

ТЕОРЕТИЧЕСКАЯ И ПРИКЛАДНАЯ ТЕПЛОТЕХНИКА



УДК 621.22

DOI:10.30724/1998-9903-2024-26-5-104-117

МОДЕЛЬ ИСКУССТВЕННОЙ НЕЙРОСЕТИ ДЛЯ ПРОГНОЗИРОВАНИЯ ОБЪЕМА ВОДЫ В ВОДОХРАНИЛИЩЕ

Шилин А.Н., Богале М.А., Коновалова Л.А.

Волгоградский государственный технический университет, г. Волгоград, Россия
eltech@vstu.ru, mila27121989@mail.ru

Резюме: АКТУАЛЬНОСТЬ данного исследования заключается в использовании искусственной нейронной сети для прогнозирования объема воды в водохранилище Кока (гидроэлектростанция Кока в Эфиопии). Как известно, гидроэнергетика, являясь возобновляемой энергией, относится к числу технологий, которые производят электроэнергию с наименьшим воздействием на глобальное изменение климата. За это время Эфиопия получала около 87% (4674 МВт) электроэнергии от гидроэнергетики. Это одна из стран, затронутых проблемами климатических явлений, таких как наводнения, засухи и ураганы, которые влияют на потенциал гидроэнергетики. ЦЕЛЬ. Для поддержания безопасной эксплуатации, хорошей эффективности производства, лучшего управления водными ресурсами, эффективного принятия решений, предотвращения аварий и обеспечения раннего предупреждения и ограничений на производство электроэнергии необходимо прогнозирование объема воды. Что, в свою очередь, является нелинейной задачей, и для этой цели подходит нейронная сеть типа мультилинейного персептрона (MLP). МЕТОДЫ. В этом исследовании были определены различные модели с различным выбранным количеством узлов и слоев, поскольку не существует конкретного правила для определения архитектуры искусственной нейронной сети. Статистический анализ (среднеквадратичная ошибка (MSE) и R-квадрат (R²)) использовался для проверки достоверности модели путем сравнения фактических значений притока воды с прогнозируемыми значениями. РЕЗУЛЬТАТЫ. Было проведено предсказание притока с использованием метода ANN, основанного на многослойном персептроне (MLP). Производительность каждой модели была оценена с использованием среднеквадратичной ошибки (MSE) и коэффициента эффективности (R²), которые являются одними из наиболее часто используемых статистических методов в гидрологическом моделировании. ЗАКЛЮЧЕНИЕ. Полученные результаты показывают, что модели успешно предсказали паводковый сток над водохранилищем.

Ключевые слова: приток в коллектор; прогнозирование; искусственная нейронная сеть; многослойный персептрон; гидроэлектростанция.

Для цитирования: Шилин А.Н., Богале М.А., Коновалова Л.А. Модель искусственной нейросети для прогнозирования объема воды в водохранилище // Известия высших учебных заведений. ПРОБЛЕМЫ ЭНЕРГЕТИКИ. 2024. Т. 26. № 5. С. 104-117. doi:10.30724/1998-9903-2024-26-5-104-117.

ARTIFICIAL NEURAL NETWORK MODEL FOR PREDICTING WATER INFLOW INTO A RESERVOIR

Shilin A.N., Bogale M.A., Konovalova L.A.

Volgograd State Technical University, Volgograd, Russia
eltech@vstu.ru, mila27121989@mail.ru

Abstract: RELEVANCE of this study lies in the use of an artificial neural network to predict the volume of water in the Coca reservoir (Coca hydroelectric power station in Ethiopia). As

you know, hydropower, being renewable energy, is one of the technologies that produce electricity with the least impact on global climate change. During this time, Ethiopia received about 87% (4,674 MW) of electricity from hydropower. It is one of the countries affected by the problems of climatic phenomena, such as floods, droughts and hurricanes, which affect the potential of hydropower. **THE PURPOSE.** In order to maintain safe operation, good production efficiency, better water resources management, effective decision-making, accident prevention and early warning and restrictions on electricity production, water volume forecasting is necessary. Which, in turn, is a nonlinear problem, and a multilinear perceptron-type neural network (MLP) is suitable for this purpose. **METHODS.** In this study, different models with different selected number of nodes and layers were identified, since there is no specific rule for determining the architecture of an artificial neural network. Statistical analysis (mean square error (MSE) and R-squared (R²)) was used to verify the validity of the model by comparing the actual values of water inflow with the predicted values. **results.** The inflow prediction was carried out using the ANN method based on a multilayer perceptron (MLP). The performance of each model was evaluated using the mean square error (MSE) and efficiency coefficient (R²), which are among the most commonly used statistical methods in hydrological modeling. **CONCLUSION.** The results obtained show that the models successfully predicted flood runoff over the reservoir.

Keywords: reservoir inflow; forecasting; artificial neural network; multilayer perceptron; hydroelectric power station.

For citation: Shilin A.N., Bogale M.A., Konovalova L.A. Artificial neural network model for predicting water inflow into a reservoir. *Power engineering: research, equipment, technology.* 2024; 26 (5): 104-117. doi:10.30724/1998-9903-2024-26-5-104-117.

Введение и литературный обзор (Introduction and Literature review)

Водохранилище используется для управления водными ресурсами, и гидрография его притока и оттока имеет решающее значение для планирования водохранилища для сельскохозяйственного, промышленного и муниципального водопользования; производства гидроэнергии; отдыха; экологических требований; и защиты от наводнений.

Водный баланс водохранилища связан со многими различными гидрологическими процессами, такими как прямое выпадение осадков, поверхностное испарение, дренаж из районов выше по течению (приток) и сброс воды через водосбросы (отток). Однако в большинстве случаев данные о погоде и уровнях воды в водохранилищах часто являются единственными наблюдениями, доступными для анализа водного бюджета [1]. Таким образом, бюджет водохранилища обычно оценивается на основе водного баланса водохранилища, но это может стать некорректной проблемой из-за отсутствия наблюдений. Некорректное уравнение водного баланса может быть решено только тогда, когда станут известны два из трех членов или переменных, а именно приток, уровень воды и отток. Таким образом, при наличии записей об уровне воды в водохранилище уравнение водного баланса может быть решено путем оценки одной из двух оставшихся неизвестных переменных притока и оттока. В этот период нулевого оттока количество воды, поступающей в водохранилище (т.е. гидрограф притока), может быть непосредственно определено количественно на основе изменений уровня воды в водохранилище (или запасов воды) после учета количества осадков и скорости испарения в уравнении водного баланса водохранилища [2].

Постановка задачи водного баланса водохранилища [3]:

– Уравнение баланса массы: $\frac{ds}{dt} = I - 0 \rightarrow \frac{ds}{dt} = (RI + R) - (E + R0)$;

– Две неизвестные переменные в одном уравнении;

– Известные переменные: S – из данных об уровне воды в водохранилище, R и E (из данных о погоде);

– Неизвестные переменные: RI и $R0$;

* ; I – общий приток; 0 – общий отток; RI – приток в водохранилище; R – осадки; E – испарение; $R0$ – отток из водохранилища.

Чаще всего проблемы возникают, когда естественный приток воды превышает установленную мощность головной ГЭС, и возникает необходимость в сливе воды. Верно и то, что в периоды засухи расход воды может легко превышать естественный

приток, что приводит к снижению напора ГЭС и, следовательно, к снижению выработки электроэнергии. Из-за этих фактов для оператора очень важно иметь возможность предвидеть изменения притока воды во времени.

Следовательно, цель исследования заключается в разработке метода прогнозирования естественного притока воды в водохранилище с использованием искусственных нейронных сетей. Реализация прогнозирования, единственный способ принципиально нивелировать недостаток:

- а) прогнозирования водного режима реки, отличающегося также значительной инерционностью, с учётом климатических факторов, обуславливающих расход притока воды (количество воды в м³, протекающее через данное живое сечение реки в секунду);
- б) прогнозирования водопотребления;
- в) прогнозирования электрических нагрузок;
- г) использования плана регламентных работ, связанных с изменением эксплуатационных характеристик электростанции, например, вывода из эксплуатации одного из гидроагрегатов (или его запуска), а также оценки текущего износа гидроагрегатов.

Последнее зачастую обуславливает проблему холостых сбросов воды при сильных паводках, что само по себе затрудняет эффективное функционирование ГЭС. Практика холостых сбросов воды в нижний бьеф (мимо турбин) является вынужденной мерой в случае превышения расхода притока воды по отношению к максимальному расходу воды через ГЭС, величина которого определяется исходя из ограничений по допустимой мощности генераторов, пропускной способности турбин, а также пределу передаваемой по линиям электропередачи мощности. Несоответствие перечисленных величин ГЭС и параметров речного стока приводит к массовым холостым сбросам воды и снижению энергетической эффективности станции.

Научная значимость исследования состоит в том, что разработанный метод позволит прогнозировать изменения притока воды и, следовательно, улучшить управление водохранилищем. Способность правильно прогнозировать увеличение естественного притока может также привести к увеличению производства электроэнергии за счет повышения гибкости в управлении запасенной водой. К сожалению, математическая зависимость между количеством осадков в разных местах и естественным притоком нелинейной, и соответствующие математические соотношения сложно найти. Поэтому необходимы новые решения. Одним из подходов, который является перспективным, это применение искусственных нейронных сетей. Главное преимущество методов, основанных на нейронных сетях, заключается в том, что для идентификации системы (которая, в свою очередь, может быть использована для построения модели системы 'черного ящика') не требуется точных знаний о физических свойствах самой системы [4]. По этой причине нейросетевые модели являются наиболее подходящими для прогнозирования естественного притока. Практическая значимость исследования заключается в возможности эффективного использования водных ресурсов, оптимизации производства гидроэнергии, планирования мероприятий по защите от наводнений и учета экологических требований при использовании водохранилища.

Теоретическая значимость данной работы заключается в исследовании применения нейронных сетей для прогнозирования притока воды на ГЭС Кока. Это открывает новые возможности для улучшения эффективности управления водными ресурсами, что может привести к снижению рисков наводнений и улучшению водоснабжения населенных пунктов. Для тестирования основанной на нейросетевом алгоритме модели прогнозирования притока воды мы использовали конкретные данные с ГЭС Кока (Эфиопия). За эксплуатацию водохранилища Кока традиционно отвечает Эфиопская электроэнергетическая корпорация (ЕЕРСо). Водоохранилище Кока используется для производства электроэнергии и орошения, и его работой управляет Комитет по эксплуатации. Расположенное ниже по течению от плотины, водохранилище обеспечивает основной источник электроснабжения для всей страны. Благодаря трем гидроэлектростанциям, расположенным внизу, электроэнергия производится эффективно и надежно. Кроме того, затопленная долина ниже плотины играет важную роль в орошении сельскохозяйственных угодий. Водоохранилище предоставляет воду для орошения более чем 70 000 гектаров земли, учитывая потребности в воде исходя из сезонных особенностей. Комитет по эксплуатации водохранилища Кока, включающий представителей Электрического совета и Министерства водных ресурсов и энергетики, разрабатывает графики работы и управляет операциями водохранилища. Графики

учитывают множество факторов, включая потребности в электроэнергии, безопасность от наводнений для застройки ниже по течению и потребности в водоснабжении населенных пунктов. Благодаря внимательному наблюдению комитета за работой водохранилища удалось предотвратить возникновение значительных наводнений и минимизировать ущерб от них. Это также привело к улучшению доступа к воде для населения и повысило эффективность орошения сельскохозяйственных угодий в затопленной долине [5]. По этой причине очень важно прогнозировать приток.

Практическая значимость полученных результатов состоит в том, что разработанный алгоритм может быть использован для прогнозирования притока воды на ГЭС Кока и других гидроэлектростанциях, что позволит улучшить эффективность управления водными ресурсами и повысить безопасность населения. Кроме того, результаты исследования могут быть использованы для разработки аналогичных систем прогнозирования в других областях, где необходим контроль за изменением уровня воды. Использование нейронных сетей имеет смысл при идентификации, контроле и прогнозировании. Основными свойствами нейронных сетей являются их нелинейность и обобщенность; то есть нейронная сеть может давать хорошие результаты даже для входных выборок, которые сильно отличаются от обучающих выборок [6].

Материалы и методы (Materials and methods)

Искусственные нейронные сети

Модель искусственной нейронной сети является полезным инструментом для моделирования сложных нелинейных систем и составления прогнозов. Таким образом, нейронные сети - это инструмент с большим потенциалом для применения в системах резервуаров. Это выражается в виде очень сложной, нелинейной и параллельно распределенной операционной системы благодаря способности к обучению, комбинированию, адаптации и обобщению. Нейроны в человеческом мозге общаются посредством электрических сигналов, которые они создают в химической среде. Следовательно, мозг можно рассматривать как структуру очень плотной электрической сети. При необходимости команды вырабатываются в центральной нервной системе и передаются в соответствующие органы. Он управляет центральной нервной системой с помощью соединений обратной связи, которые подтверждают предупреждения в этих органах. В большинстве случаев искусственная нейронная сеть - это адаптивная система, которая изменяет свою структуру на основе внешней или внутренней информации, проходящей через сеть. Они могут быть использованы для моделирования сложных взаимосвязей между входами и выходами [7].

Искусственные нейронные сети – это компьютерные программы, которые могут стимулировать нервную систему, составляющую человеческий мозг, и генерировать новую информацию из ранее изученных или классифицированных данных с помощью нейронных датчиков и принимать решения путем принятия решений. Он используется во многих областях, таких как распознавание образов, идентификация систем, роботизированная обработка сигналов, области нелинейного управления [8]. Как показано на рисунке 1, искусственные нервные клетки состоят из пяти основных частей. Это входные данные, веса, передаточная функция, функция активации и выходные данные.

Нейронная сеть в интеллектуальном анализе данных - это метод классификации, который принимает входные данные, обучается распознавать структуру входных данных и прогнозировать выходные данные для новых входных данных аналогичного типа. Нейронная сеть формирует основу глубокого обучения, подраздела машинного обучения, который относится к искусственному интеллекту. Точно так же, как человеческий мозг отвечает за интеллект и его способность к различению, нейронная сеть также имитирует человеческий мозг, извлекает уроки из его опыта и применяет это обучение для классификации и прогнозирования.

Искусственная нейронная сеть состоит из трех функциональных уровней. Они состоят из (а) входного слоя, (б) скрытого слоя и (в) выходного слоя. Скрытый слой может состоять из нескольких скрытых слоев, как показано на рисунке 2.

Основной принцип работы искусственных нейронных сетей показан на рисунках 1 и 2.

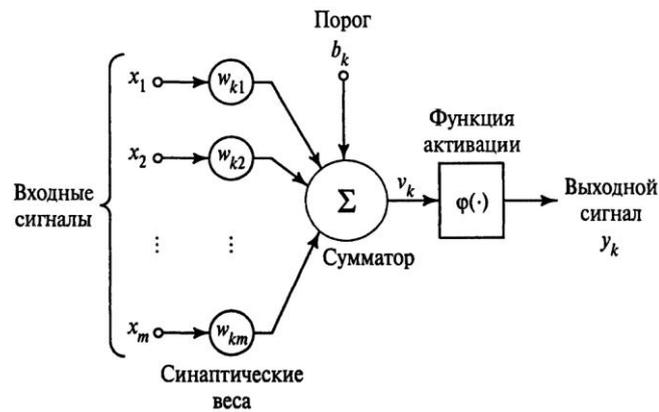


Рис. 1. Математическая модель нейрона

Fig. 1. Mathematical model of a neuron

*Источник: Составлено авторами Source: compiled by the author.

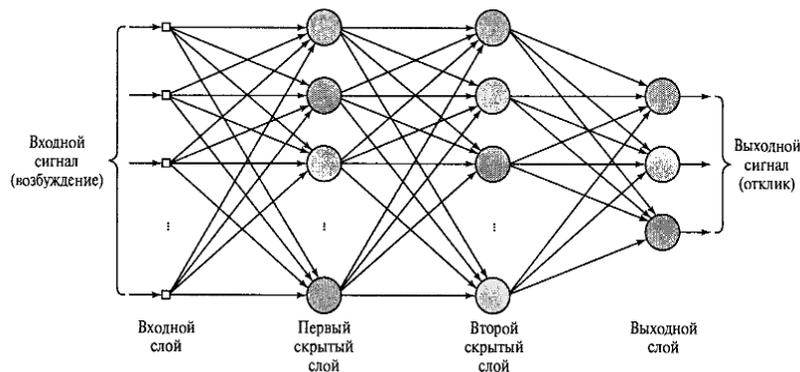


Рис. 2. Образование «нейронной сети»

Fig. 2. Formation of a "neural network"

*Источник: Составлено авторами Source: compiled by the author.

Единицей обработки информации в нейронной сети является нейрон. Математическая модель нейрона [9] представляет собой абстракцию биологического нейрона, используемую в области искусственного интеллекта и нейронных сетей [10]. Ее цель – предоставление математического описания работы нейрона и его взаимодействия с другими нейронами (рис. 1). Одна из самых распространенных математических моделей нейрона – модель Мак Каллока-Питтса. В этой модели нейрон представляется в виде узла, который принимает несколько входных сигналов и производит выходной сигнал на основе этих входных сигналов. Входные сигналы умножаются на веса, которые определяют силу влияния каждого входного сигнала на выходной сигнал. Затем взвешенные входные сигналы суммируются и пропускаются через функцию активации, которая определяет, каким образом суммированный вход будет преобразован в выходной сигнал. Различные функции активации могут быть использованы в модели нейрона, включая сигмоидную функцию, гиперболический тангенс и функции ReLU. Выбор функции активации зависит от конкретной задачи и требований моделирования.

Функция ReLU (Rectified Linear Unit) имеет несколько преимуществ, которые делают ее популярным выбором для активации нейронов в нейронных сетях:

1. Простота и эффективность: Функция ReLU очень проста в вычислении и не требует сложных операций, что делает ее вычислительно эффективной и быстрой.

2. Решение проблемы затухающего градиента: ReLU помогает избежать проблемы затухающего градиента, которая может возникнуть при использовании других функций активации, таких как сигмоида или тангенс.

3. Способствует разреженности активаций: Функция ReLU может привести к разреженным активациям нейронов, что способствует улучшению обобщающей способности модели и предотвращает переобучение.

4. Подходит для глубоких нейронных сетей: ReLU хорошо работает в глубоких нейронных сетях благодаря своей способности передавать градиенты и ускорять обучение.

5. Нелинейность: Функция ReLU вводит нелинейность в модель, что позволяет выучивать более сложные зависимости в данных.

Из-за этих преимуществ функция ReLU широко используется в нейронных сетях и является одной из наиболее популярных функций активации. Эта функция может преодолеть проблему исчезающего градиента, в отличие от других функций активации, потому что она выполняет пороговую операцию для входных элементов, так что она приводит в порядок количество входных данных ниже нуля (отрицательные значения), чтобы получить результат, равный нулю, это свойство называется разреженностью, т.е. активацией скрытых слоев в нейронные сети имеют истинные нулевые значения, поэтому обучение происходит быстрее, в то время как выходные данные функции имеют линейный тренд, когда входные значения положительны (рис. 3).

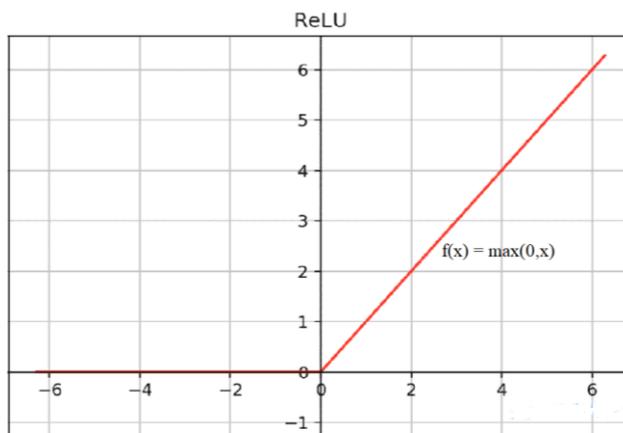


Рис. 3. Кривая функции ReLU

Fig. 3. The curve of the ReLU function

*Источник: Составлено авторами Source: compiled by the author.

Математически функцию активации ReLU можно определить как: $f(x)$, равную $\max(0, x)$, так что $\min(0, x) = xi$, если $xi \geq 0$, или $\min(0, x) = 0$, если xi меньше нуля [11].

Ограниченность однослойных нейронных сетей, связанная с линейной неразделимостью обучающих данных, подробно доказывается в [12]. Поэтому наиболее распространённым типом ИНС является перцептронная многослойная сеть, состоящая из нескольких последовательно соединённых слоёв нейронов.

В каждой из задач математического моделирования нейронная сеть играет роль универсального аппроксиматора функции от нескольких переменных, реализуя нелинейную функцию

$$y = f(x), \tag{1}$$

где X – это входной вектор, а y – реализация векторной функции нескольких переменных [12]. В контексте задачи математического моделирования процесса прогнозирования притока воды данная функция примет вид

$$y = (x_1, x_2, x_3), \tag{2}$$

где y – приток воды; x_1 – испарение; x_2 – осадки; x_3 – уровень воды.

Одним из наиболее популярных нейропакетов является программа Python, обладающая широкими возможностями моделирования нейронных сетей различной архитектуры, а также простым и понятным интерфейсом.

Решение задачи аппроксимации нелинейной функции с помощью нейронных сетей выполняется в несколько этапов.

Подготовка данных для обучения и проверки корректности работы нейронной сети

На основе информации о притоке и соответствующих гидрологических условиях, собранной метеостанцией за годы N и $N-1$, мы сформируем таблицу 1. Как упоминалось выше, известно, что (при анализе водного баланса) испарение, приток воды и осадки в водохранилище напрямую влияют на уровень воды в водохранилище.

Стандартная процедура разделяется тем, что набор данных разбивается на обучающие 80% данных, а для теста – на 20% данных.

Прежде чем разрабатывать какую-либо модель машинного обучения, сначала необходимо анализировать данные, чтобы определить, существует ли какая-либо линейная корреляция между переменными (рис. 4).

Информация о входных и выходных переменных в соответствии с наблюдениями метеостанции на водохранилище Кока

Information on input and output variables according to observations from the weather station at Koka Reservoir

Дата	Испарение, мм	Осадки, мм	Уровень воды, м	Приток воды, млн. куб. м
	x_1	x_2	x_3	y
01.N-1	204,6	28,7	109	10,65
02.N-1	134	20	107,9	6,23
03.N-1	210,8	20	107	27,1
04.N-1	198	12,23	106	22,17
05.N-1	189,1	14,36	105	89,73
06.N-1	171	93,1	104,5	68,89
07.N-1	161,2	251,9	106	377,3
08.N-1	151,9	251,9	108,5	893,49
09.N-1	141	133,7	110,7	267,38
10.N-1	192	20	110,5	43,94
11.N-1	192	20	109,7	24,6
12.N-1	186	20	109	11,83
01.N	204,6	28,7	108	8,65
02.N	134	20	107,5	7,66
03.N	210,8	20	106,5	23,49
04.N	198	12,23	105,5	44,59
05.N	189,1	14,36	105	39
06.N	171	93,1	104	68,63
07.N	161,2	251,9	107	482,06
08.N	151,9	251,9	109,5	833,89
09.N	141	133,7	110	405,95
10.N	192	20	110,4	45,13
11.N	192	20	109,5	25,97
12.N	186	20	109	12,48

*Источник: Составлено авторами Source: compiled by the author.

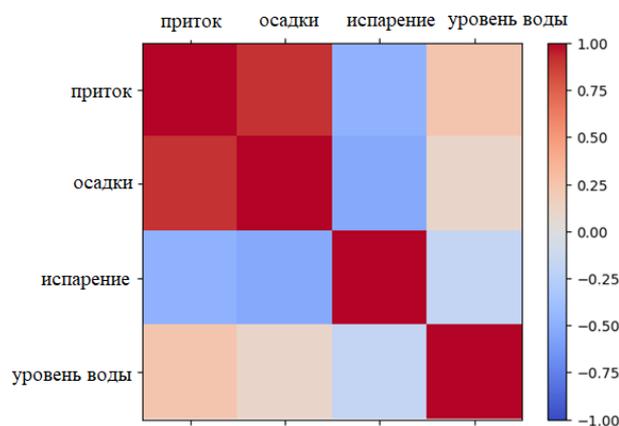


Рис. 4. Корреляция между переменными

Fig. 4. Correlation between variables

*Источник: Составлено авторами Source: compiled by the author.

Из данного множества данных отделяются две части, которые не пересекаются. Одна из них называется обучающим набором данных и используется для обучения нейронной сети. Другая часть, выделенная курсивом, является контрольным набором данных, который не используется в процессе обучения, но служит для проверки качества работы сети [13].

Для улучшения качества и скорости обучения нейронной сети необходимо привести входные данные к определенному диапазону значений $[-1; 1]$ [11]. Формула пересчета значения признака x для i -го примера выборки в интервал $[a; b]$ такова:

$$\tilde{x}_i = \frac{(x_i - x_{\min})(b-a)}{x_{\max} - x_{\min}} + a, \quad (3)$$

где x_{\min} , x_{\max} – минимальное и максимальное выборочные значения признака.

Выполнив ряд элементарных преобразований, выражение (3) можно будет записать в следующем виде:

$$\tilde{x}_i = \frac{x_i - \frac{1}{b-a}(x_{\min} - x_{\max})}{\frac{1}{b-a}(x_{\min} - x_{\max})} \quad (4)$$

Python автоматически выполняет нормирование входных сигналов в диапазон $[-1; 1]$ для подачи на вход нейронной сети по правилу (4).

Согласно нашему набору данных, Python выполнил нормализацию данных, показанную на рисунке 5:

```
array([[0.00498163, 0.0687195, 0.9192709, 0.7462683 ],
       [0.01796542, 0.03241958, 0.83333334, 0.2985077 ],
       [0.02352186, 0.03241958, 1.00000001, 0.44776154],
       [0.01796542, 0.03241958, 0.83333334, 0.2985077 ],
       [0.09410996, 0.00888722, 0.7174479, 0.14925385],
       [0.07062192, 0.3374223, 0.48177087, 0.07462692],
       [0.41822016, 1.0, 0.35416663, 0.2985077 ],
       [1.0, 1.0, 0.23307288, 0.67164135],
       [0.29433313, 0.5068219, 0.09114587, 1.00000001 ],
       [0.04250164, 0.03241958, 0.7552084, 0.97014904],
       [0.02070419, 0.03241958, 0.7552084, 0.8507471 ],
       [0.00631157, 0.03241958, 0.6770834, 0.7462683 ],
       [0.0027275, 0.0687195, 0.9192709, 0.5970144 ],
       [0.0016117, 0.03241958, 0.5223875 ],
       [0.01945315, 0.03241958, 1.00000001, 0.3731346 ],
       [0.04323423, 0.03241958, 0.83333334, 0.22388077],
       [0.03693393, 0.00888722, 0.7174479, 0.14925385],
       [0.07032888, 0.3374223, 0.48177087, 0.07462692],
       [0.53629154, 1.0, 0.35416663, 0.44776154],
       [0.932827, 1.0, 0.23307288, 0.8208952 ]], dtype=float32)
```

Рис. 5. Структурный синтез нейронной сети *Fig. 5. Structural synthesis of a neural network*
 *Источник: Составлено авторами *Source: compiled by the author.*

Для оценки оптимального числа нейронов в скрытых слоях персептрона может применяться формула, являющаяся следствием теорем Арнольда – Колмогорова – Хехт-Нильсена [13]:

$$\frac{N_y \cdot Q}{1 + \log_2 Q} \leq N_w \leq N_y \left(\frac{Q}{N_x} + 1 \right) (N_x + N_y + 1) + N_y, \quad (5)$$

где N_y – размерность выходного сигнала;

Q – число элементов обучающей выборки;

N_w – необходимое число синаптических весов;

N_x – размерность входного сигнала.

Согласно нашему набору данных: $3,76 \leq N_w \leq 37,5$.

При этом число нейронов скрытого слоя двухслойного персептрона:

$$N = \frac{N_w}{N_x + N_y} \quad (6)$$

Использование формул (5), (6) при $N_x = 3$, $N_y = 1$, $Q = 20$ даёт минимальное значение для $N = 1$ и максимальное $N = 9$.

Далее определим модель с нейронами (выбрав от 1 до 9 в зависимости от производительности) в первом скрытом слое и 1 нейроном в выходном слое, чтобы предсказать приток. Мы будем использовать функцию потерь средней абсолютной ошибки (MSE и R2) и эффективную версию Adam для стохастического градиентного спуска. Модель рассчитана на 795 тренировочных периодов с размером партии 32.

Обучение нейронной сети

Этап «обучение нейронной сети» является одним из основных этапов в разработке и использовании нейронных сетей. На этом этапе нейронная сеть настраивается на конкретную задачу путем обучения на обучающих данных. Процесс обучения включает следующие шаги: подготовка данных: обучающие данные должны быть предварительно подготовлены и структурированы таким образом, чтобы они были пригодны для обучения сети. Это может включать в себя предобработку данных, такую как нормализацию, удаление выбросов или заполнение пропущенных значений; определение архитектуры сети: нейронная сеть состоит из слоев нейронов, которые

соединены между собой. На этом этапе определяется структура сети, включая количество слоев, количество нейронов в каждом слое и типы активационных функций; инициализация весов: веса нейронной сети инициализируются случайными значениями. Это начальные значения, с которых начинается процесс обучения сети; прямой проход: обучающие данные передаются через нейронную сеть, происходит вычисление выходного значения сети; расчет функции потерь: функция потерь используется для определения разницы между выходными данными, полученными от нейронной сети, и ожидаемыми выходными данными. Чем меньше значение функции потерь, тем лучше результаты сети; распространение ошибки: ошибка, вычисленная на предыдущем шаге, распространяется обратно через сеть, влияя на веса каждого нейрона. Этот процесс называется обратным распространением ошибки; обновление весов: веса нейронной сети обновляются, используя различные алгоритмы оптимизации, такие как стохастический градиентный спуск или адам; повторение процесса: весь процесс (шаги 4-7) повторяется множество раз, пока сеть не достигнет приемлемого уровня точности на обучающих данных. Обучение нейронной сети может быть времязатратным процессом, особенно для сложных моделей или больших объемов данных. Поэтому обычно используются специализированные вычислительные ресурсы, такие как графические процессоры (GPU), для ускорения обучения.

В Python обратное распространение является наиболее распространенным алгоритмом обучения нейронных сетей. Это делает возможным градиентный спуск для многослойных нейронных сетей. Tensor Flow обрабатывает обратное распространение автоматически, поэтому не нужно глубокое понимание алгоритма.

Важной частью построения модели является разделение данных для обучения и тестирования, что гарантирует, что получена модель, которая может обобщаться за пределами обучающих данных, и что производительность и выходные данные будут статистически значимыми.

Результаты и обсуждения (Results and discussions)

Опрос обученной сети и проверка ошибки прогноза на контрольной выборке. Если значение ошибки находится в допустимых пределах, то задача считается решенной, и обученная нейронная сеть допускается к дальнейшему практическому применению.

Исторические данные метеорологических и гидрологических данных за 2005-2006 годы (месячное количество осадков, месячное испарение и месячный уровень воды) были использованы для нейросетевого моделирования в качестве входных переменных и ежемесячного притока воды в качестве выходных данных, чтобы оценить эффективность этого метода при прогнозировании притока воды на плотине ГЭС Кока (Эфиопия). Первоначально данные были предварительно обработаны путем устранения шума и нормализации данных. Для повышения производительности моделей в процессе обучения был использован алгоритм оптимизации, позволяющий минимизировать значение потерь или ошибку сети путем итеративного обновления весов сети на основе обучающих данных. Тип функции оптимизации ADAM был выбран, поскольку он является сильным и широко используется в последнее время для повышения производительности нейронной сети [14]. В этой статье было проведено предсказание притока с использованием метода ANN, основанного на многослойном персептроне (MLP). Модели были написаны на языке программирования python с использованием передаточной функции RELU и различных архитектур из-за отсутствия общего правила, которое было бы надежным для определения количества узлов и уровней в сети (рис. 6).

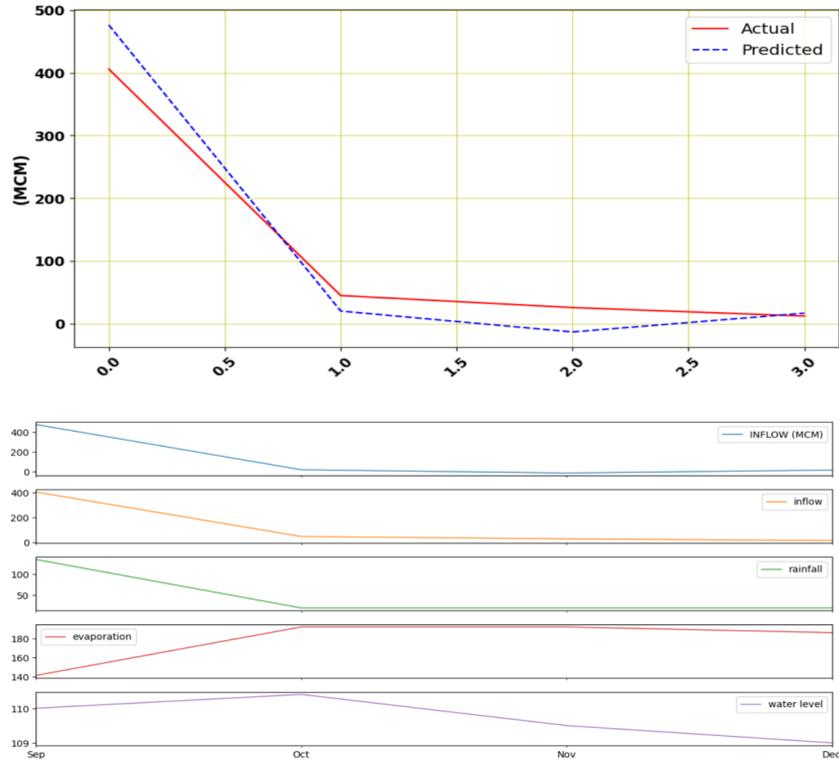
На графиках показаны тенденции, которые описывают взаимосвязь между прогнозируемыми и фактическими значениями притока воды за четыре месяца (сентябрь-декабрь).

Производительность каждой модели (a-d) оценивается с использованием среднеквадратичной ошибки (MSE) и коэффициента эффективности (R²), которые являются одними из наиболее часто используемых статистических методов в гидрологическом моделировании. Эти методы могут измерить, насколько хорошо регрессия соответствует данным. Уравнения 7 и 8, используемые для расчета MSE и R² соответственно, приведены ниже:

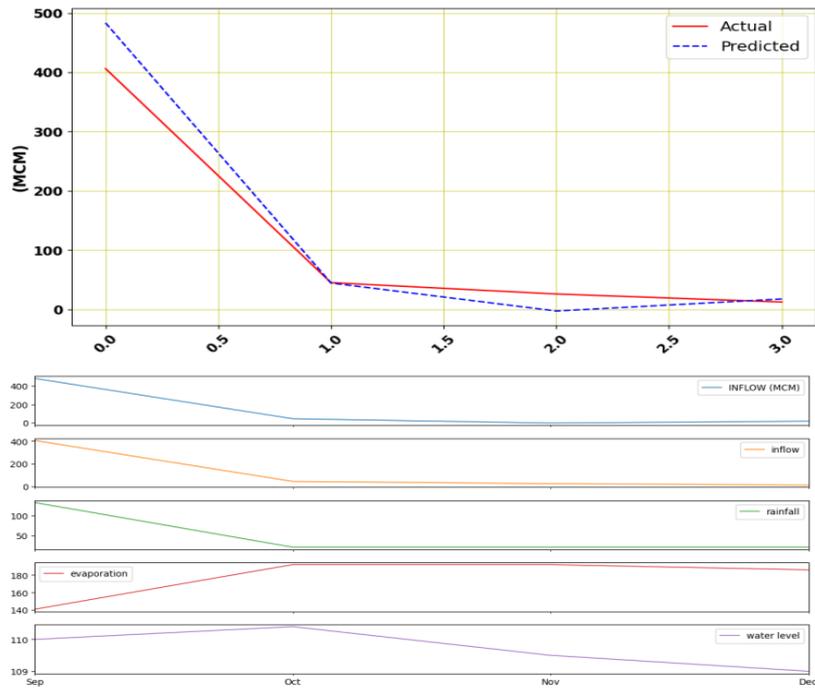
$$MSE = \frac{\sum_{i=0}^n (y_i - y_{io})^2}{n} \quad (7)$$

$$R^2 = \left(\sum_{i=1}^n (y_{io} - y_{mean})^2 \right) - \left(\sum_{i=1}^n (y_i - y_{io})^2 \right) / \left(\sum_{i=1}^n (y_{io} - y_{mean})^2 \right), \quad (8)$$

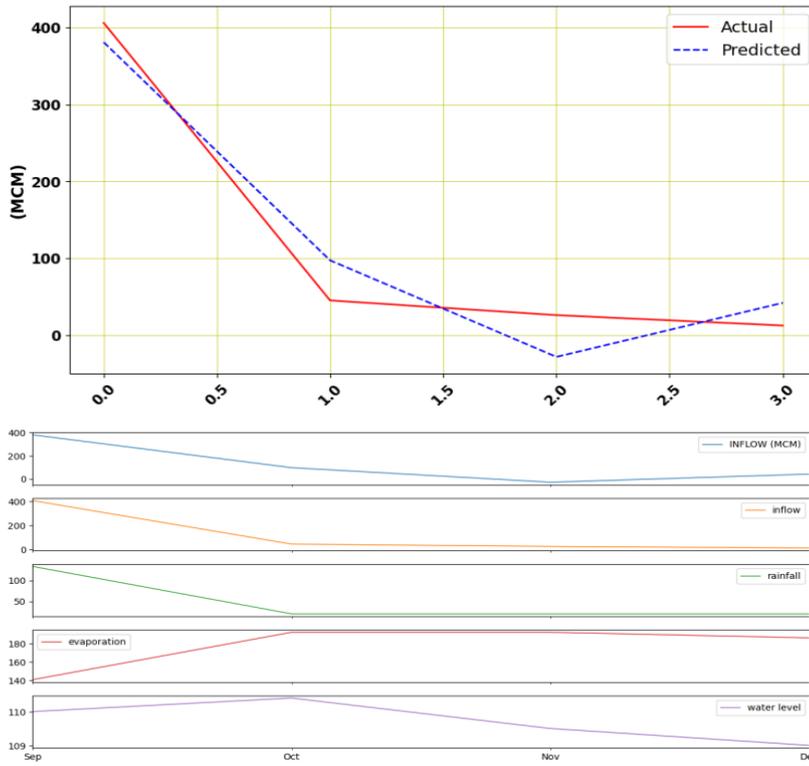
где y_i и y_{io} – прогнозируемые и фактические значения выходных данных соответственно, $mean$ – среднее значение фактического значения, а n – общее количество наблюдений. Минимальная ошибка относится к достоверности производительности компьютерной модели. Значение R^2 находится в диапазоне от 0 до 1. Как только коэффициент $R^2=1$, модель совершенна, но если он равен 0,5 или ниже, модель неудовлетворительная. Нулевое значение MSE означает идеальную модель [15].



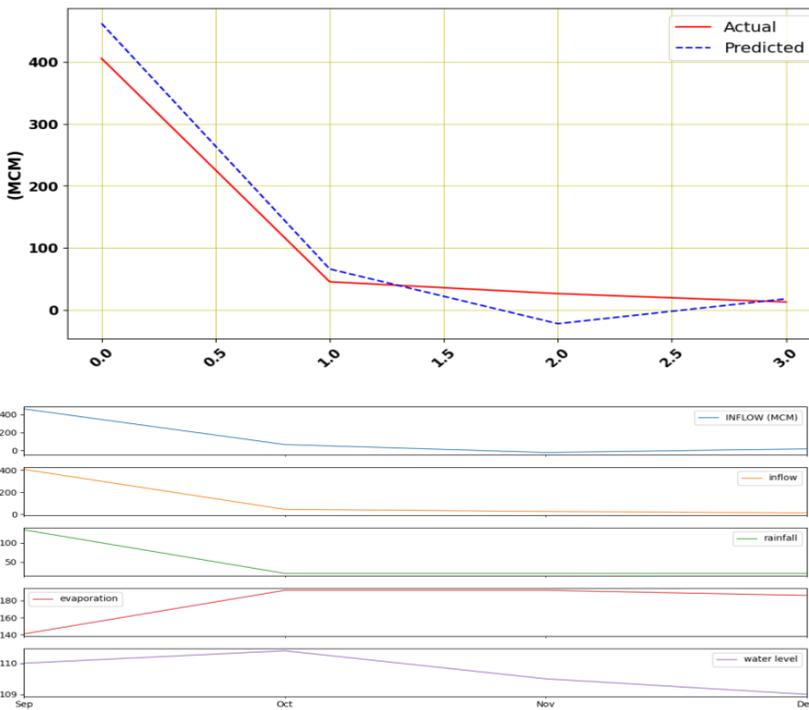
a)



b)



c)



d)

Рис. 6. Многослойные модели перцептронов (a-d) Fig. 6. Multilayer perceptron models (a-d)

*Источник: Составлено авторами Source: compiled by the author.

В данной статье была использована структура из 4 моделей, включая один входной слой, один скрытый слой с разным числом нейронов и один выходной слой. Во входном слое было установлено 3 нейрона для каждой модели. Обучающий набор данных, составляющий 80% от общего объема данных, использовался для настройки весовых коэффициентов нейронных сетей. В соответствии как со значениями MSE, так и R2, представленными в таблице 2 линии тренда объясняют более 90% вариаций в данных, что означает, что прогнозирование очень хорошее. Модель D из шести нейронов в скрытом слое является лучшей среди других моделей и может

рассматриваться как идеальная модель. Другими словами, прогнозируемые значения притока соответствуют целевым значениям и поэтому валидность моделей для прогнозирования расхода доказана.

Таблица 2

Модели искусственных нейронных сетей, рассмотренные в исследовании
Models of artificial neural networks considered in the study

Модели	Тип сети	Передающая функция	Входных функций нет	Архитектура	Оптимизатор	MSE	R2
A	MLP	RELU	3	3-9-1	ADAM	1769,400879	0,934316
B	MLP	RELU	3	3-8-1	ADAM	1701,245239	0,936846
C	MLP	RELU	3	3-7-1	ADAM	1792,263062	0,933467
D	MLP	RELU	3	3-6-1	ADAM	1499,834351	0,944323

*Источник: Составлено авторами Source: compiled by the author.

В этом исследовании многослойные персептронные нейронные сети были использованы в качестве подхода для прогнозирования притока воды с использованием гидрологических и метеорологических данных с различных измерительных станций на водоразделе Кока-ГЭС. Важным шагом является предварительная обработка собранных необработанных данных перед построением сети. MLP подходит и широко используется в гидрологических приложениях, подобных этому исследованию. Большая часть данных была собрана для обучения моделей. Различные архитектуры были определены на основе итераций. Статистические методы R2 и MSE успешно доказали валидность моделей.

Естественно, что для повышения точности моделирования процесса прогнозирования притока воды в водохранилища с помощью нейронных сетей необходимо гораздо большее количество обучающих выборок.

Литература

1. Чаби, Амеди и др. «Оценка водного баланса Илаукоского водохранилища Уэме на водосборе Саве (Бенин, Западная Африка)» (2019).
2. Чжоу, Уган и др. «Оценка притока пласта при значительном боковом притоке с использованием метода сопряженных уравнений». *Journal of Hydrology* 574 (2019): 360-372.
3. Сон, Чон-Хун, Ёнгу Хер и Мун-Сон Кан. «Оценка резервуара. Приток и отток по данным наблюдений за уровнем воды с использованием экспертных знаний: работа с некорректным уравнением водного баланса при управлении водохранилищами». *Water Resources Research* 58.4 (2022): e2020WR028183.
4. Голоб Р., Штокель Т., Гргич Д. Прогнозирование притока воды на основе нейросетей // *Инженерная практика управления*. – 1998. – Т. 6. – №. 5. – С. 593-600.
5. Гураара, Микияс, Аддис Бекеле и Селамавит Гебейеху. «Гидрологические данные Система обработки и управления» - *Международный журнал инженерных исследований и технологий (IJERT)* ISSN: 2278-0181- Том 9, выпуск 05, май 2020 г.
6. Хайкин С. *Нейронные сети: MacMillan College Publ //Co., Нью-Йорк*. – 1994.
7. ТЕМИЗ, Темель, Юнус ДАМЛА и Эрдинч КЕСКИН. «Сравнение различных методов искусственных нейронных сетей при определении емкости резервуара». *Журнал науки и технологий Университета Эрзинджан* 15.1 (2022): 183-203.
8. Кескенлер, Мустафа Фуркан и Эйюп Фахри Кескенлер. «Из прошлого в настоящее искусственные нейронные сети и их история». *Takvim-i Vekayi* 5.2 (2017): 8-18.
9. Шилин, А. Н. Применение искусственных нейронных сетей для прогнозирования аварий воздушных линий электропередачи в гололёдный период / А. Н. Шилин, А. А. Шилин, С. С. Дементьев // *Электро. Электротехника, электроэнергетика, электротехническая промышленность*. – 2016. – № 2. – С. 15-21. – EDN VVKJSP.
10. Хайкин С. *Нейронные сети: полный курс / под ред. Н.Н. Куссуль; пер. с англ. Н.Н. Куссуль, А.А. Шелестова*. 2-е изд., испр. М.: Вильямс, 2006. 1104 с.
11. Бородин, Георгий Дмитриевич. "Краткий обзор и классификация искусственных нейронных сетей. «Известия Тульского государственного университета. Технические науки 11 (2021): 45-53.
12. Осовский, Станислав. *Нейронные сети для обработки информации. Финансы и статистика*, 2004.
13. Ясницкий, Леонид Нахимович. «Введение в искусственный интеллект» (2008).
14. Джаис, Имран Хан Мохд, Амелия Ритахани Исмаил и Сайед Камрун Ниса.

«Адамалгоритм оптимизации для широкой и глубокой нейронной сети». Инженерия знаний и наука о данных 2.1 (2019): 41-46.

15. Чикко, Давиде, Маттейс Дж. Уорренс и Джузеппе Юрман. «Коэффициент детерминации R-квадрат более информативен, чем SMAPE, MAE, MAPE, MSE и RMSE при оценке регрессионного анализа». PeerJ Computer Science 7 (2021): e.623.

Авторы публикации

Шилин Александр Николаевич – д-р техн. наук, профессор кафедры «Электротехника», ВолгГТУ. *ORCID: <http://orcid.org/0009-0002-6416-4357> e-mail: eltech@vstu.ru*

Богале Мулуken Асамнеу – аспирант кафедры «Электротехника», ВолгГТУ. *ORCID: <https://orcid.org/0009-0009-4389-815X> e-mail: mulem2as1977@gmail.com*

Коновалова Людмила Александровна – ст. преподаватель кафедры «Электротехника», ВолгГТУ. *ORCID: <https://orcid.org/0009-0004-3844-574X> e-mail: mila27121989@mail.ru*

References

1. Chabi, Amedée, et al. "Assessment of Water Balance in the Ilauko Reservoir of the Ouémé at Savè Catchment (Benin, West Africa)." (2019).
2. Zhou, Wugang, et al. "Estimation of reservoir inflow with significant lateral inflow by using the adjoint equation method." Journal of Hydrology 574 (2019): 360-372.
3. Song, Jung-Hun, Younggu Her, and Moon-Seong Kang. "Estimating Reservoir Inflow and Outflow from Water Level Observations Using Expert Knowledge: Dealing With an Ill-Posed Water Balance Equation in Reservoir Management." Water Resources Research 58.4 (2022): e2020WR028183.
4. Golob R., Shtokel T., Grgic D. Forecasting water inflow based on neural networks // Engineering management practice. – 1998. – Т. 6. – No. 5. – pp. 593-600.
5. Gurara, Mikiyas, Addis Bekele, and Selamawit Gebeyehu. "Hydrological Data Processing and Management System."- International Journal of Engineering Research & Technology (IJERT) ISSN: 2278-0181- Vol. 9 Issue 05, May-2020
6. Haykin S. Neural networks: MacMillan College Publ //Co., New York. – 1994.
7. TEMİZ, Temel, Yunus DAMLA, and Erdiñç KESKİN. "Comparison of Different Artificial Neural Network Methods in Determining Reservoir Capacity." Erzincan University Journal of Science and Technology 15.1 (2022): 183-203.
8. Keskenler M. F., Keskenler E. F. From past to present artificial neural networks and history //Takvim-i Vekayi. – 2017. – Т. 5. – №. 2. – С. 8-18.
9. Shilin, A. N. Application of artificial neural networks for forecasting accidents of overhead power lines during the icy period / A. N. Shilin, A. A. Shilin, S. S. Dementyev // Elektro. Electrical engineering, electrical power engineering, electrical industry. – 2016. – No. 2. – P. 15-21. – EDN VVKJSP.
10. Khaikin S. Neural networks: a complete course / ed. N.N. Kussul; lane from English N.N. Kussul, A.A. Shelestova. 2nd ed., rev. M.: Williams, 2006. 1104 p.
11. Borodin, Georgy Dmitrievich. «Brief overview and classification artificial neural Networks» News of Tula State University. Technical Sciences 11 (2021): 45-53
12. Osovsky, Stanislav. Neural networks for information processing. Finance and statistics, 2004.
13. Yasnitsky, Leonid Nakhimovich. "Introduction to Artificial Intelligence." (2008).
14. Jais, Imran Khan Mohd, Amelia Ritahani Ismail, and Syed Qamrun Nisa. "Adam optimization algorithm for wide and deep neural network." Knowledge Engineering and Data Science 2.1 (2019): 41-46.
15. Chicco, Davide, Matthijs J. Warrens, and Giuseppe Jurman. "The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation." PeerJ Computer Science 7 (2021): e623.

Authors of the publication

Alexander N. Shilin – Volgograd State Technical University, Volgograd, Russia. *ORCID: <http://orcid.org/0009-0002-6416-4357> e-mail: eltech@vstu.ru*

Bogale Muluken Asamneu – Volgograd State Technical University, Volgograd, Russia. *ORCID: <https://orcid.org/0009-0009-4389-815X> e-mail: mulem2as1977@gmail.com*

Lyudmila A. Konvalova – Volgograd State Technical University, Volgograd, Russia.
ORCID: <https://orcid.org/0009-0004-3844-574X> e-mail: mila27121989@mail.ru

Шифр научной специальности: 2.4.6. Теоретическая и прикладная теплотехника

Получено ***16.02.2024 г.***

Отредактировано ***27.02.2024 г.***

Принято ***07.03.2024 г.***