0.005
2	96	384	384	64	0.000221	0.0051

Эта конфигурация показала наименьшее значение MAE, что свидетельствует о наивысшей точности модели при данных настройках

гиперпараметров. Интересно отметить, что большинство лучших конфигураций имеют только один скрытый слой, что указывает на достаточную способность модели с небольшим количеством слоев обрабатывать временные ряды данных для мониторинга уровня реки, причем увеличение количества слоев не всегда приводит к улучшению результатов, как видно из результатов кросс-валидации.

### Полученные результаты

Окончательная проверка выбранной модели на тестовой выборке дала следующие результаты: MAE = 5.69; RMSE = 11.48.

Метрика MAE, равная 5.69, указывает на то, что в среднем прогнозируемые значения уровня реки отклоняются от фактических значений на 5.69 единиц. Это свидетельствует о достаточно высокой точности модели, так как средняя ошибка прогноза находится на приемлемом уровне для задач подобного рода.

Этот результат демонстрирует, что RNN со слоями LSTM и одним полносвязным скрытым слоем демонстрирует высокий уровень производительности при прогнозировании уровня воды в реке Амур. Достигнутый MAE указывает на то, что модель RNN способна давать очень точные прогнозы со средним отклонением всего 5.69 единиц от фактических зарегистрированных уровней воды.

Эта производительность заметно превосходит эффективность традиционных методов машинного обучения. Предыдущие исследования, в которых использовались различные модели, такие как CatBoost, регрессионная модель и полносвязанные нейронные сети, показали MAE = 28.19 [10].

Существенное улучшение точности прогнозирования, о чем свидетельствует более низкий MAE, подтверждает превосходство модели RNN со слоями LSTM над традиционными методами машинного обучения для

---

этого конкретного приложения. Это исследование демонстрирует потенциал передовых архитектур нейронных сетей в гидрологическом прогнозировании и предполагает, что дальнейшее изучение таких моделей может дать еще более точные и надежные прогнозы.

Метрика RMSE, равная 11.48, также подтверждает приемлемую точность модели, хотя и указывает на наличие отдельных больших отклонений в прогнозах. Поскольку RMSE более чувствительна к большим ошибкам из-за квадратичного характера метрики, значение 11.48 указывает на то, что некоторые прогнозы имеют более значительные отклонения, чем средние значения.

На рисунке 1 можно наблюдать график фактических значений по тестовой выборке (синяя линия) и предсказанные моделью значения (красная линия).

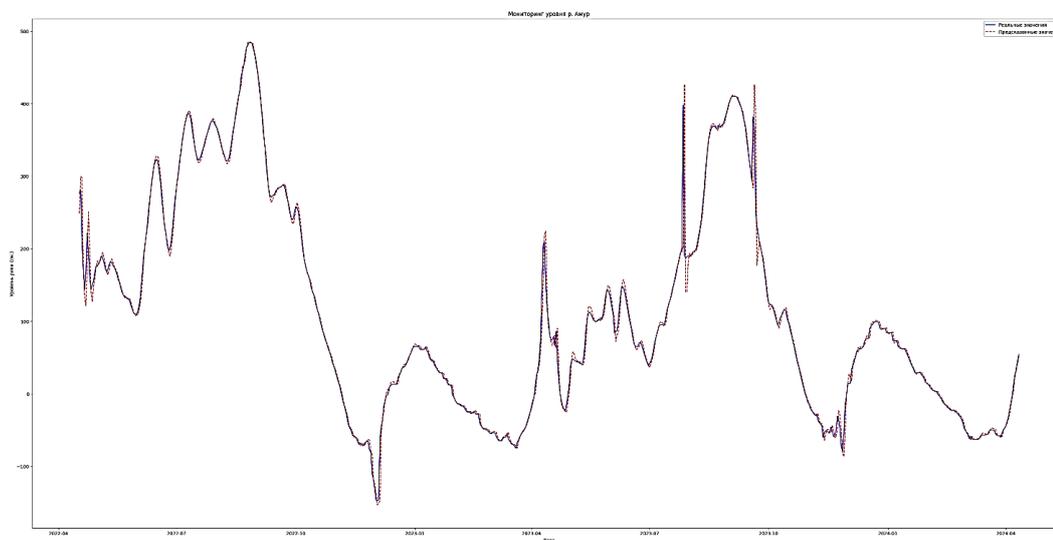


Рис. 1. – График уровня реки Амур (фактический и предсказанный) по тестовой выборке

По графику видно, что модель RNN в большинстве случаев адекватно предсказывает уровень реки. Небольшое количество резких выбросов, которые модель не смогла предсказать с высокой точностью, указывает на возможные случаи аномальных данных или экстремальных условий, которые

могут потребовать дополнительной обработки или адаптации модели. Тем не менее, общая тенденция прогнозов модели достаточно точно отражает фактические изменения уровня реки, что подтверждается низкими значениями метрик MAE и RMSE.

### **Заключение**

В результате проведенного исследования изучена эффективность модели RNN с использованием LSTM-слоев для предсказания уровня воды в реке Амур. Модель тщательно оптимизирована с использованием различных гиперпараметров и оценена на основе метрик MAE и RMSE.

Тестирование показало, что модель демонстрирует высокую точность прогнозов, что свидетельствует о ее способности адекватно предсказывать уровень воды с минимальными ошибками. Как показал анализ полученных результатов, модель корректно предсказывает большинство изменений уровня реки, хотя отдельные резкие выбросы предсказываются с меньшей точностью.

Сравнительный анализ с другими методами машинного обучения, рассмотренными в литературе, подтвердил, что предложенная RNN модель с LSTM-слоями обладает большей эффективностью и меньшей ошибкой предсказаний. Это делает её подходящей для практического применения в задачах мониторинга уровня воды в реке Амур.

Таким образом, данная модель может быть рекомендована для использования в системах предупреждения и мониторинга, обеспечивая своевременные и точные прогнозы изменений уровня реки.

*Работа выполнена при финансовой поддержке Министерства науки и высшего образования Российской Федерации, дополнительное соглашение № 75-02-2024-1432 от 28 февраля 2024 г.*

### **Литература**

1. Борщ С. В., Симонов Ю. А., Христофорова А. В., Юмина Н. М. Краткосрочное прогнозирование уровней воды на реке Амур // Результаты

испытания новых и усовершенствованных технологий, моделей и методов гидрометеорологических прогнозов. 2017. № 44. С. 136-151.

2. Скрипачев В. О., Гуйда М. В., Гуйда Н. В., Жуков А. О. Исследование сверточных нейронных сетей для обнаружения объектов на аэрокосмических снимках // International Journal of Open Information Technologies. 2022. Т. 10. № 7. С. 54-63.

3. Глухих И. Н., Карякин Ю. Е., Березовский А. К., Дудина А. А. Классификация состояний объектов городской инфраструктуры с использованием нейронных сетей // Инженерный вестник Дона. 2021. № 8. URL: [ivdon.ru/ru/magazine/archive/n8y2021/7143](http://ivdon.ru/ru/magazine/archive/n8y2021/7143).

4. Белоусов И. С., Рогачев А. Ф. Разработка глубокой нейронной сети для сегментации проблемных участков сельскохозяйственных полей // Инженерный вестник Дона. 2022. № 8. URL: [ivdon.ru/ru/magazine/archive/n8y2022/7864](http://ivdon.ru/ru/magazine/archive/n8y2022/7864).

5. Курганович К. А., Шаликовский А. В., Босов М. А., Кочев Д. В. Применение алгоритмов искусственного интеллекта для контроля паводкоопасных территорий // Водное хозяйство России. 2021. № 3. С. 6-24.

6. Терехов А. Г., Абаев Н. Н., Сагатдинова Г. Н. и др. Спутниковый мониторинг речных отмелей трансграничной реки Или (Центральная Азия) в задаче оценки уровня воды // Современные проблемы дистанционного зондирования Земли из космоса. 2023. Т. 20. № 4. С. 227-238. DOI: 10.21046/2070-7401-2023-20-4-227-238.

7. Nagesh K. D., Srinivasa R. K., Sathish T. River Flow Forecasting using Recurrent Neural Networks // Water Resources Management. 2004. N 18. Pp. 143–161. DOI: 10.1023/B:WARM.0000024727.94701.12.

8. Waqas M., Humphries U. W. A critical review of RNN and LSTM variants in hydrological time series predictions // MethodsX. 2024. V. 13. 102946. DOI: 10.1016/j.mex.2024.102946.

---

9. Новикова А. А., Кудяшов А. А., Вегера Д. В. Прогнозирование концентраций газов на основе рекуррентной нейронной сети // Инженерный вестник Дона. 2024. № 7. URL: [ivdon.ru/ru/magazine/archive/n7y2024/9359](http://ivdon.ru/ru/magazine/archive/n7y2024/9359)
10. Александров Н. Э., Ермаков Д. Н., Азиз Н. М. Х. А., Казенков О. Ю. Определение оптимальной модели машинного обучения для предсказания паводков на реке Амур // Computational nanotechnology. 2022. № 2. С. 11-20. DOI: 10.33693/2313-223X-2022-9-2-11-20.
11. Кучма М. О., Воронин В. В., Шамилова Ю. А., Амельченко Ю. А. Разработка нейросетевого алгоритма оперативного детектирования разливов бассейна реки Амур на основе данных космического аппарата Sentinel-2 // Системы анализа и обработки данных. 2022. № 3. С. 7-20.
12. Саноцкая Н. А., Лоскутов Д. А., Ромашова К. В. Прогнозирование максимального уровня воды рек как обобщенного параметра состояния сложной нелинейной системы на основе использования многослойной нейронной сети // Технологии гражданской безопасности. 2022. № 2. С. 14-20. DOI: 10.54234/CST.19968493.2022.19.2.72.3.14.
13. DVHub: Уровень воды в Амуре у Хабаровска онлайн. URL: [dvhab.ru/uroven-amura](http://dvhab.ru/uroven-amura).
14. Hochreiter S., Schmidhuber J. Long Short-Term Memory // Neural Comput. 1997. N 9 (8). Pp. 1735–1780. DOI: 10.1162/neco.1997.9.8.1735.

### References

1. Borshh S. V., Simonov Ju. A., Hristoforov A. V., Jumina N. M. Rezul'taty ispytaniya novyh i usovershenstvovannyh tehnologij, modelej i metodov gidrometeorologicheskikh prognozov, 2017, № 44, pp. 136-151.
2. Skripachev V. O., Gujda M. V., Gujda N. V., Zhukov A. O. International Journal of Open Information Technologies, 2022, V. 10, № 7, pp. 54-63.
-



3. Gluhih I. N., Karjakin Ju. E., Berezovskij A. K., Dudina A. A. Inzhenernyj vestnik Dona, 2021, № 8. URL: [ivdon.ru/ru/magazine/archive/n8y2021/7143](http://ivdon.ru/ru/magazine/archive/n8y2021/7143).
4. Belousov I. S., Rogachev A. F. Inzhenernyj vestnik Dona, 2022, № 8. URL: [ivdon.ru/ru/magazine/archive/n8y2022/7864](http://ivdon.ru/ru/magazine/archive/n8y2022/7864).
5. Kurganovich K. A., Shalikovskij A. V., Bosov M. A., Kochev D. V. Vodnoe hozjajstvo Rossii, 2021, № 3, pp. 6-24.
6. Terehov A. G., Abaev N. N., Sagatdinova G. N. i dr. Sovremennye problemy distancionnogo zondirovaniya Zemli iz kosmosa, 2023, V. 20, № 4, pp. 227-238. DOI: 10.21046/2070-7401-2023-20-4-227-238.
7. Nagesh K. D., Srinivasa R. K., Sathish T. Water Resources Management, 2004, N 18, pp. 143–161. DOI: 10.1023/B:WARM.0000024727.94701.12.
8. Waqas M., Humphries U. W. MethodsX, 2024, V. 13, 102946. DOI: 10.1016/j.mex.2024.102946.
9. Novikova A. A., Kudjashov A. A., Vegera D. V. Inzhenernyj vestnik Dona, 2024, № 7. URL: [ivdon.ru/ru/magazine/archive/n7y2024/9359](http://ivdon.ru/ru/magazine/archive/n7y2024/9359)
10. Aleksandrov N. Je., Ermakov D. N., Aziz N. M. H. A., Kazenkov O. Ju. Computational nanotechnology, 2022, № 2, pp. 11-20. DOI: 10.33693/2313-223X-2022-9-2-11-20.
11. Kuchma M. O., Voronin V. V., Shamilova Ju. A., Amel'chenko Ju. A. Sistemy analiza i obrabotki dannyh, 2022, №3, pp. 7-20.
12. Sanockaja N. A., Loskutov D. A., Romashova K. V. Tehnologii grazhdanskoj bezopasnosti, 2022, № 2, pp. 14-20. DOI: 10.54234/CST.19968493.2022.19.2.72.3.14.
13. DVHub: Uroven' vody v Amure u Habarovska onlajn [DVHub: Water level in Amur near Khabarovsk online]. URL: [dvhab.ru/uroven-amura](http://dvhab.ru/uroven-amura).
14. Hochreiter S., Schmidhuber J. Neural Comput, 1997, N 9 (8), pp. 1735–1780. DOI: 10.1162/neco.1997.9.8.1735.

**Дата поступления: 8.01.2025 Дата публикации: 25.02.2025**

---