



Научная статья  
УДК 551.583  
<https://doi.org/10.37493/2308-4758.2025.1.2>

## РЕАЛИЗАЦИЯ НЕЙРОСЕТЕВОЙ МОДЕЛИ В СРЕДЕ STATISTICA 12 ДЛЯ ПРОГНОЗА ЧАСТОТЫ СХОДА СЕЛЕЙ

Борис Азреталиевич Ашабоков<sup>1,2</sup>,  
Алла Амарбиевна Ташилова<sup>3\*</sup>,  
Лара Асировна Кешева<sup>4</sup>,  
Наталья Вячеславовна Теунова<sup>5</sup>

<sup>1,3,4,5</sup> Высочгорный геофизический институт (д. 2, пр. Ленина, 360001, Нальчик, Российская Федерация)

<sup>2</sup> Институт информатики и проблем регионального управления КБНЦ РАН (д. 37, ул. Инессы Арманд, Нальчик, 360017, Российская Федерация)

<sup>1,2</sup> [ashabokov.boris@mail.ru](mailto:ashabokov.boris@mail.ru); <https://orcid.org/0000-0002-2889-0864>

<sup>3</sup> [tashilovaa@mail.ru](mailto:tashilovaa@mail.ru); <https://orcid.org/0000-0002-2368-6047>

<sup>4</sup> [kesheva.lara@yandex.ru](mailto:kesheva.lara@yandex.ru); <https://orcid.org/0000-0002-5132-1563>

<sup>5</sup> [nata0770@yandex.ru](mailto:nata0770@yandex.ru); <https://orcid.org/0000-0002-1135-3587>

\* Автор, ответственный за переписку

### Аннотация.

В статье изложены некоторые принципы работы искусственной нейросети, приводится пример реализации нейросетевой модели с помощью подбора ее наилучшей архитектуры средствами программного пакета Statistica 12. Рассматривается метод нейросетевого прогнозирования ряда количества сходов селевых потоков на основе нелинейных связей с рядами осадков и температур. Для решения поставленной задачи в пакете Statistica 12 был использован блок Data Mining (интеллектуальный анализ данных) – Neural Networks (нейронные сети). В качестве нейросетевого метода был выбран многослойный перцептрон MLP (Multilayer perceptron), в качестве функции активации – гиперболический тангенс (tanh). На основе алгоритмов глубокого обучения была разработана математическая модель MPL 2-50-1, способная обучаться на используемых данных (осадки, температура, количество селей за период 1953–2015 гг.) и осуществлять прогнозирование количества схода селей по введенным в модель метеопараметрам (осадки, температура). Получено, что при осредненных значениях осадков с величиной более 110 мм в период с мая по сентябрь с 2016 по 2034 г. прогнозируется количество сходов селей от 10 до 13, что выше среднего их значения  $n = 8$  за период с фактическими исходными данными 1953–2015 гг.

Тенденции изменения количества селей в Терскольском ущелье в теплый сезон с 1953 по 2015 гг. (период с фактическими данными) и с 2016 по 2034 гг. (период с прогнозными данными) определены с помощью полиномиального и линейного трендов. Из уравнения линейного тренда следует, что в среднем за весь период, включая прогнозный, количество схода селей имеет тенденцию слабого роста на 0,3/10лет. Полиномиальный тренд демонстрирует рост и снижение количества селей на разных временных интервалах. На интервале прогнозирования 2016–2034 гг. снижение количества селей демонстрируют как полиномиальный тренд, так и линейный.

**Ключевые слова:** нейронные сети, многослойный перцептрон MLP, функция активации, гиперболический тангенс, прогноз, количество сходов селей, сумма осадков, средние температуры

**Для цитирования:** Ашабоков Б. А., Ташилова А. А., Кешева Л. А., Теунова Н. В. Реализация нейросетевой модели в среде Statistica 12 для прогноза частоты схода селей // Наука. Инновации. Технологии. 2025. № 1. С. 37-64. <https://doi.org/10.37493/2308-4758.2025.1.2>

**Конфликт интересов:** авторы заявляют об отсутствии конфликта интересов.

Статья поступила в редакцию 26.01.2025;  
одобрена после рецензирования 11.03.2025;  
принята к публикации 21.03.2025.

**1.6.18. Atmospheric and Climate Sciences  
(Physical and Mathematical Sciences)**  
Research article

**Implementation of a neural network model  
in the Statistica 12 for mudflow  
frequency forecasting**

**Boris A. Ashabokov<sup>1,2</sup>,  
Alla A. Tashilova<sup>3\*</sup>,  
Lara A. Kesheva<sup>4</sup>,  
Nataliya V. Teunova<sup>5</sup>**

<sup>1,3,4,5</sup> High-Mountain Geophysical Institute (2, Lenin Ave., Nalchik, 360001, Russian Federation)

<sup>2</sup> Institute of Informatics and Regional Management Problems of the Kabardino-Balkarian Scientific Center of the Russian Academy of Sciences (37, Inessa Armand St., Nalchik, 360017, Russian Federation)

<sup>1,2</sup> [ashabokov.boris@mail.ru](mailto:ashabokov.boris@mail.ru); <https://orcid.org/0000-0002-2889-0864>  
[tashilovaaa@mail.ru](mailto:tashilovaaa@mail.ru); <https://orcid.org/0000-0002-2368-6047>

<sup>4</sup> [kesheva.lara@yandex.ru](mailto:kesheva.lara@yandex.ru); <https://orcid.org/0000-0002-5132-1563>

<sup>5</sup> [nata0770@yandex.ru](mailto:nata0770@yandex.ru); <https://orcid.org/0000-0002-1135-3587>

\* Corresponding author

**Abstract.**

The article describes some principles of operation of an artificial neural network. It provides an example of implementing a neural network model by selecting its best architecture using the Statistica 12 software package. The article considers a method for neural network forecasting of a series of mudflow events based on nonlinear relationships with precipitation and temperature series. To solve the problem, the Data Mining (intelligent data analysis) block – Neural Networks was used in the Statistica 12 package. A multilayer perceptron (MLP) was chosen as a neural network method, and a hyperbolic tangent (tanh) was used as an activation function. Based on deep learning algorithms, a mathematical model MPL 2-50-1 was developed, which is capable of learning on the used data (precipitation, temperature, number of mudflows for the period 1953-2015) and forecasting the number of mudflows based on the meteorological parameters (precipitation, temperature) entered into the model. It was found that with average precipitation values of more than 110 mm in the period from May to September from 2016 to 2034, the number of mudflows is predicted to be from 10 to 13, which is higher than their average value of  $n = 8$  for the period with actual initial data from 1953 to 2015. Trends in the number of mudflows in the Terskol Gorge in the warm season from 1953 to 2015 (the period with actual data) and from 2016 to 2034 (the period with predicted data) were determined using polynomial and linear trends. It follows from the linear trend equation that, on average, over the entire period, including the predicted one, the number of mudflows tends to grow slightly by 0.3/10 years. The polynomial trend demonstrates an increase and decrease in the number of mudflows at different time intervals. In the forecast interval of 2016-2034, the decrease in the number of mudflows demonstrates both a polynomial trend and a linear trend.

**Keywords:**

neural networks, multilayer perceptron MLP, activation function, hyperbolic tangent, forecast, number of mudflows, precipitation amount, average temperatures

**For citation:**

Ashabokov BA, Tashilova AA, Kesheva LA, Teunova NV. implementation of a neural network model in the Statistica 12 for mudflow frequency forecasting. *Science. Innovations. Technologies.* 2025;(1):37-64. (In Russ.). <https://doi.org/10.37493/2308-4758.2025.1.2>

**Conflict of interest:**

the authors declare no conflicts of interests.

The article was submitted 26.01.2025;  
approved after reviewing 11.03.2025;  
accepted for publication 21.03.2025.

## **Введение**

За последние десятилетия для изучения и прогнозирования опасных природных явлений широко используются возможности искусственных нейронных сетей [1, 2]. Искусственные нейронные сети – мощный метод моделирования, позволяющий воспроизводить чрезвычайно сложные зависимости, в первую очередь – нелинейные, что особенно важно, поскольку научное исследование чаще всего заключается в выявлении скрытых нелинейных закономерностей в наборах данных. В природе многие реальные процессы не могут быть адекватно описаны с помощью традиционных статистических моделей, поскольку имеют либо хаотическую, либо квазипериодическую, либо смешанную основу [3–6]. Поэтому в настоящее время наряду с методами традиционной статистики активно используются возможности искусственного интеллекта, реализованного в нейронных сетях.

Искусственные нейронные сети успешно применяются там, где нужно решать задачи прогнозирования, классификации или автоматизации. Это обусловлено несколькими причинами. Они просты в использовании, учатся на примерах. Пользователь нейронной сети подбирает представительные данные, а затем запускает алгоритм обучения, который автоматически воспринимает структуру данных.

В данной статье будут представлены результаты прогнозирования количества селей с применением метода обучения искусственных нейронных сетей. В качестве исходных данных при разработке регрессионных моделей прогнозирования использованы данные наблюдений средней температуры и сумм осадков метеостанции Терскол, а также данные о сходе селей в теплый сезон (май–сентябрь) 1953–2015 гг. [7, 8].

Метод прогноза количества селей основан на решении задачи аппроксимации функций по набору точек (регрессия) с помощью обучения искусственных нейронных сетей программного пакета Statistica 12, в котором реализован алгоритм подбора наилучшей архитектуры нейронной сети [9–12].

### Материалы и методы исследований

В работе предпринята попытка решения задачи прогнозирования количества схода селей в теплый сезон на основе автоматизированных нейронных сетей из пакета Statistica 12. В блоке *Интеллектуальный анализ данных* (Data Mining) был выбран *Нейросетевой метод* (Neural Networks) анализа и прогноза. Из возможных задач, которые решает нейросеть (регрессия, классификация, кластерный анализ и аппроксимация) для решения нашей задачи аппроксимации функции по набору точек, были выбраны *Временные ряды* (регрессия) – Timeseries (regression) (рис. 1, скриншот 1).

Из трех стратегий построения моделей (автоматизированный сетевой поиск (ANS), пользовательская нейросеть (CNN) и метод многократных подвыборок [Subsampling]) – была использована 3-я стратегия для создания модели – это *метод многократных подвыборок* (рис. 1, скриншот 2).

В окошке *Переменные* (Variables) отметили непрерывную целевую переменную – количество селей (4) и две непрерывные входные переменные – температура (2) и осадки (3) (рис. 1, скриншот 3).

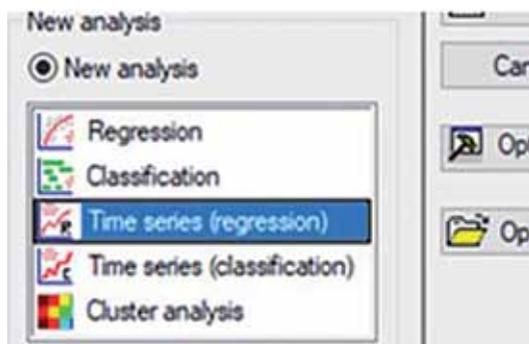
В окне *Создание подвыборок* (Subsampling) установили размеры подвыборок (%): обучающая (Train subsampling) – 70 %, контрольная (Test subsampling) – 15 %, тестовая (Validation subsampling) – 15 %, (рис. 1, скриншот 4).

В этой же вкладке в окне *Количество сетей* (Number of subsamples) отметили 10 сетей, которые будут обучаться (рис. 1, скриншот 4).

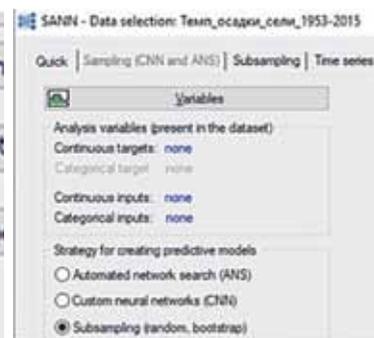
Из двух возможных алгоритмов – радиальной базисной функции (Radial Basic Function, RBF) и многослойного перцептрона (Multilayer perceptron, MLP) был выбран алгоритм многослойного перцептрона MLP, который является наиболее широко используемым алгоритмом для расчета оптимального веса (рис. 2а).

Для определения архитектуры сети необходимо выбрать такие параметры, как: 1) число слоев сети (выбрали  $n = 10$ ); 2) число нейронов в каждом слое; 3) используемые функции активации (рис. 2).

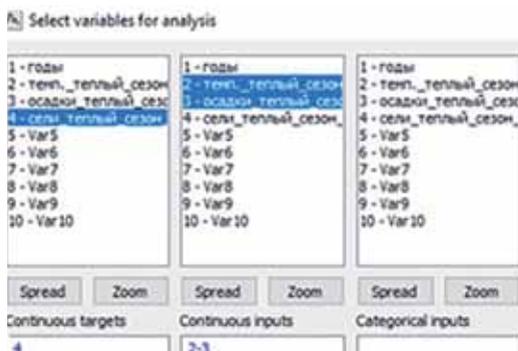
1



2



3



4

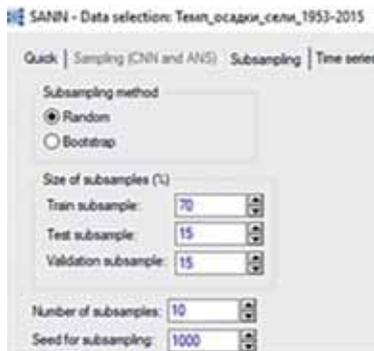


Рис. 1.

**Последовательность команд для начала работы с нейронными сетями в Statistica 12 (скриншоты).**

Fig. 1. Sequence of commands for starting work with neural networks in Statistica 12 (screenshots).

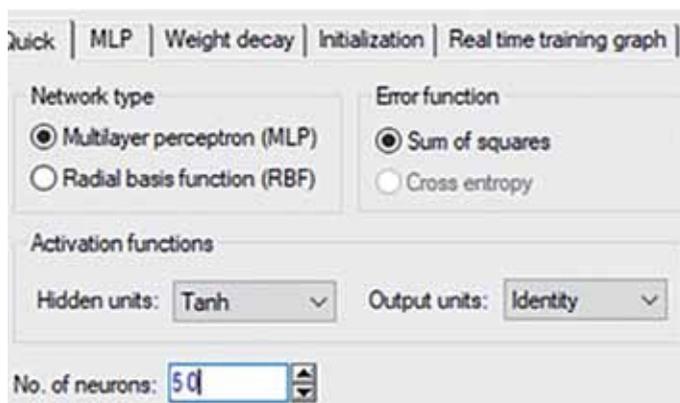
Источник:

составлено авторами.

Source:

compiled by the authors.

a



б

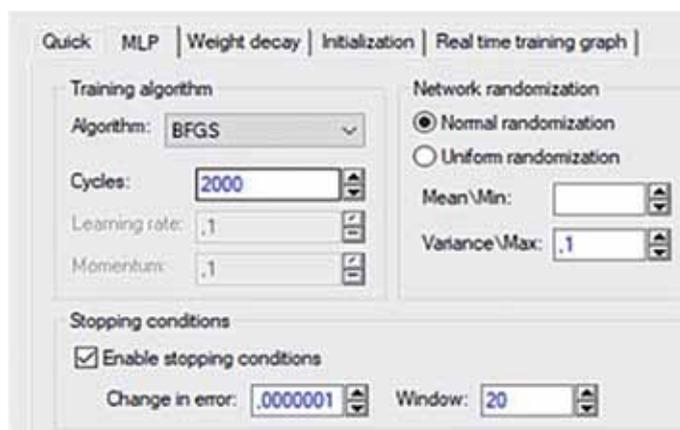


Рис. 2.

Последовательность команд для выбора типа нейросети, функции активации и архитектуры нейросети (скриншоты).

Fig. 2. Sequence of commands for selecting the type of neural network, activation function and neural network architecture (screenshots).

Источник:

составлено авторами.

Source:

compiled by the authors.

### Результаты исследований и их обсуждение

Число нейронов входного слоя определяется числом и видом независимых переменных в модели. Архитектура выходного слоя нейронной сети также диктуется структурой задачи. Для каждой зависимой количественной переменной создается по одному выходному нейрону. К сожалению, до настоящего времени не выработано методик для определения числа скрытых слоев и числа нейронов в них. Имеются лишь оценки, позволяющие оценить соответствие размеров нейронной сети размеру обучающей выборки. На практике число скрытых слоев и нейронов в них определяют экспериментальным путем, анализируя качество аппроксимации, обеспечиваемое сетями разного размера. Интеллектуальные возможности нейросети зависят от количества нейронов и от количества связей между ними.

Выбор функции активации, то есть точной математической функции, выполняющей роль пороговой функции, имеет решающее значение при построении модели нейронной сети, поскольку она напрямую связана с производительностью модели. Наиболее распространенными функциями активации являются сигмоид (1) и гиперболический тангенс (2) [9]:

$$f(x) = \frac{1}{1 + e^{-x}}, \quad (1)$$

$$f(x) = \tanh(x). \quad (2)$$

Эти функции известны как функции сжатия, поскольку они сжимают входные данные ( $x$ ) из интервала  $(-\infty; \infty)$  между  $f(x) = 0$  и  $f(x) = 1$  (сигмоид) и между  $f(x) = -1$  и  $f(x) = 1$  (гиперболический тангенс). В качестве функции активации нами был выбран гиперболический тангенс ( $\tanh$ ).

После многократного перебора количества скрытых нейронов остановимся на  $N = 50$  (No Of neuron) в скрытом слое сети (рис. 2а).

Выбираем алгоритм обратного обучения-BFGS (градиентный метод второго порядка с двойной точностью), при этом увеличиваем циклы (итерации) или эпохи до 2000 (рис. 2б).

Многослойный персептрон представляет иерархическую сетевую структуру со связанными между собой узлами сети (нейронами), объединенными в несколько слоев. Особенностью многослойного персептрона является наличие более чем одного обучаемого слоя (как правило, два или три). В данной сети один алгоритм обратного распространения ошибки обучает все слои.

Нейрону  $j$  в скрытом слое присваивается значение  $y_j$  [12]:

$$y_j = \tanh \sum_i^N (x_{ij} x_i + c_j), \quad (3)$$

где  $N$  – количество скрытых нейронов,  
 $w_{ij}$  и  $c_j$  – параметры взвешивания и смещения, соответственно,  
 а  $x_i$  – данные прогноза, нормализованные на четырехкратное SD (стандартное отклонение) наблюдения  $\sigma$  в период обучения из входного слоя, поскольку диапазон входных данных составляет от  $-1,0$  до  $1,0$ .

Этот выход из  $j$ -го нейрона ( $y_j$ ) вводится в выходной слой следующим образом [12]:

$$Z = \sum_j^N (\tilde{w}_j y_j + \tilde{c}), \quad (4)$$

где  $H$  – число выходных нейронов,  
 а  $\tilde{w}_j$  и  $\tilde{c}$  – вес и смещение от скрытого слоя к выходному слою соответственно.

Процесс обучения нейронной сети – это процесс подбора весовых коэффициентов связей  $w_i$  таким образом, чтобы сеть корректно решала поставленную задачу.

Результаты вычисления, выполненного нейронной сетью, определяются ее параметрами – весами связей между нейронами  $\tilde{w}_j$  и смещениями  $\tilde{c}$ . Этот процесс повторяется для минимизации оценочной функции,  $J$  [12]:

$$J = \sqrt{\frac{1}{T} \sum_{t=1}^T (Z_t - O_t)^2}, \quad (5)$$

где  $O_t$  – наблюдение на шаге  $t$ ,  
 а  $T$  – период обучения.

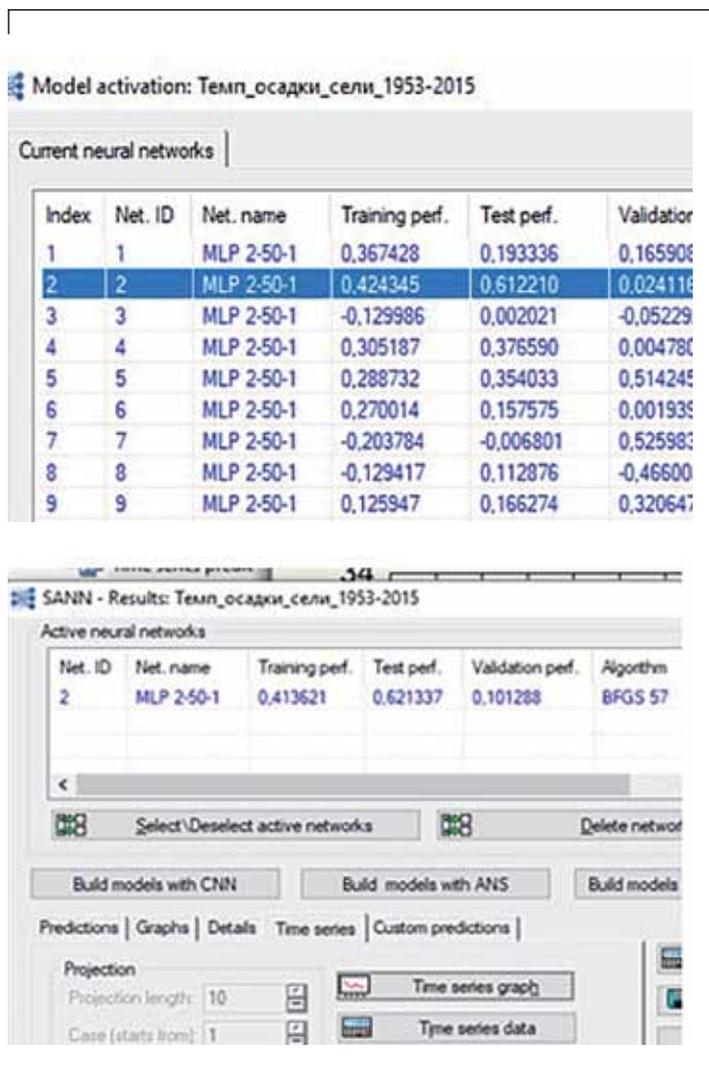
На этапе обучения обрабатываемые данные перемешиваются и, как было отмечено выше, 70 % используют для обучения, 15 % – для тестирования и 15 % – для проверки. После обучения сети (train) открывается окошко с 10 обученными нейросетями (рис. 3а). Отбирается одна нейронная сеть из 10 обученных сетей по максимальному коэффициенту детерминации в столбцах *обучение, тестирование, валидация* (training, test, validation) с наименьшей ошибкой. Это модель № 2, искусственная нейронная сеть с рабочим названием MLP 2-50-1 (рис. 3б), далее работаем с ней.

Для визуализации результатов модели MLP 2-50-1 запускаем команду *Графики временных рядов* (Time series graph). На рисунке 4 можно увидеть график модельного ряда количества селей теплого сезона за 1953-2015 гг., созданный искусственной нейронной сетью MLP 2-50-1 (красная линия), и визуально оценить качество модели, сравнив его с фактическими данными (график с синей линией).

Далее проведем анализ адекватности модели исходным данным. Анализ остатков (разности между наблюдаемыми и предсказанными значениями) является одним из способов проверки качества модели или степени ее адекватности данным.

Предполагается, что модель адекватна, если выполняются 2 требования: 1) остатки независимы; 2) остатки распределены по нормальному закону.

Если остатки представляют собой временной ряд случайных независимых величин, распределенных по нормальному закону, то это может служить обоснованием пригодности уравнения для прогноза. Из рисунка 5 видно, что гистограмма остатков близка к гауссовой кривой распределения, что подтверждает адекватность модели. На нормализованном графике остатки должны вести себя достаточно хаотично, не должно быть резких выбросов, закономерностей в чередовании знаков (рис. 5б). На рисунке 5б представлены прогнозы количества сходов селей (синие кружочки), сделанные нейронной сетью, они в целом сосредоточены вокруг нормализованной прямой (идеальное совпадение с прямой указывало бы на относительную ошибку, равную 0, и, следовательно, идеальное предсказание). В целом, оба графика характеризуют распределение остатков по нормальному закону, что может служить обоснованием пригодности модели для прогноза.



**Рис. 3. Результаты процесса обучения нейросетей (скриншоты).**  
 Fig. 3. Results of the neural network training process (screenshots).  
 Источник: составлено авторами.  
 Source: compiled by the authors.

Для вычисления относительной ошибки (MAPE) модели по формуле (6), воспользуемся данными таблицы 1 – фактическими  $V1$ , модельными  $V2$  и значениями абсолютной ошибки  $V3$  ( $V3 = V2 - V1$ ):

$$MAPE = (abs(V3)/(V1))100 \% \quad (6)$$

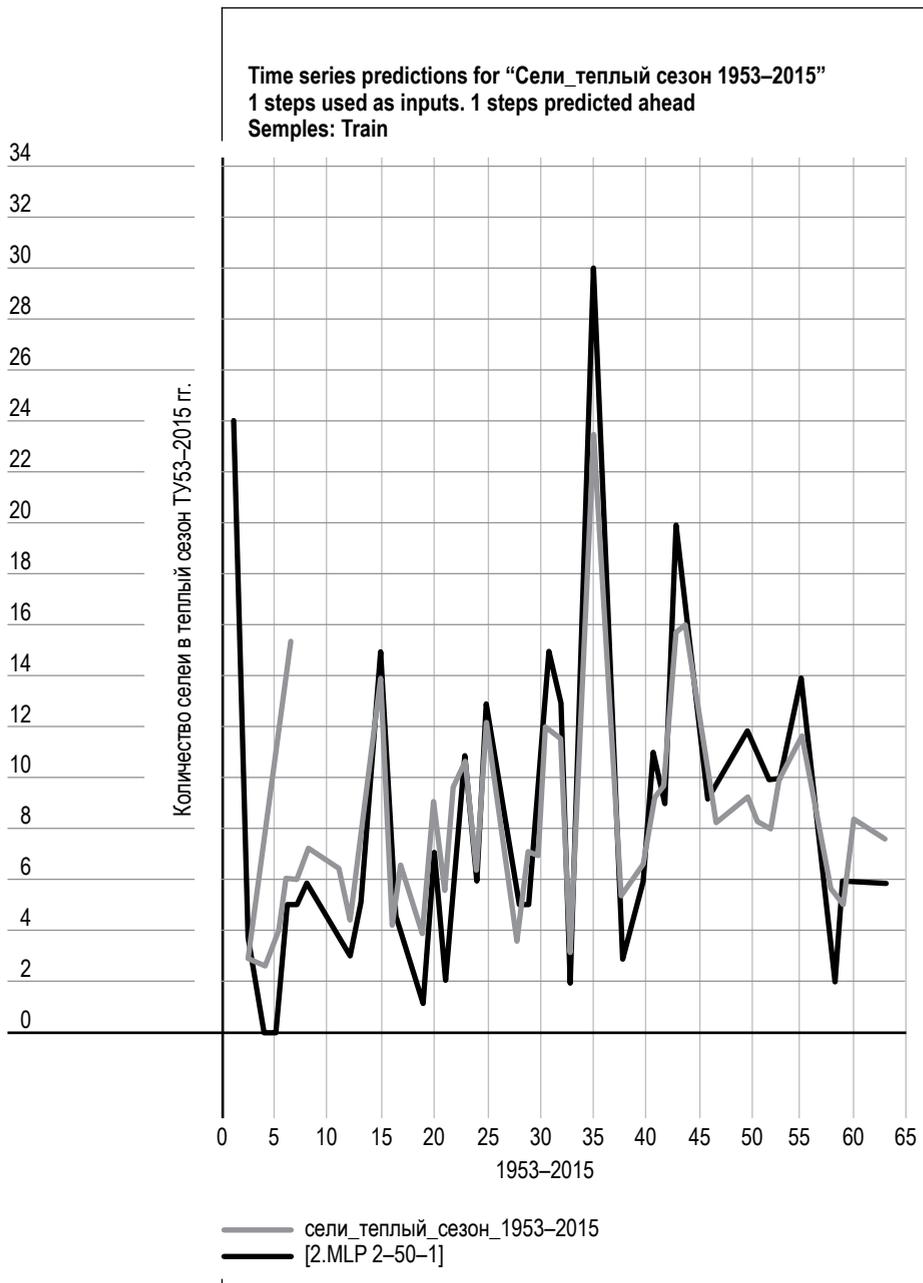


Рис. 4.

Графики фактического ряда количества селей в теплый сезон (синий) и модельного MLP 2-50-1 (нейросетевая модель).

Fig. 4. Graphs of the actual series of mudflows in the warm season (blue) and the model MLP 2-50-1 (neural network model).

Источник:

составлено авторами.

Source:

compiled by the authors.

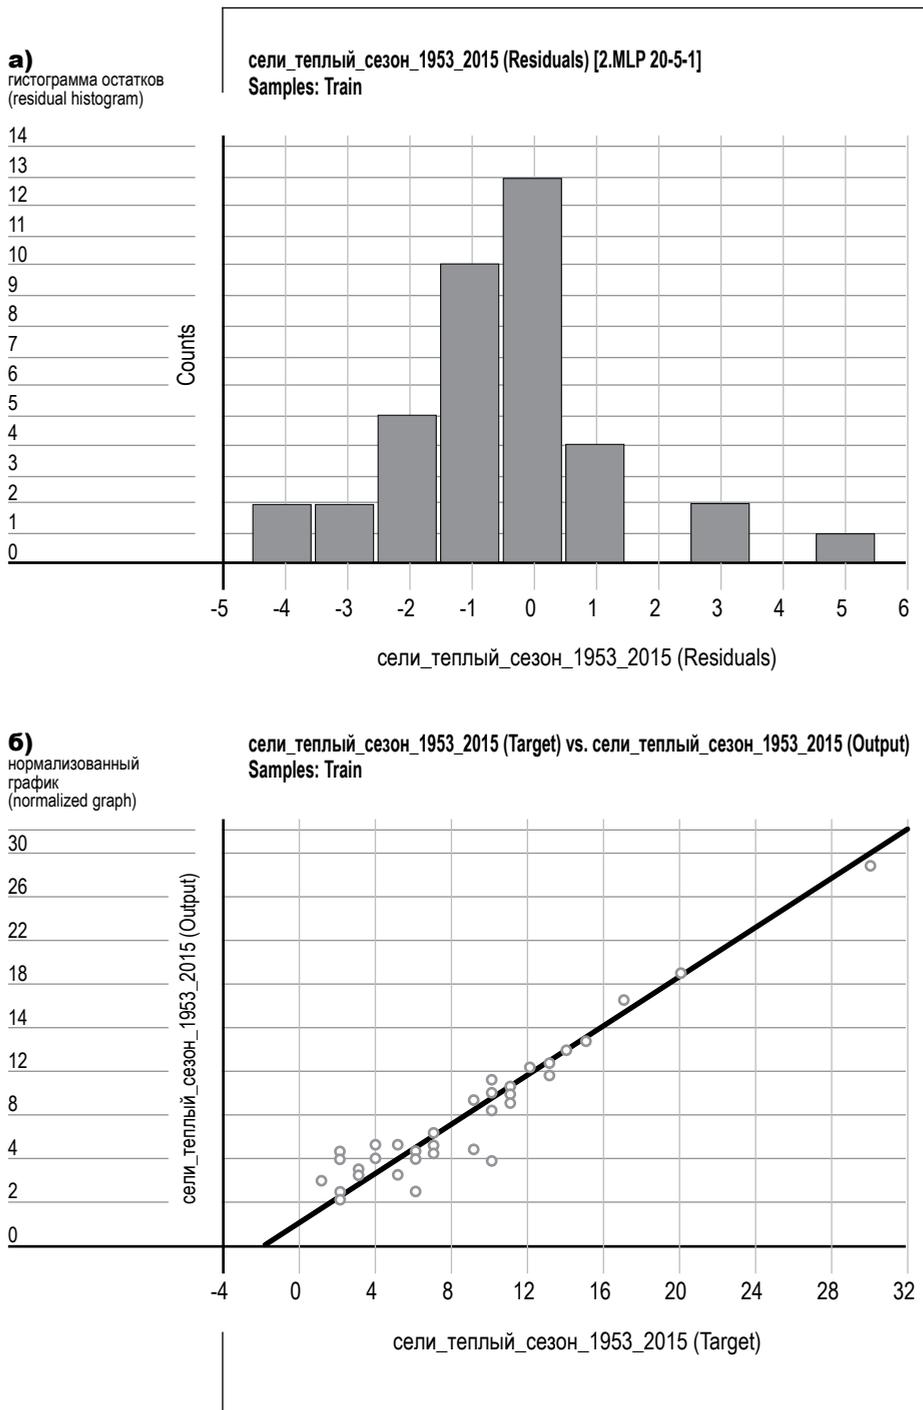


Рис. 5.

**Проверка модели на адекватность.**

Fig. 5. Checking the model. For adequacy.

Источник: составлено авторами. Source: compiled by the authors.

Таблица 1. ДАННЫЕ ДЛЯ РАСЧЕТА ОТНОСИТЕЛЬНОЙ ОШИБКИ (MAPE)  
Table 1. Data for calculating the relative error (MAPE)

Таблица прогнозов для ряда «Количество селей\_1953-2015»  
Сеть: 2.MLP 2-50-1

Количество селей, V1 (target), фактические	Количество селей (MLP 2-50-1), V2 (output), модельные	Абсолютная ошибка V3 (Abs. Res.)	abs (V3)	Относительная ошибка MAPE, %
24	—	—	—	—
4	3,1	-0,952	0,952	23,8
1	2,7	1,734	1,734	173,4
1	3,8	2,767	2,767	276,7
5	6,1	1,134	1,134	22,7
5	6,1	1,091	1,091	21,8
6	7,4	1,357	1,357	22,6
4	6,6	2,557	2,557	63,9
3	5,6	2,546	2,546	84,9
5	7,2	2,210	2,210	44,2
10	12,1	2,077	2,077	20,8
15	14	-1,052	1,052	7
5	4,2	-0,840	0,840	16,8
4	6,8	2,823	2,823	70,6
1	3,8	2,753	2,753	275,3
7	9,1	2,078	2,078	29,7
2	5,4	3,395	3,395	169,7
7	9,7	2,740	2,740	39,1
11	10,7	-0,307	0,307	2,8
6	7	0,994	0,994	16,6
13	11,8	-1,266	1,266	9,7
5	3,6	-1,374	1,374	27,5
5	7,3	2,275	2,275	45,5
9	7	-2,001	2,001	22,2
15	12,	-2,817	2,817	18,8

Таблица прогнозов для ряда «Количество селей\_1953-2015»  
Сеть: 2.MLP 2-50-1

Количество селей, V1 (target), фактические	Количество селей (MLP 2-50-1), V2 (output), модельные	Абсолютная ошибка V3 (Abs. Res.)	abs (V3)	Относительная ошибка MAPE, %
13	11,5	-1,516	1,516	11,7
2	4,2	2,189	2,189	109,4
30	23,5	-6,469	6,469	21,6
11	11,6	0,623	0,623	5,7
3	5,4	2,427	2,427	80,9
6	6,7	0,709	0,709	11,8
11	9,1	-1,872	1,872	17
9	10,173	1,173	1,173	13
20	17,7	-2,311	2,311	11,6
17	16,1	-0,865	0,865	5,1
9	10,2	1,187	1,187	13,2
10	8,3	-1,730	1,730	17,3
12	9,4	-2,617	2,617	21,8
11	8,4	-2,611	2,611	23,7
10	8	-2,030	2,030	20,3
10	10,2	0,173	0,173	1,7
14	11,7	-2,305	2,305	16,5
2	5,6	3,652	3,652	182,6
6	4,9	-1,073	1,073	17,9
6	8,4	2,370	2,370	39,5
6	7,7	1,654	1,654	27,6
				Осредненное значение MAPE = 48,4%

Источник: составлено авторами.  
Source: compiled by the authors.

Точность модели составила 48,4%, что позволяет предположить, что улучшение качества модели возможно как с увеличением качества предикторов, так и с учетом других метеопараметров, влияющих на сход селей (например, орография местности и т.д.).

При этом высокое значение коэффициента корреляции ( $r = 0,9483$ ) между реальными данными V1 и модельными данными V2 подтверждает хорошее согласие модели с фактическими данными.

### Прогноз активности селей по нейросетевой модели MLP 2-50-1.

Хорошее качество модели позволяет использовать ее для восстановления и прогноза количества селей на 2016–2034 гг., используя в качестве предикторов температуры и осадки в теплый сезон (май–сентябрь). Ряды температур и осадков 2016–2034 гг. состоят из фактических данных м/станции Терскол с 2016 по 2024 г. и из прогнозных значений, рассчитанных с помощью метода сингулярно-спектрального анализа («Гусеница-SSA») [13–15].

Данные прогноза температур и осадков теплого сезона (май–сентябрь) м/станции Терскол представлены в таблицах 2 и 3.

Таблица 2. ПРОГНОЗ СРЕДНЕЙ ТЕМПЕРАТУРЫ ТЕПЛОГО СЕЗОНА на 2025–2034 гг.  
Table 2. Forecast of average temperature of warm season for 2025–2034

№ п/п	Годы	Исходный ряд, °С	Прогнозный ряд, °С	№ п/п	Годы	Исходный ряд, °С	Прогнозный ряд, °С
1	1953	11,3	—	64	2024	10,9	10,8
...	...	...	...	среднее		10,9	10,8
относительная ошибка $\delta = 41\%$							
54	2014	10,9	10,9	65	2025	—	10,2
55	2015	11,3	11,1	66	2026	—	11,1
56	2016	10,1	10,2	67	2027	—	11,4
57	2017	11,1	10,6	68	2028	—	10,9
58	2018	11,4	10,5	69	2029	—	10,9
59	2019	10,7	11,4	70	2030	—	10,7
60	2020	10,9	10,4	71	2031	—	11,9
61	2021	10,8	10,2	72	2032	—	11,0
62	2022	10,8	11,2	73	2033	—	10,9
63	2023	10,8	11,0	74	2034	—	11,1

Источник: составлено авторами. Source: compiled by the authors.

Таблица 3. ПРОГНОЗ ОСРЕДНЕННОЙ СУММЫ ОСАДКОВ ТЕПЛОГО СЕЗОНА на 2025–2034 гг.  
Table 3. Forecast of average precipitation amount for the warm season for 2025–2034

№ п/п	Годы	Исходный ряд, мм	Прогнозный ряд, мм	№ п/п	Годы	Исходный ряд, мм	Прогнозный ряд, мм
1	1953	89,4		64	2024	70,8	70,0
...	...	...	...	среднее		92,5	91,9
относительная ошибка $\delta = 14\%$							
54	2014	120,5	120,5	65	2025	—	135,6
55	2015	62,6	79,9	66	2026	—	115,0
56	2016	109,6	88,1	67	2027	—	73,8
57	2017	112,4	95,1	68	2028	—	87,0
58	2018	87,0	86,4	69	2029	—	84,4
59	2019	110,0	101,4	70	2030	—	81,1
60	2020	87,3	117,0	71	2031	—	125,0
61	2021	98,1	105,5	72	2032	—	126,9
62	2022	89,8	84,7	73	2033	—	80,8
63	2023	69,7	62,4	74	2034	—	65,3

Источник: составлено авторами.

Source: compiled by the authors.

Относительная ошибка прогноза определялась по формуле:

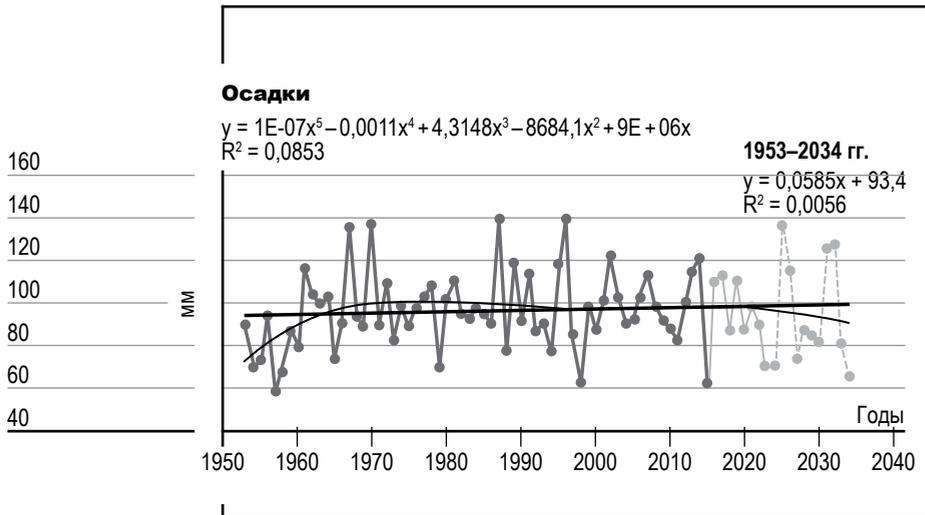
$$\delta = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i^{\phi} - y_i^{\text{пр}}}{y_i^{\phi}} \right| 100\%, \quad (7)$$

где  $y_i^{\text{пр}}$  – прогнозные значения на историческом интервале 2014–2024 гг.;

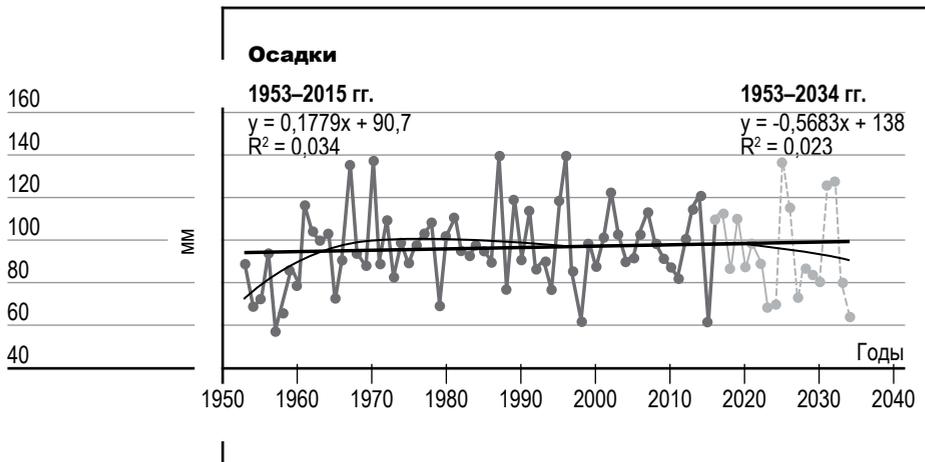
$y_i^{\phi}$  – фактические значения на этом же интервале.

Ошибки прогноза температуры и осадков методом сингулярно-спектрального анализа, рассчитанные по формуле (7), составили для температуры  $\delta = 4,1\%$ , для осадков  $\delta = 14\%$ , что характеризует хорошее качество моделей и возможность для дальнейшего использования полученных значений для прогноза количества селей с помощью модели MLP 2-50-1.

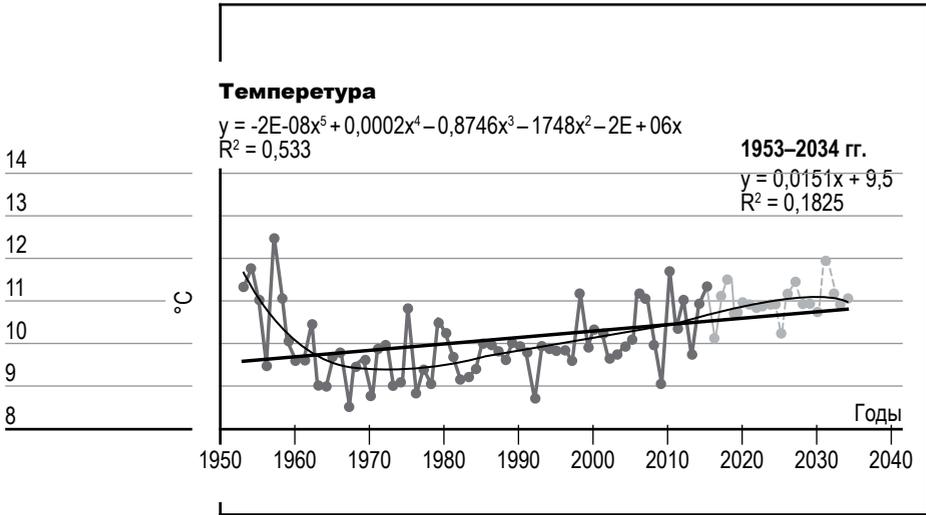
Графики рядов температур и осадков за 1953–2034 гг. представлены на рисунках 6–9. На них оранжевым цветом выделены значения с 2016 по 2034 г., которые в дальнейшем будут использоваться для получения прогноза количества селей, используя нейро-



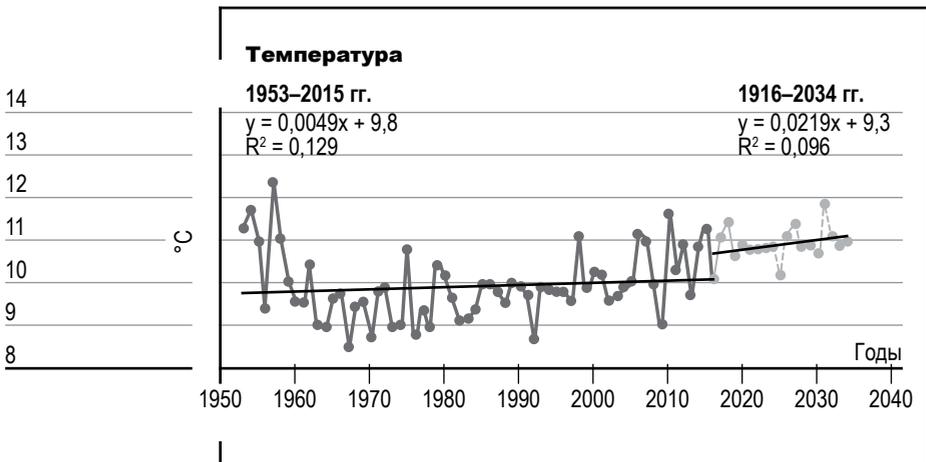
**Рис. 6.** Средненная сумма осадков теплого сезона (май–сентябрь) с полиномиальным и линейным трендами, 1953–2034 гг., Терскол (пунктиром – прогноз на 2025–2034 гг., «Гусеница-SSA»).  
Fig. 6. Average precipitation for the warm season (May–September) with polynomial and linear trends, 1953–2034, Terskol (dotted line – forecast for 2025–2034, Caterpillar-SSA).  
Источник: составлено авторами. Source: compiled by the authors.



**Рис. 7.** Средненная сумма осадков теплого сезона (май–сентябрь) с линейными трендами 1953–2015 гг. и 2016–2034 гг. (пунктиром – прогноз на 2025–2034 гг., «Гусеница-SSA»).  
Fig. 7. Average precipitation for the warm season (May–September) with linear trends for 1953–2015 and 2016–2034 (dotted line – forecast for 2025–2034, Caterpillar-SSA).  
Источник: составлено авторами. Source: compiled by the authors.



**Рис. 8.** Средняя температура теплого сезона (май–сентябрь) с полиномиальным и линейным трендами, 1953–2034 гг., Терскол (пунктиром – прогноз на 2025–2034 гг., «Гусеница-SSA»).  
Fig. 8. Average temperature of the warm season (May–September) with polynomial and linear trends, 1953–2034, Terskol (dotted line – forecast for 2025–2034, Caterpillar-SSA).  
Источник: составлено авторами. Source: compiled by the authors.



**Рис. 9.** Средняя температура теплого сезона (май–сентябрь) с линейными трендами 1953–2015 гг. и 2016–2034 гг., Терскол (пунктиром – прогноз на 2025–2034 гг., «Гусеница-SSA»).  
Fig. 9. Average temperature of the warm season (May-September) with linear trends for 1953–2015 and 2016–2034, Terskol (dotted line – forecast for 2025–2034, Caterpillar-SSA)  
Источник: составлено авторами. Source: compiled by the authors.

сетевую модель MLP 2-50-1. Ряды температур и осадков состоят из фактических данных (1953–2024 гг.) и прогнозных данных (2025–2034 гг.), которые выделены пунктирной линией.

В силу естественной изменчивости тренды, основанные на коротких периодах наблюдений, очень чувствительны к датам начала и окончания периода и в целом не отражают долгосрочные климатические тенденции. Поэтому были использованы не только линейные тренды, охватывающие весь период исследования 1953–2015 гг., но и полиномиальный тренд, демонстрирующий изменения в подпериодах, также был выделен линейный тренд для прогнозных данных с 2016 по 2034 г.

Воспользуемся командой *Прогноз пользователя* (Custom Predictions) для прогноза количества селей на базе полученной модели MLP-2-50-1 (рис. 10). Запускаем команду *Прогноз пользователя* и вносим в окошко свои данные по температуре и осадкам за период 2016–2034 гг. (из них с 2016 по 2024 г. – фактические данные м/станции Терскол и с 2025 по 2034 г. – прогнозные данные, полученные с помощью метода Гусеница-SSA, и использования их в модели MLP 2-50-1 для прогноза количества селей. В результате формируем таблицу 4 с прогнозными значениями количества селей с 2016 по 2034 г.

Из таблицы 4 видно, что при осредненных значениях осадков с величиной более 110 мм в период с мая по сентябрь 2016–2034 гг. прогнозируется количество сходов селей от 10 до 13, что выше среднего их значения  $n = 8$  за период с фактическими данными 1953–2015 гг. [8].

На рисунке 11 показаны тенденции изменения количества селей в Терскольском ущелье в теплый сезон с 1953 по 2015 г. (период с фактическими данными, сплошная линия) и с 2016 по 2034 г. (период с прогнозными данными, пунктир) с помощью полиномиального и линейного трендов. Из уравнения линейного тренда следует, что в среднем за весь период, включая прогнозный, количество схода селей имеет тенденцию слабого роста на 0,3/10 лет. Полиномиальный тренд демонстрирует рост и снижение количества селей на разных временных интервалах.

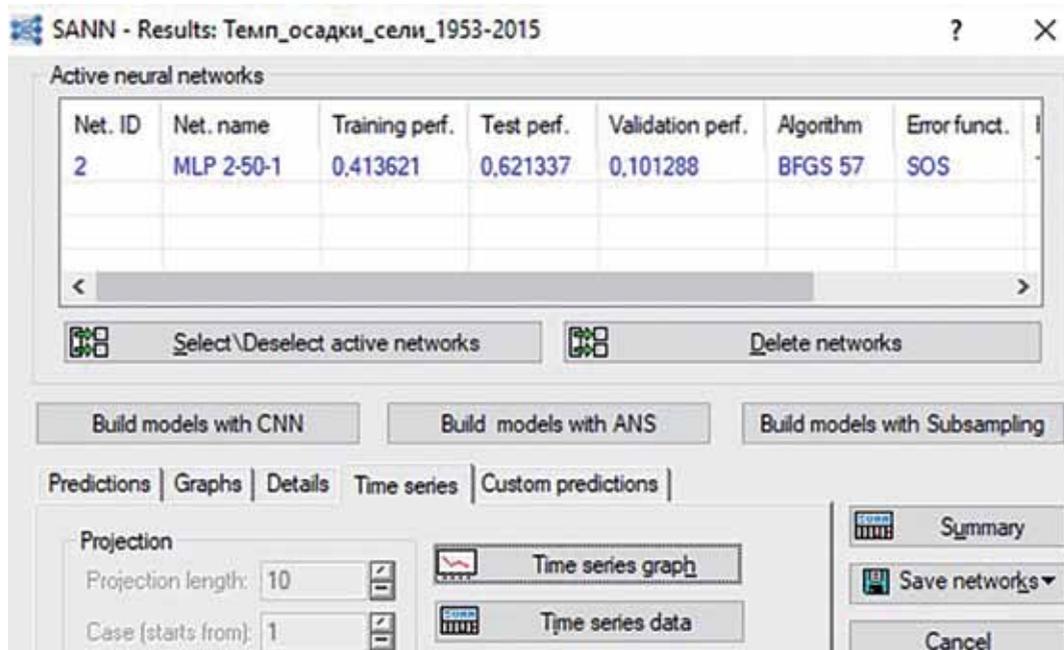


Рис. 10.

Скриншот с командой Прогноз пользователя (Custom Predictions) с нейросетевой моделью MLP 2-50-1.

Fig. 10. Screenshot with the Custom Predictions command with the MLP 2-50-1 neural network model

Источник:  
Source:

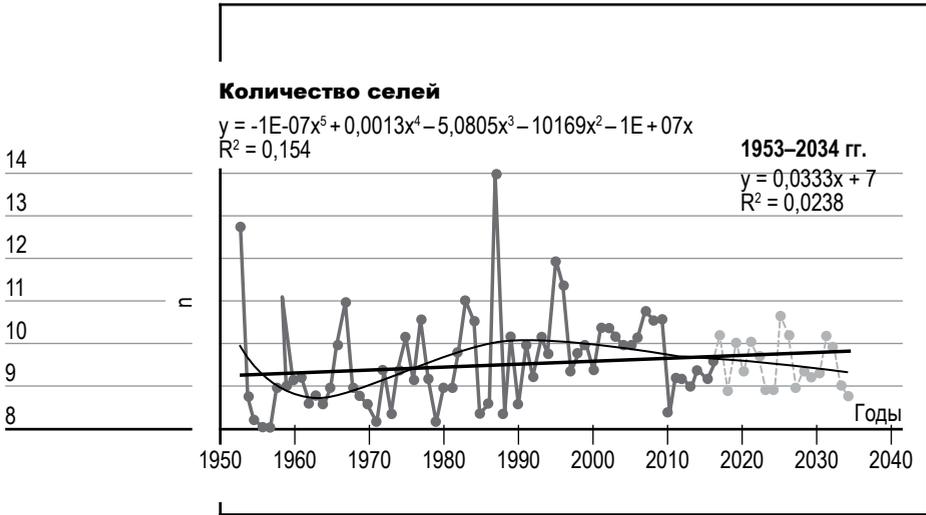
составлено авторами.  
compiled by the authors.

Таблица 4. РЕЗУЛЬТАТЫ ПРОГНОЗА КОЛИЧЕСТВА СЕЛЕЙ НА 2016–2034 ГГ. С ПОМОЩЬЮ НЕЙРОСЕТЕВОЙ МОДЕЛИ MLP 2-50-1  
Table 4. Results of the forecast of the number of mudflows for 2016-2034 using the neural network model MLP 2-50-1

пп	Годы	Прогноз количества селей по модели MLP 2-50-1		
		Количество селей	Температура (входные)*	Осадки (входные)*
1	2016	8,2	10,12	109,56
2	2017	11,1	11,06	112,36
3	2018	4,6	11,44	87,00
4	2019	10,2	10,66	110,00
5	2020	6,8	10,92	87,32
6	2021	10,4	10,82	98,12
7	2022	8,6	10,80	89,82
8	2023	4,7	10,84	69,74
9	2024	4,6	10,90	70,80
10	2025	13,2	10,20	135,60
11	2026	11,0	11,10	115,04
12	2027	5,0	11,40	73,76
13	2028	6,8	10,90	87,04
14	2029	6,1	10,90	84,36
15	2030	6,7	10,70	81,12
16	2031	10,5	11,90	124,98
17	2032	9,8	11,10	126,90
18	2033	5,3	10,90	80,82
19	2034	4,2	11,00	65,26

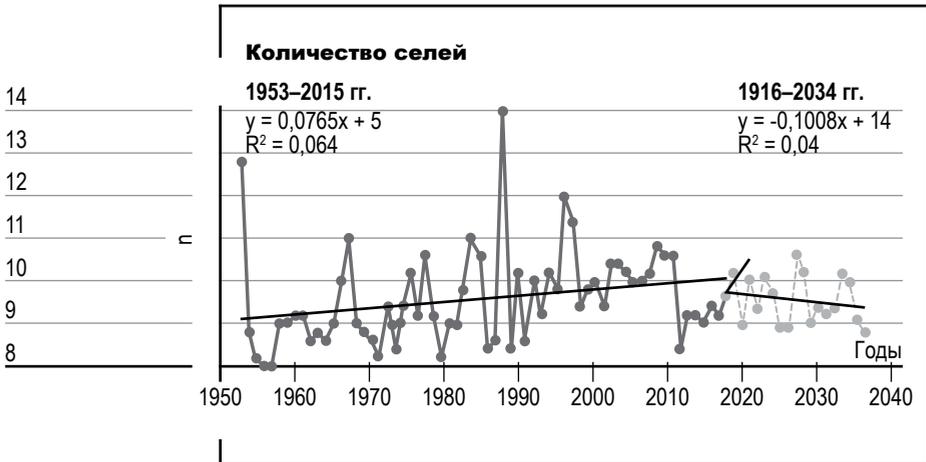
Источник: составлено авторами.  
Source: compiled by the authors.

\* С 2016 по 2024 г. — фактические данные метеопараметров м/станции Терскол, с 2025 по 2034 г. — прогнозные данные, полученные с помощью метода сингулярно-спектрального анализа (Гусеница-SSA).



**Рис. 11.** Количество селей в теплый сезон (май–сентябрь) с полиномиальным и линейным трендами, 1953–2034 гг., Терскол (пунктиром – прогноз на 2016–2034 гг., нейросетевая модель MLP 2-50-1).

Fig. 11. The number of mudflows in the warm season (May-September) with polynomial and linear trends, 1953-2034, Terskol (dotted line – forecast for 2016–2034, neural network model MLP 2-50-1)  
Источник: составлено авторами. Source: compiled by the authors.



**Рис. 12.** Количество селей с линейными трендами 1953–2015 гг. и 2016–2034 гг. (пунктиром – прогноз на 2016–2034 гг., нейросетевая модель MLP 2-50-1).

Fig. 12. Mudflows with linear trends for 1953–2015 and 2016–2034 (dotted line – forecast for 2016–2034, neural network model MLP 2-50-1).  
Источник: составлено авторами. Source: compiled by the authors.

На рисунке 12 выделены два временных интервала: с 1953 по 2015 г. – период с фактическими данными (сплошная голубая линия) и с 2016 по 2034 г. – период с прогнозными данными (оранжевый пунктир). Как видно из рисунков 11 и 12, снижение количества селей на интервале прогнозирования 2016–2034 гг. (оранжевый пунктир) демонстрируют как полиномиальный тренд, так и линейный.

Из сравнения с рисунками 7 и 8 (осадки) видно, что отрицательная тенденция количества селей на интервале прогнозирования идентична тенденции суммы осадков в теплый сезон, а именно, их снижение, и происходит это на фоне роста температур (рисунки 9 и 10).

### **Заключение**

Таким образом, на основе алгоритмов глубокого обучения была разработана математическая модель MPL 2-50-1, способная обучаться на используемых данных (осадки, температура, количество селей за период 1953–2015 гг.), и осуществлять прогнозирование количества селей по метеопараметрам (осадки, температура). Получено, что при осредненных значениях осадков с величиной более 110 мм в период с мая по сентябрь с 2016 по 2034 г. прогнозируется количество сходов селей от 10 до 13, что выше среднего их значения  $n = 8$  за 1953–2015 гг. – периода с фактическими данными.

Точность модели составила 48,4 %, что позволяет предположить, что улучшение качества модели возможно как с увеличением качества предикторов, так и с учетом других метеопараметров, влияющих на сход селей (например, орография местности и т.д.).

Такие модели необходимы для реализации следующих задач – формулировки методологии, а именно, системы методов, которые используются для решения исследовательской задачи и затем разработки модели снижения рисков опасных склоновых явлений.

### **Список источников**

1. Солдатенко С. А. Искусственный интеллект и его применение в задачах численного прогноза погоды // Метеорология и гидрология. 2024. № 4. С. 5–27.

2. Сумачев А. Э., Банщикова Л. С., Грига С. А. Применение методов обучения искусственных нейронных сетей при прогнозировании высших уровней воды на примере рек Двинско-Печорского бассейнового округа // Метеорология и гидрология. 2024. № 4. С. 104–115.
3. Ашабоков Б. А., Ташилова А. А., Кешева Л. А., Теунова Н. В. Модель синусоидальной регрессии для оценки динамики селевых сходов // Наука. Инновации. Технологии. 2024. № 3. С. 71–94. <https://doi.org/0.37493/2308-4758.2024.3.4>
4. Золина О.Г., Булыгина О.Н. Современная климатическая изменчивость характеристик экстремальных осадков в России // Фундаментальная и прикладная климатология. 2016. Т. 1. С. 84–103.
5. Ashabokov B. A., Tashilova A. A., Kesheva L. A., Teunova N.V. Analysis of climate change in the Caucasus region: the end of the 20th - the beginning of the 21st century // CLIMATE. Special issue: Climate Variability and Change in the 21th Century. CLIMATE. 2019. Vol. 7. No. 11. P. 1–15. <https://doi.org/10.3390/cli7010011>
6. Yun W.-T., Krishnamurti T. N. Linear and non-linear multi-model superensemble prediction model // Atmosphere. 2002. No. 12 (3). P. 26–31.
7. Кондратьева Н. В. Распространение и особенности проявления селевых процессов на северном и юго-западном склонах Большого Кавказа. дис. ... док. геогр. наук: 25.00.23 / Кондратьева Наталия Владимировна. Нальчик. 2018. 402 с.
8. Ташилова А. А., Федченко Л. М., Залиханов М. Ч., Кондратьева Н. В. Анализ динамики селей на фоне климатических изменений в высокогорной зоне Кабардино-Балкарии // Наука. Инновации. Технологии. 2024. № 1. С. 69–90. <https://doi.org/10.37493/2308-4758.2024.1.4>
9. Нейронные сети. STATISTICA Neural Networks. Методология и технологии современного анализа данных / Под ред. В.П. Боровикова. 2-е изд. Телеком, 2008. 392 с.
10. Электронный учебник по статистике. URL: <http://statsoft.ru/home/textbook/default.htm> (дата обращения 27.06.2024).
11. Филатова Т. В. Применение нейронных сетей для аппроксимации данных // Вестник Томского государственного университета. 2004. № 284. С. 121–125.
12. Хайкин С. Нейронные сети: полный курс. 2-е изд.: пер. с англ. М.: Издательский дом «Вильямс», 2006. 1104 с.

13. Голяндина Н. Э. Метод «Гусеница»-SSA. Анализ временных рядов. СПб: Изд-во СПбГУ, 2004. 76 с.
14. Голяндина Н. Э. Метод «Гусеница»-SSA. Прогноз временных рядов. СПб: Изд-во СПбГУ, 2004. 52 с.
15. Golyandina N., Nekrutkin V., Zhigljansky A. Analysis of Time Series Structure // SSA and Related Techniques. London Chapman & Hall/CRC, 2001. 305 p.

### References

1. Soldatenko SA. Artificial intelligence and its application in numerical weather forecasting problems. *Meteorologiya i Gidrologiya*. 2024;(4):5-27. (In Russ.).
2. Sumachev AE, Bانشchikova LS, Griga SA. Application of artificial neural network training methods in forecasting higher water levels using the example of the rivers of the Dvina-Pechora basin district. *Meteorologiya i Gidrologiya*. 2024;(4):104–115. (In Russ.).
3. Ashabokov BA, Tashilova AA, Kesheva LA, Teunova NV. Sinusoidal regression model for assessing the dynamics of mudflows. *Science. Innovations. Technologies*. 2024;(3):71-94. (In Russ.). <https://doi.org/10.37493/2308-4758.2024.3.4>
4. Zolina OG, Bulygina ON. Modern climatic variability of characteristics of extreme precipitation in Russia. *Fundamental and Applied Climatology*. 2016;(1):84-103. (In Russ.).
5. Ashabokov BA, Tashilova AA, Kesheva LA, Teunova NV. Analysis of climate change in the Caucasus region: the end of the 20th - the beginning of the 21st century. *CLIMATE. Special issue: Climate Variability and Change in the 21st Century*. *CLIMATE*. 2019;7(11):1-15. <https://doi.org/10.3390/cli7010011>
6. Yun W-T, Krishnamurti TN. Linear and non-linear multi-model superensemble prediction model. *Atmosphere*, 2002;12(3):26-31.
7. Kondratieva NV. Distribution and features of manifestation of mudflow processes on the northern and southwestern slopes of the Greater Caucasus. dissertation of dr. of geogr. sciences. Nalchik. 2018. 402 p. (In Russ.).
8. Tashilova AA, Fedchenko LM, Zalikhanov MCh, Kondratieva NV. Analysis of mudflow dynamics against the background of climate change in the high-mountain zone of Kabardino-Balkaria. *Science. Innovations. Technologies*. 2024;(1):69-90. (In Russ.). <https://doi.org/10.37493/2308-4758.2024.1.4>
9. Neural networks. *STATISTICA Neural Networks. Methodology*

- and technologies of modern data analysis. Ed. V.P. Borovikov. 2nd ed. Telecom; 2008. 392 p. (In Russ.).
10. Electronic textbook on statistics. Available from: <http://statsoft.ru/home/textbook/default.htm> [Accessed 27 June 2024]. (In Russ.).
  11. Filatova TV. Application of neural networks for data approximation. Tomsk State University Journal. 2004;(284):121-125. (In Russ.).
  12. Khaikin S. Neural networks: full course. 2nd ed.: trans. from English. Moscow: Williams Publishing House; 2006. 1104 p. (In Russ.).
  13. Golyandina NE. The Caterpillar-SSA Method. Time Series Analysis. SPb: SPbSU Publishing House; 2004. 76 p. (In Russ.).
  14. Golyandina NE. The Caterpillar-SSA Method. Time Series Forecast. SPb: SPbSU Publishing House; 2004. 52 p. (In Russ.).
  15. Golyandina N, Nekrutkin V, Zhigljansky A. Analysis of Time Series Structure/ SSA and Related Techniques. London Chapman & Hall/CRC; 2001. 305 p.

### **Информация об авторах**

**Борис Азреталиевич Ашабоков** – доктор физико-математических наук, профессор, заведующий отделом физики облаков Высокогорного геофизического института; заведующий отделом Института информатики и проблем регионального управления КБНЦ РАН, Scopus ID: 6505916110, Researcher ID: K-4299-2015.

**Алла Амарбиевна Ташилова** – доктор физико-математических наук, доцент, ведущий научный сотрудник лаборатории микрофизики облаков Высокогорного геофизического института, Scopus ID: 57191577384, Researcher ID: K-4321-2015.

**Лара Асировна Кешева** – кандидат физико-математических наук, старший научный сотрудник лаборатории атмосферных конвективных явлений Высокогорного геофизического института, Scopus ID: 57191577471, Researcher ID: K-4261-2015.

**Наталья Вячеславовна Теунова** – кандидат физико-математических наук, старший научный сотрудник лаборатории микрофизики облаков Высокогорного геофизического института, Scopus ID: 57191571952, Researcher ID: K-4312-2015.

**Вклад авторов:** все авторы сделали равный вклад в подготовку публикации статьи.

### **Information about the authors**

**Boris A. Ashabokov** – Dr. Sci. (Phys.-Math.), Professor, Head of the Department of Cloud Physics, High Mountain Geophysical Institute; Head of Department at the Institute of Informatics and Regional Management Problems, Kabardino-Balkarian Scientific Center of the Russian Academy of Sciences, Scopus ID: 6505916110, Researcher ID: K-4299-2015.

**Alla A. Tashilova** – Dr. Sci. (Phys.-Math.), Associate Professor, Leading Researcher at the Laboratory of Cloud Microphysics, High Mountain Geophysical Institute, Scopus ID: 57191577384, Researcher ID: K-4321-2015.

**Lara A. Kesheva** – Cand. Sci. (Phys.-Math.), Senior Researcher at the Laboratory of Atmospheric Convective Phenomena, High Mountain Geophysical Institute, Scopus ID: 57191577471, Researcher ID: K-4261-2015.

**Nataliya V. Teunova** – Cand. Sci. (Phys.-Math.), Senior Researcher at the Laboratory of Cloud Microphysics, High Mountain Geophysical Institute, Scopus ID: 57191571952, Researcher ID: K-4312-2015.

**Contribution of the authors:** the authors contributed equally to this article.