

Научная статья

УДК 004.032.26

DOI 10.25205/1818-7900-2023-21-2-39-50

## Применение нейросетевого моделирования в задачах прогнозирования уровня паводка рек

Татьяна Михайловна Шамсутдинова

Башкирский государственный аграрный университет  
Уфа, Россия

tsham@rambler.ru, <https://orcid.org/0000-0003-1809-3615>

### Аннотация

Цель данной статьи – рассмотреть теоретические и практические вопросы разработки нейросетевых моделей для прогнозирования паводка рек (на примере реки Белая в районе г. Уфы), а также реализовать соответствующую нейронную сеть на языке Python. Для построения обучающей выборки были использованы архивные данные метеослужб и сайтов метеонаблюдений за паводковые периоды реки Белая (Агидель) 2018–2022 годов. Были собраны и проанализированы следующие показатели: уровень воды, температура воды, дневная и ночная температура воздуха, осадки, высота снежного покрова, включая сведения о предпаводковом состоянии снежного покрова. Программная реализация нейронной сети выполнялась с использованием библиотеки глубокого обучения PyTorch; кроме этого, использовались модули библиотек Matplotlib и Pandas. Была изучена устойчивость работы данной нейронной сети при изменении следующих параметров: используемых оптимизаторов (Adam, Adamax и Rprop); коэффициента скорости обучения; количества нейронов в скрытом слое; количество эпох обучения. Делается вывод, что разработанная нейронная сеть может использоваться для моделирования уровня паводка при создании краткосрочных прогнозов. Для перехода в перспективе к более долгосрочным прогнозам предполагается в дальнейшем расширить размер факторов в обучающей выборке.

### Ключевые слова

нейронные сети, прогнозирование, паводок, снежный покров, моделирование, PyTorch

### Для цитирования

Шамсутдинова Т. М. Применение нейросетевого моделирования в задачах прогнозирования уровня паводка рек // Вестник НГУ. Серия: Информационные технологии. 2023. Т. 21, № 2. С. 39–50. DOI 10.25205/1818-7900-2023-21-2-39-50

## Application of Neural Network Modeling in Problems of Predicting the Level of River Floods

Tatyana M. Shamsutdinova

Bashkir State Agrarian University  
Ufa, Russia

tsham@rambler.ru, <https://orcid.org/0000-0003-1809-3615>

### Abstract

The purpose of this article is to consider the theoretical and practical issues of developing neural network models for river flood forecasting (in case of the Belaya River near Ufa), as well as to implement the corresponding neural network

© Шамсутдинова Т. М., 2023

in Python. To build a training sample, archival data from meteorological services and meteorological observation sites for the flood periods of the Belaya (Agidel) River in 2018–2022 were used. The following indicators were collected and analyzed: water level, water temperature, day and night air temperature, precipitation, snow depth, including information about the pre-flood condition of the snow cover. The software implementation of the neural network was performed using the PyTorch deep learning library; in addition, modules from the Matplotlib and Pandas libraries were used. The stability of the operation of this neural network was studied when the following parameters were changed: the optimizers used (Adam, Adamax and Rprop); learning rate coefficient; the number of neurons in the hidden layer; number of learning epochs. It is concluded that the developed neural network can be used to model the flood level when creating short-term forecasts. In order to move to longer-term forecasts in the future, it is planned to further expand the size of the factors in the training sample.

#### Keywords

neural networks, forecasting, flood, snow cover, modeling, PyTorch

#### For citation

Shamsutdinova T. M. Application of Neural Network Modeling in Problems of Predicting the Level of River Floods. *Vestnik NSU. Series: Information Technologies*, 2023, vol. 21, no. 2, pp. 39–50. DOI 10.25205/1818-7900-2023-21-2-39-50

## Введение

Ежегодные наводнения в результате весеннего разлива рек наносят колоссальный ущерб экономике страны, приводят к разрушению жилых домов, хозяйственных построек, дорожных покрытий, нарушают агротехнологический цикл сельскохозяйственного производства и т. д. В этих условиях большую актуальность приобретает задача прогнозирования уровня паводка рек, в том числе и с использованием методов нейросетевого моделирования.

Прогнозирование паводка рек является при этом очень сложной многопараметрической задачей, зависящей от большого числа разнообразных факторов природно-климатического характера, включая и техногенное воздействие человека. В частности, в качестве параметров нейросетевых моделей могут выступать следующие характеристики:

- количество выпадающих осадков, уровень почвенной влаги, уровень воды в реке, геометрические характеристики водосбора и водотока, параметры общей синоптической обстановки, атмосферного давления, ветра, а также параметры гидрологии всего русла [1];
- данные гидрометрических и дождемерных станций, вид рельефа, включая уклон и кривизну склона, накопление стока, тип почвы [2];
- данные систем спутникового мониторинга, например, размеры снежного покрова, температура поверхности и воздуха, водная маска поверхности воды и грунтовых вод, солнечное излучение, коэффициент испарения с поверхности [3];
- данные по подъему воды и градиенту гидротермического поля, включая показатель индикатора сезонности [4];
- влажность почвы на объекте в предпрогнозный период, замеры приращения уровня воды в паводковый период [5];
- количество осадков в верхней части водосбора и/или речного стока в верхних точках вдоль основных рек или притоков [6];
- паводкообразующие осадки и показатели предпаводочного увлажнения, зависящего от запаса воды в снежном покрове [7];
- рельеф местности, испарение влаги [8];
- параметры дождевого стока [9];
- предшествующие уровни воды реки в ее верховьях [10];
- сбросы воды на близлежащей ГЭС, состояние ледяного покрова на реке [11] и др.

Можно сказать, что в настоящее время задача применения нейронных сетей для прогнозирования уровня паводка носит научно-исследовательский характер. Существует ряд определенных проблем, связанных с получением требуемой эмпирической информации для обучения нейронных сетей, кроме этого, нет устоявшихся единообразных методик предобработки дан-

ных, выбора архитектуры нейронной сети – количества слоев, нейронов, функций активации, оптимизаторов и т. д. [12].

Цель данной статьи – рассмотреть теоретические и практические вопросы разработки нейросетевых моделей для прогнозирования паводка рек (на примере реки Белая в районе г. Уфы), а также реализовать нейронную сеть на языке Python с использованием библиотеки глубокого обучения PyTorch.

## 1. Материалы и методы

В ходе исследования были проанализированы данные наблюдений за паводковой ситуацией в бассейне реки Белая (Агидель) в районе г. Уфы.

При этом были использованы архивные данные метеослужб и сайтов метеонаблюдений за паводковые периоды реки Белая (Агидель) 2018–2022 годов:

- Архив уровней рек. Федеральное государственное бюджетное учреждение «Башкирское управление по гидрометеорологии и мониторингу окружающей среды». Пункт: г. Уфа. Водный объект: р. Белая. Выход на пойму: 660 см ([www.meteorb.ru/arhiv-urovney-rek/](http://www.meteorb.ru/arhiv-urovney-rek/));
- Gismeteo. Дневник погоды в Уфе ([www.gismeteo.ru/diary/4588/](http://www.gismeteo.ru/diary/4588/));
- World Weather. Погода в Уфе ([www.world-weather.ru/pogoda/russia/ufa/](http://www.world-weather.ru/pogoda/russia/ufa/));
- Расписание погоды. Архив погоды в Деме. Номер метеостанции 28722 (Башкортостан, Уфа) ([www.rp5.ru/Архив\\_погоды\\_в\\_Деме](http://www.rp5.ru/Архив_погоды_в_Деме)).

Были собраны и проанализированы следующие показатели: уровень воды, температура воды, дневная температура воздуха, вечерняя температура воздуха, ночная температура воздуха, осадки, высота снежного покрова.

На рис. 1 представлены графики уровня весеннего паводка р. Белая в районе пункта г. Уфа в 2018–2022 годах. Как видим из графиков, динамика характера распределения локальных экстремумов паводка существенно различается по годам.




Рис. 1. Уровень паводка р. Белая в 2018–2022 годах

Fig. 1. Flood level of the Belaya River in 2018–2022

При этом данные имеют ряд выраженных экстремумов, что делает затруднительным процесс моделирования ряда с целью его дальнейшего прогнозирования. Ввиду этого было проведено частичное сглаживание рядов данных с помощью фильтра Ходрика–Прескотта в программном комплексе Logitom (с дальнейшим экспортом данных в электронные таблицы MS Excel). Описание некоторых особенностей применения фильтра Ходрика–Прескотта к задачам сглаживания нелинейных временных рядов приводится, например, в работе [13].

## 2. Результаты моделирования нейронной сети и ее обучения

Программная реализация нейронной сети выполнялась на языке Python с использованием библиотеки глубокого обучения PyTorch. Кроме этого, использовались модули библиотек Matplotlib и Pandas.

Начальная структура нейронной сети содержала три слоя, число нейронов в скрытом слое – 20, функция активации – Sigmoid, оптимизатор для выполнения шагов градиентного спуска – torch.optim.Adam (алгоритм Адама).

При этом был подготовлен массив данных (более 300 строк), используемый далее для обучения нейронной сети. Структура обучающего массива и его сводные показатели представлены в табл. 1 и 2.

Таблица 1

Сводные показатели по обучающей выборке  
(средние значения по месяцам)

Table 1

Summary Indicators for the Training Sample (Monthly Averages)

| Параметр (источник данных наблюдений)          | 2018 г. |      | 2019 г. |      | 2020 г. |      | 2021 г. |      | 2022 г. |      |
|------------------------------------------------|---------|------|---------|------|---------|------|---------|------|---------|------|
|                                                | апрель  | май  | апрель  | май  | апрель  | май  | апрель  | май  | апрель  | май  |
| Уровень воды, см на 8 часов (meteorb)          | 149     | 199  | 201     | 95   | 373     | 323  | 353     | 38   | 222     | 88   |
| Температура воды, °C (meteorb)                 | 1,6     | 8,6  | 3,8     | 10,5 | 3,8     | 11,1 | 2,4     | 12,1 | 2,6     | 9,5  |
| Дневная температура воздуха, °C (gismeteo)     | 7,9     | 16,0 | 10,7    | 18,3 | 9,3     | 18,9 | 11,9    | 24,6 | 11,6    | 14,6 |
| Вечерняя температура воздуха, °C (gismeteo)    | -0,1    | 7,0  | 0,4     | 8,9  | 3,0     | 7,9  | 10,2    | 23,5 | 10,1    | 13,6 |
| Ночная температура воздуха, °C (world-weather) | 0       | 7    | 0       | 9    | 3       | 8    | 3       | 11   | 4       | 6    |
| Высота снежного покрова, см (gr5)              | 20,6    | –    | 1,0     | –    | 0,4     | –    | 10,3    | –    | 10,3    | –    |

Таблица 2

Осадки, количество дней по месяцам  
(по архивным данным сайта world-weather)

Table 2

Precipitation, Number of Days by Month  
(According to the Archival Data from the World-Weather Website)

| Вид осадков, (количество дней) | 2018 г. |     | 2019 г. |     | 2020 г. |     | 2021 г. |     | 2022 г. |     |
|--------------------------------|---------|-----|---------|-----|---------|-----|---------|-----|---------|-----|
|                                | апрель  | май | апрель  | май | апрель  | май | апрель  | май | апрель  | май |
| без осадков                    | 23      | 26  | 27      | 28  | 22      | 28  | 28      | 29  | 23      | 22  |
| слабый дождь                   | 1       | 3   | 3       | 2   | 1       | 2   | 1       | 1   | 3       | 5   |
| кратковременные осадки         | 5       | 2   | 0       | 1   | 6       | 1   | 0       | 1   | 4       | 4   |
| сильный дождь                  | 1       | 0   | 0       | 0   | 1       | 0   | 1       | 0   | 0       | 0   |

Ввиду большого влияния сформированного снежного покрова на уровень паводка рек было решено добавить в обучающую выборку также сведения о предпаводковом состоянии снежного покрова в первом квартале (январь – март) 2018–2022 годов (см. табл. 3).

Таблица 3

Высота снежного покрова, см  
(по архивным данным <https://rp5.ru>, номер метеостанции 28722)

Table 3

Summary Snow Depth, cm  
(According to the Archival Data <https://rp5.ru>, weather station number 28722)

| Месяц   | Сводные показатели по обучающей выборке | 2018 г. | 2019 г. | 2020 г. | 2021 г. | 2022 г. |
|---------|-----------------------------------------|---------|---------|---------|---------|---------|
| Январь  | среднее                                 | 16,1    | 28,5    | 30,1    | 27,8    | 29,5    |
|         | максимальное                            | 21      | 39      | 41      | 42      | 39      |
| Февраль | среднее                                 | 19,1    | 47,4    | 40,9    | 31,3    | 42,7    |
|         | максимальное                            | 36      | 54      | 48      | 42      | 51      |
| Март    | среднее                                 | 37,6    | 33,4    | 18,7    | 41,7    | 50,1    |
|         | максимальное                            | 56      | 57      | 36      | 47      | 58      |

Как известно, после обучения на основе подготовленной выборки нейронная сеть приобретает возможность проводить расчеты и для данных, не используемых ранее в процессе обучения. Это позволяет использовать нейросетевые модели для задач прогнозирования данных.

На рис. 2 представлен полученный результат визуализации нейросетевой модели прогноза по данным об уровне реки Белая в районе г. Уфа за апрель–май 2022 г., включая продолжение прогнозного ряда на начало июня.




Рис. 2. Результаты нейросетевого моделирования (по данным за 2022 год)

Fig. 2. Results of neural network modeling (according to data for 2022)

Детализация данного прогноза представлена на рис. 3. Как видим на данном рисунке, в начале июня наблюдается спад уровня паводка с достаточно монотонно-гладкой динамикой уменьшения числовых показателей уровня воды.




Рис. 3. Результаты прогноза на 1–3 июня 2022 года

Fig. 3. Forecast results for June 1–3, 2022

Для анализа качества полученных прогнозных значений были рассчитаны среднеквадратичная ошибка MSE (Mean Squared Error) по формуле (1) и средняя абсолютная ошибка в процентах MAPE (Mean Absolute Percentage Error) по формуле (2):

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - p_i)^2, \quad (1)$$

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \frac{|y_i - p_i|}{y_i}, \quad (2)$$

где  $y_i$  – эмпирическое значение,  $p_i$  – прогноз,  $n$  – количество измерений.

В результате расчетов получено значение  $MSE = 4.548$ ,  $MAPE = 1,11\%$  что показывает хорошее качество прогноза в соотношении с размерностью исследуемых данных.

Но надо заметить, что прогнозирование такого рода функций, имеющих большое количество локальных экстремумов, представляет собой сложный процесс и вообще может быть успешно реализовано лишь для некоторых краткосрочных периодов. При увеличении периода прогнозирования (выше трех дней) наблюдалось увеличение показателей MSE и MAPE, из чего можно сделать вывод об эффективности применения данной сети именно для кратковременного прогнозирования.

### 3. Исследование параметров нейронной сети

Также была изучена устойчивость работы данной нейронной сети при изменении следующих параметров:

- используемых оптимизаторов;
- коэффициента скорости обучения  $lr$ ;
- количества нейронов в скрытом слое;
- количество эпох обучения.

Был проведен сравнительный анализ динамики изменения функции потерь при выполнении шагов градиентного спуска для трех различных вариантов:

- `torch.optim.Adam` – алгоритм Адама;
- `torch.optim.Adamax` – алгоритм Адамакс (вариант Адама, основанный на норме бесконечности, *англ.* infinity norm);
- `torch.optim.Rprop` – устойчивый алгоритм обратного распространения.

Коэффициент скорости обучения при этом изменялся от  $lr = 0,001$  до  $lr = 0,1$ ; количество нейронов в скрытом слое варьировалось от 10 до 50.

Результаты экспериментального исследования по изучению динамики улучшения функции потерь (loss) представлены на рис. 4–6.

Как видим из рис. 4 и 5, при параметре скорости обучения  $lr = 0,01$  увеличение числа нейронов скрытого слоя с 10 до 20 значительно увеличивает скорость метода градиентного спуска. Из рис. 6 видим, что увеличение параметра скорости обучения с  $lr = 0,01$  до  $lr = 0,1$  значительно уменьшает количество эпох сходимости оптимизаторов Adamax и Adam.




Рис. 4. График функции потерь в случае использования 20 нейронов в скрытом слое при скорости обучения  $lr = 0,01$

Fig. 4. Graph of the loss function in the case of using 20 neurons in the hidden layer at a learning rate  $lr = 0.01$




Рис. 5. График функции потерь в случае 10 нейронов в скрытом слое при скорости обучения  $lr = 0,01$

Fig. 5. Graph of the loss function in the case of 10 neurons in the hidden layer at the learning rate  $lr = 0.01$




Рис. 6. График функции потерь в случае 10 нейронов в скрытом слое при скорости обучения  $lr = 0,1$

Fig. 6. Graph of the loss function in the case of 10 neurons in the hidden layer at a learning rate  $lr = 0.1$

Для параметра скорости обучения  $lr = 0,1$  было получено, что для данного примера в качестве оптимального количества эпох обучения можно принять 1000 эпох, в ходе которых обеспечивается сходимость метода градиентного спуска для всех трех вариантов оптимизатора – Adam, Adamax и Rprop. При уменьшении скорости обучения до  $lr = 0,01$  оптимизаторам Adam и Adamax в случае 10 нейронов в скрытом слое потребовалось более 3000 эпох обучения.

Также экспериментально было получено, что при уменьшении скорости обучения до  $lr = 0,001$  очень существенно возрастает число эпох, необходимых для сходимости метода градиентного спуска. Уменьшения числа эпох можно при этом добиться с помощью увеличения числа нейронов в скрытом слое. Для данной модели при скорости обучения  $lr = 0,001$  и количестве нейронов в скрытом слое равном 50 для сходимости градиентного спуска методами Adamax и Adam потребовалось около 5000 эпох.

Исходя из результатов численного исследования, можем сделать вывод об удовлетворяющем качестве построенной нейросетевой модели. Для различных вариантов количества нейронов в скрытом слое из диапазона от 10 до 50 удалось подобрать параметры обучения нейронной сети, обеспечивающие ее сходимость за менее чем 5000 эпох.

При этом можно сделать некоторые заключения, касающиеся сравнения оптимизаторов Adam, Adamax и Rprop.

В работе D. P. Kingma и J. Ba [14] отмечается, что метод Adam, относящийся к методам стохастической оптимизации, высоко эффективен в вычислительном отношении, не требователен к памяти, а также устойчив к диагональному изменению масштаба градиентов и хорошо подходит для задач с большим количеством параметров, например, для сверточных нейронных сетей (*англ.* Convolutional neural networks – CNNs). Там же говорится и о методе Adamax как одном из вариантов метода Adam, основанном на норме бесконечности. При этом уточняется, что в Adam правило обновления для отдельных весов заключается в масштабировании их градиентов обратно пропорционально масштабированной евклидовой норме  $L_2$  их индивидуальных текущих и прошлых градиентов. При переходе к норме  $L_p$  в случае  $p \rightarrow \infty$  получаем норму  $L_\infty$ , определяемую как нахождение наибольшего из векторов в нормированном векторном пространстве. В результате применения данной нормы к расчету весовых коэффициентов нейронной сети получается новый устойчивый алгоритм оптимизации, получивший название Adamax.

Говоря о методе Rprop [15], С. Igel и М. Hüsken отмечают, что алгоритм Rprop (*англ.* resilient backpropagation – устойчивое обратное распространение) является одним из эффективных алгоритмов обучения первого порядка для нейронных сетей с произвольной топологией. Особенность обучения первого порядка характеризуется тем, что временная и пространственная сложность масштабируется только линейно в зависимости от количества оптимизируемых параметров. При этом С. Igel и М. Hüsken доказывают высокую эффективность метода для ряда примеров обучения нейронных сетей, в частности, для задач классификации данных и регрессионного анализа.

Что же можно сказать относительно сравнения оптимизаторов Adam, Adamax и Rprop применительно к данной конкретной построенной модели нейросетевого прогнозирования уровня паводка рек? В данном случае можем рассмотреть сравнение работы оптимизаторов с разных позиций: на основе количества эпох, требуемых для сходимости метода; на основе расчета среднеквадратичной ошибки MSE и средней абсолютной ошибки MAPE для полученного прогноза.

Как видим на рис. 4–6, во всех случаях метод Rprop показал более быструю сходимость градиентного спуска. Оптимизаторам же Adam и Adamax понадобилось большее, но сопоставимое между собой число эпох. Можно предположить, что быстрая сходимость метода градиентного спуска в случае применения оптимизатора Rprop обусловлена относительной несложностью топологии сети. Также отметим, что задача прогнозирования по своей концепции имеет некоторую близость к задачам регрессии, если принять во внимание, что алгоритмы

авторегрессионного анализа позволяют строить продолжение временного ряда с учетом его имеющихся предыдущих (ретроспективных) значений. Ввиду этого можно заключить, что полученные на рис. 4–6 результаты соответствуют изложенной в [15] концепции эффективности применения алгоритма Rprop для задач регрессионного анализа данных.

Методы Adam и Adamax ориентированы на объемные данные (в том числе на CNNs, используемые, например, при распознавании образов) и отличаются более точной подстройкой весовых коэффициентов за счет нелинейности применяемых в алгоритме моделей.

Как видим из табл. 4, построенной по исходным параметрам нейронной сети (число нейронов в скрытом слое – 20, функция активации – у оптимизатора Adamax).

Таблица 4

Сравнение прогнозов с фактическим уровнем паводка

Table 4

Comparison of Forecasts with Actual Flood Levels

| Оптимизатор либо факт. уровень | Уровень на 01.06.2022, см | Уровень на 02.06.2022, см | Уровень на 03.06.2022, см | Среднеквадр. ошибка MSE | Средняя абс. ошибка MAPE |
|--------------------------------|---------------------------|---------------------------|---------------------------|-------------------------|--------------------------|
| Adam                           | 181,4900                  | 176,1584                  | 159,3045                  | 4,54849788              | 1,11%                    |
| Adamax                         | 182,0203                  | 174,8007                  | 158,2212                  | 6,37528734              | 1,04%                    |
| Rprop                          | 181,0734                  | 174,3470                  | 158,4074                  | 8,16325711              | 1,33%                    |
| Уровень фактический            | 182                       | 179                       | 157                       | –                       | –                        |

Но можем заметить, что все три варианта оптимизаторов Adam, Adamax и Rprop показали хорошее качество прогноза относительно средней абсолютной ошибки MAPE.

### Выводы

Обобщая вышесказанное, можно сделать вывод, что существует ряд проблем, связанных с разработкой нейросетевых моделей для прогнозирования уровня паводка. Например, нехватка систематизированных данных гидрометрических наблюдений, необходимых для обучения и тестирования модели. Кроме этого, на данный момент недостаточно изучен вопрос выбора оптимальной структуры нейросетевых моделей, включая выбор количества слоев, нейронов, видов функции активации, оптимизаторов и др. Отсутствует единая методика предобработки исходных эмпирических данных, связанная с их сглаживанием и устранением шумов и аномалий. Ввиду этого задача разработки и исследования новых нейросетевых моделей имеет большую востребованность и актуальность.

Разработанная нейронная сеть показала удовлетворяющие характеристики результатов моделирования при создании краткосрочных прогнозов, размер среднеквадратичной ошибки прогнозирования с использованием оптимизатора Adam составил  $MSE = 4,548$  для прогноза на три дня. При увеличении периода прогнозирования (выше трех дней) наблюдалось увеличение показателя MSE, из чего можно сделать вывод об эффективности применения данной сети именно для кратковременного прогнозирования. Для перехода в перспективе к более долгосрочным прогнозам предполагается в дальнейшем расширить размер факторов в обучающей выборке, введя в нее дополнительные природно-климатические и ландшафтные характеристики, например, особенности рельефа местности, влияющие на удержание влаги в почве в районе русла рек и др.

## Список литературы

1. **Афонин Л. А.** Проблемы прогнозирования паводков и наводнений // Наука. Инновации. Технологии. 2014, № 1. С. 145–152.
2. **Jahangir M. H., Reineh S. M. M., Abolghasemi M.** Spatial predication of flood zonation mapping in Kan River Basin, Iran, using artificial neural network algorithm. *Weather and Climate Extremes*, 2019, vol. 25, 100215. DOI: 10.1016/j.wace.2019.100215
3. **Ткаченко П. Н., Вакорин М. В.** Анализ проблемной ситуации использования информационных систем для прогнозирования паводка органами управления МЧС России // Сибирский пожарно-спасательный вестник. 2019, № 4 (15). С. 49–54.
4. **Варшанина Т. П., Митусов Д. В., Плисенко О. А., Стародуб И. В.** Нейросетевая модель прогноза паводков на малых реках Адыгеи // Известия Российской академии наук. Серия: Географическая. 2007, № 6. С. 87–93.
5. **Великанова Л. И.** Прогноз уровня воды при прохождении паводков на горных реках с применением нейросетевых технологий и прогноза метеослужбы // Проблемы автоматизации и управления. 2013, № 1 (24). С. 66–73.
6. **Hag-Elsafi S.** Artificial Neural Networks (ANNs) for flood forecasting at Dongola Station in the River Nile, Sudan, Alexandria. *Engineering Journal*, 2014, vol. 53, issue 3, p. 655-662. DOI: 10.1016/j.aej.2014.06.010
7. **Лариошкин В. В.** Методика прогноза дождевых паводков в бассейне верхнего Амура (на примере р. Онон) // Известия Томского политехнического университета. Инжиниринг георесурсов. 2016. Т. 327, № 11. С. 105–115.
8. **Гребнев Я. В., Яровой А. В.** Мониторинг и прогнозирование паводков на территории Красноярского края использованием нейросетевых алгоритмов // Сибирский пожарно-спасательный вестник. 2018, № 3 (10). С. 13–16.
9. **Napolitano G., See L., Calvo B., Savi F., Heppenstall A.** A conceptual and neural network model for real-time flood forecasting of the Tiber River in Rome. *Physics and Chemistry of the Earth, Parts A/B/C*, 2010, vol. 35, issues 3–5, p. 187-194. DOI: 10.1016/j.pce.2009.12.004
10. **Castangia M., Grajales L.M.M., Aliberti A., Rossi C., Macii A., Macii E., Patti E.** Transformer neural networks for interpretable flood forecasting. *Environmental Modelling & Software*, 2023, vol. 160, 105581. DOI: 10.1016/j.envsoft.2022.105581
11. **Буянов Д. И., Федотов Р. С., Ткаченко П. Н.** Прогнозирование подъема уровня воды на реке Обь в Томской области на основе регрессионного анализа // Научные и образовательные проблемы гражданской защиты. 2015, № 2 (25). С. 112–118.
12. **Шамсутдинова Т. М.** Проблемы нейросетевого и регрессионного прогнозирования уровня паводка рек // Сибирский пожарно-спасательный вестник. 2021, № 2 (21). С. 99–105. DOI: 10.34987/vestnik.sibpsa.2021.79.13.017
13. **Li Z., Tanaka G.** HP-ESN: Echo State Networks Combined with Hodrick-Prescott Filter for Nonlinear Time-Series Prediction. 2020 International Joint Conference on Neural Networks (IJCNN), Glasgow, UK, 2020, p. 1-9. DOI: 10.1109/IJCNN48605.2020.9206771
14. **Kingma D. P., Ba J.** Adam: A Method for Stochastic Optimization. 3rd International Conference on Learning Representations (ICLR), San Diego, 2015. DOI: 10.48550/arXiv.1412.6980
15. **Igel C., Hüsken M.** Empirical Evaluation of the Improved Rprop Learning Algorithms. *Neurocomputing*, 2003, vol. 50, p. 105-123. DOI: 10.1016/S0925-2312(01)00700-7

## References

1. **Afonin L. A.** Problems of forecasting floods and flooding. *Science // Innovation. Technologies*. 2014. No. 1. Pp. 145–152. (in Russ.)

2. **Jahangir M. H., Reineh S. M. M., Abolghasemi M.** Spatial predication of flood zonation mapping in Kan River Basin, Iran, using artificial neural network algorithm // *Weather and Climate Extremes*. 2019. Vol. 25. 100215. DOI 10.1016/j.wace.2019.100215
3. **Tkachenko P. N., Vakorin M. V.** Analysis of the problem situation in case of using information flood forecasting systems by units of EMERCOM of Russia // *Siberian Fire and Rescue Bulletin*. 2019. No. 4(15). Pp. 49–54. (in Russ.)
4. **Varshanina T. P., Matusov D. V., Plisenko O. A., Starodub I. V.** Neuro-Network System of the Flood Forecast on Adygei Small Rivers // *Izvestiya Rossiiskoi Akademii Nauk. Seriya Geograficheskaya*. 2007. No. 6. Pp. 87–93. (in Russ.)
5. **Velikanova L. I.** Forecasting the Water Level at Forwarding Flood in The Mountain Streams Using Neural Network Technology and Forecast of Meteorological Service. *Automation and Control Problems*. 2013. No. 1(24). Pp. 66–73. (in Russ.)
6. **Hag-Elsafi S.** Artificial Neural Networks (ANNs) for flood forecasting at Dongola Station in the River Nile, Sudan, Alexandria // *Engineering Journal*. 2014. Vol. 53, iss. 3. Pp. 655–662. DOI 10.1016/j.aej.2014.06.010
7. **Larioshkin V. V.** Technique of Forecasting Rain Flood in the Upper Amur Basin (by the Example of the Onon River) // *Bulletin of the Tomsk Polytechnic University. Geo Assets Engineering*. 2016. Vol. 327. No. 11. Pp. 105–115. (in Russ.)
8. **Grebnev Y. V., Yarovoy A. V.** Control and prediction of floods on the territory of the Krasnoyarsk kray through the use of neural network algorithms // *Siberian Fire and Rescue Bulletin*. 2018. No. 3(10). Pp. 13–16. (in Russ.)
9. **Napolitano G., See L., Calvo B., Savi F., Heppenstall A.** A conceptual and neural network model for real-time flood forecasting of the Tiber River in Rome // *Physics and Chemistry of the Earth, Parts A/B/C*. 2010. Vol. 35. Iss. 3–5. Pp. 187–194. DOI 10.1016/j.pce.2009.12.004
10. **Castangia M., Grajales L. M. M., Aliberti A., Rossi C., Macii A., Macii E., Patti E.** Transformer neural networks for interpretable flood forecasting // *Environmental Modelling & Software*. 2023. Vol. 160. 105581. DOI 10.1016/j.envsoft.2022.105581
11. **Buyanov D. I., Fedotov R. S., Tkachenko P. N.** Prediction of the Ob's Water Level Rise in Tomsk Region Using Regression Analysis // *Scientific and educational problems of civil protection*. 2015. No. 2(25). Pp. 112–118. (in Russ.)
12. **Shamsutdinova T. M.** Problems of neural network and regression forecasting the river flood level // *Siberian Fire and Rescue Bulletin*. 2021. No. 2(21). Pp. 99–105. (in Russ.) DOI 10.34987/vestnik.sibpsa.2021.79.13.017
13. **Li Z., Tanaka G.** HP-ESN: Echo State Networks Combined with Hodrick-Prescott Filter for Nonlinear Time-Series Prediction // *2020 International Joint Conference on Neural Networks (IJCNN)*, Glasgow, UK, 2020. Pp. 1–9. DOI doi.org/10.1109/IJCNN48605.2020.9206771
14. **Kingma D. P., Ba J.** Adam: A Method for Stochastic Optimization // *3rd International Conference on Learning Representations (ICLR)*, San Diego, 2015. DOI 10.48550/arXiv.1412.6980
15. **Igel C., Hüsken M.** Empirical Evaluation of the Improved Rprop Learning Algorithms // *Neurocomputing*. 2003. Vol. 50. Pp. 105–123. DOI 10.1016/S0925-2312(01)00700-7

### Информация об авторе

**Шамсутдинова Татьяна Михайловна**, кандидат физико-математических наук, доцент кафедры цифровых технологий и прикладной информатики Башкирского государственного аграрного университета

**Information about the Author**

**Tatyana M. Shamsutdinova**, Candidate of Sciences (Physics and Mathematics), Docent of the Department of Digital Technologies and Applied Informatics, Bashkir State Agrarian University

*Статья поступила в редакцию 04.04.2023;  
одобрена после рецензирования 07.07.2023; принята к публикации 07.07.2023*

*The article was submitted 04.04.2023;  
approved after reviewing 07.07.2023; accepted for publication 07.07.2023*