

УДК 621.22
DOI: 10.35211/2500-0586-2025-2-51-6-15

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

**МОДЕЛЬ ИСКУССТВЕННОЙ НЕЙРОСЕТИ
ДЛЯ ПРОГНОЗИРОВАНИЯ ОБЪЕМА ВОДЫ В ВОДОХРАНИЛИЩЕ**

Волгоградский государственный технический университет
eltech@vstu.ru, mila27121989@mail.ru, mulem2as1977@gmail.com

Автор, ответственный за переписку:
Людмила Александровна Коновалова, mila27121989@mail.ru

Прогнозирование объема воды в водохранилищах критически важно для безопасной эксплуатации гидроэлектростанций и эффективного управления ресурсами. Поскольку эта задача нелинейна, в исследовании применен метод искусственной нейронной сети – многослойный персептрон (MLP). Были разработаны различные архитектуры моделей с вариативным числом нейронов в скрытом слое, учитывая отсутствие строгих правил их выбора. Точность моделей оценена через сравнение прогнозируемого и фактического притока воды с использованием статистических метрик, широко применяемых в гидрологическом моделировании. Результаты демонстрируют успешное предсказание паводкового стока в водохранилище, подтверждая эффективность подхода.

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

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

**AN ARTIFICIAL NEURAL NETWORK MODEL FOR PREDICTING
THE VOLUME OF WATER IN A RESERVOIR**

Volgograd State Technical University

Forecasting the water volume in reservoirs is critical for the safe operation of hydroelectric power plants and efficient resource management. Since this problem is nonlinear, the study applies the artificial neural network method - multilayer perceptron (MLP). Different model architectures with a variable number of neurons in the hidden layer were developed, given the lack of strict rules for their selection. The accuracy of the models is assessed by comparing the predicted and actual water inflow using statistical metrics, widely used in hydrological modeling. The results demonstrate successful prediction of flood runoff in the reservoir, confirming the effectiveness of the approach. Keywords: electric charging station, electric vehicle, modernization, infrastructure.

Keywords: inflow into the reservoir, forecasting, artificial neural network, multilayer perceptron, hydroelectric power plant

Введение

Обеспечение водными ресурсами – ключевая глобальная проблема, усугубляемая изменением климата. Водохранилища ГЭС играют важную роль в распределении водных ресурсов, однако управление ими требует контроля баланса притока и расхода, зависящих от метеорологических условий, потребления и экологических требований. Прогнозирование при-

тока критически важно для предотвращения наводнений и планирования энергопотребления. Точный прогноз осложняется множеством случайных факторов, что требует применения специализированных методов, таких как нейронные сети.

Искусственные нейронные сети (ИНС) [1] – математические модели, имитирующие работу биологических нейронов. Их нелинейность

и способность к обобщению позволяют эффективно обрабатывать данные даже при отклонениях от обучающих выборок. Интеграция ИНС в информационно-измерительные системы (с датчиками и управляющими ЭВМ) повышает точность прогнозов притока воды, обеспечивая устойчивое управление ресурсами.

Система автоматического регулирования уровня воды в водохранилище ГЭС

Для решения этой проблемы была разработана информационно-измерительная система (ИИС) регулирования уровня воды в водохранилище ГЭС [2; 3], представленная на рис. 1. ИИС содержит датчики основных факторов, влияющих на уровень воды. Это две группы: климатические и водные. Климатические датчики: температуры воздуха 1, уровня осадков 2, уровня снежного покрова 3 (в случае использования в северных широтах), влагосодержания почв 4, глубины промерзания 5, которые установлены на берегу реки. Водные датчики: испарения воды 6, находящиеся на поверхности воды, уровня воды 7, расхода притока 8 и водопотребления 9, размещенные под водой. Все датчики, климатические и водные, размещены по обеим сторонам плотины. Датчики 1–9 соединены с управляющей ЭВМ 13, содержащей нейронный процессор 14, который формирует прогноз уровня воды и приток воды в водохранилище и на основании этой информации планирует расход воды по потребителям с учетом их приоритетов и риска наводнения, и интерфейс 15. ЭВМ 13 осуществляет управление затвором водосброса 10 через электропривод 12.

Система автоматического регулирования уровня воды в водохранилище ГЭС реализуется следующим образом. Датчики ИИС 1–9 формируют массив данных для передачи на ЭВМ 13 с нейронным процессором 14, который симулирует искусственную нейронную сеть, обученную на прогнозирование с заданным горизонтом в N дней или месяцев уровня воды и притока воды. Нейронный процессор 14 выполняет прогноз, фактически аппроксимируя функции изменения уровня воды и притока воды в водохранилище на основе информации, полученной по каналам передачи данных от датчиков 1–9.

Нейронный процессор 14 работает в режимах обучения ИНС и опроса обученной ИНС для прогнозирования значения упомянутой величины и переобучения ИНС после сравнения спрогнозированного ею значения с реально за-

фиксированным значением. В режимах обучения и переобучения (повторного обучения) ЭВМ 13 с помощью программы обрабатывает массивы информации, сравнивая входные данные с реально зарегистрированными значениями уровня воды и притока воды в водохранилище. Полученные таким способом массивы именуются в теории нейроинформатики как «учебники» (переобучение подразумевает постоянное обновление «учебников» с течением времени). Далее с использованием стандартных алгоритмов (например, алгоритма, основанного на методе обратного распространения ошибки) нейронный процессор 14 выполняет обучение, то есть корректировку весов синаптических связей ИНС, после чего по достижении допустимой погрешности (непрерывно сравнивая выходное значение, отраженное в «учебнике», с тем значением, которое сгенерировала ИНС) прекращает обучение. После этого нейронный процессор 14 выполняет на основе текущих входных данных опрос обученной ИНС на предмет будущих значений уровня воды и притока воды в водохранилище, то есть осуществляет прогнозирование с заданным упреждением в N дней или месяцев. По мере того, как регистрируются реальные значения этих прогнозируемых величин (то есть по мере приближения к дате прогноза), возникает возможность сравнения реальных и сгенерированных ИНС значений, а также обновления «учебника» и переобучения ИНС.

При прогнозе, сформированном нейронным процессором 14, согласно которому через N дней или месяцев уровень воды в водохранилище может превысить форсированный подпорный уровень (ФПУ), а приток в водохранилище превысит максимальный расход воды через турбины, ЭВМ 13 осуществляет расчет поэтапного, плавного (по каждому из N дней до паводка) нарастания сработки (сработка водохранилища – понижение уровня воды при использовании накопленного ее запаса в большем количестве, чем поступает в водоем с водосброса) воды, то есть решая задачу определения водно-энергетического и водно-хозяйственного режима сработки-наполнения водохранилища с упреждением. После этого ЭВМ 13 с учетом средней погрешности прогнозирования, выполненного нейронным процессором 14, подает соответствующую команду на электропривод 12 затвора водосброса 10 с целью увеличения пропуска воды и увеличения мощности, гене-

рируемой электростанцией. На каждый из последующих дней до прогнозируемого паводка искусственная нейронная сеть 14 сдвигает окно прогнозирования также на один день (месяц) и выполняет новый (уточненный) прогноз указанных выше двух величин, корректируя предыдущий план сработки воды до паводка. В соответствии с откорректированным планом

ЭВМ 13 подает очередную команду на электропривод 12 затвора 10. Таким образом, реализуется плавное регулирование уровня воды в водохранилище до паводка во избежание резких сбросов воды в процессе паводка. Уменьшение сбросов воды мимо турбин (холостых сбросов) приводит к росту генерируемой электроэнергии.




Рис. 1. Система автоматического регулирования уровня воды в водохранилище ГЭС

Во время паводка система регулирования уровня воды водохранилища работает в усиленном режиме. Агрегаты в верхнем бьефе водохранилища ГЭС работают аналогично агрегатам в нижнем бьефе. Предлагаемая система контроля уровня воды осуществляет мониторинг уровня воды в водохранилище посредством датчиков 1–9. Полученные данные обрабатываются ЭВМ 13, которая использует заложенный в ней алгоритм для определения мгновенной v_i (в i -й момент времени) и среднеквадратичной v_{cp} скоростей изменения уровня воды в водохранилище. Уровни воды вычисляются по формулам [4]:

$$v_{cp} = \sqrt{\frac{v_i^2 + v_{i+1}^2 + \dots + v_n^2}{n}}, \quad (1)$$

$$v_i = \lim_{\Delta t_i \rightarrow 0} \frac{\Delta x_i}{\Delta t_i},$$

где Δx_i – изменение уровня воды в водохранилище за промежуток времени Δt_i ; n – количество измерений.

Таким образом, ЭВМ 13, оснащенная нейронным процессором 14, выполняет функции обработки данных, рассчитывает скорость из-

менения уровня воды в водохранилище и принимает решение о регулировании затвора 10. Для этого используется значение среднеквадратичной скорости изменения уровня воды, которая определяет скорость открытия/закрытия затвора. При большом значении среднеквадратичной скорости изменения уровня воды выдержка по времени будет меньше, а скорость открытия/закрытия затвора будет выше. Наряду с этим использование значения скорости обеспечивает возможность оперативного управления затвором. Если уровень воды превышает оптимальную наивысшую отметку (НПУ) водной поверхности водохранилища, система переходит в режим повышенной готовности и проверяет состояние затвора 10. После анализа данных о среднеквадратичной скорости изменения уровня воды в водохранилище, вычисленной по показателям датчиков в бьефах, система определяет необходимую скорость открытия затвора 10 и время задержки для исключения случайного или слишком частого срабатывания системы регулирования. Вслед за этим система принимает решение об открытии

затвора 10 с определенными ранее параметрами. На протяжении регулирования система непрерывно осуществляет мониторинг параметров: уровня воды в разных точках, баланс прихода и расхода воды, исправности элементов системы регулирования. Когда система устанавливает снижение уровня воды ниже НПУ, осуществляется проверка возможности закрытия затвора 10, при которой система регулирования определяет наличие или отсутствие паводка, сравнивая данные о средней скорости изменения уровня воды, вычисленные по показаниям датчиков в бьефах. Если система в момент паводка обнаруживает угрозу для прибрежных территорий, она автоматически открывает затвор 10 на максимальную величину для быстрого сброса излишнего количества воды из водохранилища. Если система определяет, что открытие затвора 10 на максимальную величину необходимо, чтобы не привести к негативным последствиям, например, к разрушению дамбы или подтоплению населенных пунктов, то система может принять решение о постепенном открытии затвора 10 с задержкой времени. В процессе работы система непрерывно производит мониторинг положения

затвора 10, уровня воды в разных точках и исправности элементов системы регулирования. При неисправности какого-либо элемента системы регулирования, система автоматически переходит в режим аварийной остановки, чтобы предотвратить возможные аварии и катастрофы. Взаимодействие оператора с предлагаемой системой для возможности внесения корректировок в технологический процесс регулирования, проведения диагностики оборудования и наблюдения за контролируемой системой величинами осуществляется через ЭВМ 13.

Для настройки ИНС использованы данные ГЭС «Кока» (Эфиопия). На основе гидрологических параметров и притока воды (метеоданные за 2012–2013 гг., табл. 1) проведено обучение и тестирование моделей с вариативным числом узлов. Анализ водного баланса выявил влияние осадков, испарения и уровня водохранилища на приток. Данные разделены на обучающую (80 % – 20 месяцев) и тестовую (20 % – 4 месяца) выборки. Результаты подтвердили высокую точность прогноза притока, что демонстрирует эффективность ИНС для управления ресурсами.

Таблица 1

**Информация о входных и выходных переменных
в соответствии с наблюдениями метеостанции**

Дата	Испарение, мм	Осадки, мм	Уровень воды, м	Приток воды, млн. куб. м
	x_1	x_2	x_3	y
01/01/2012	204,6	28,7	109	10,65
02/01/2012	134	20	107,9	6,23
03/01/2012	210,8	20	107	27,1
04/01/2012	198	12,23	106	22,17
05/01/2012	189,1	14,36	105	89,73
06/01/2012	171	93,1	104,5	68,89
07/01/2012	161,2	251,9	106	377,3
08/01/2012	151,9	251,9	108,5	893,49
09/01/2012	141	133,7	110,7	267,38
10/01/2012	192	20	110,5	43,94
11/01/2012	192	20	109,7	24,6
12/01/2012	186	20	109	11,83
01/01/2013	204,6	28,7	108	8,65
02/01/2013	134	20	107,5	7,66
03/01/2013	210,8	20	106,5	23,49
04/01/2013	198	12,23	105,5	44,59
05/01/2013	189,1	14,36	105	39

Окончание табл. 1

Дата	Испарение, мм	Осадки, мм	Уровень воды, м	Приток воды, млн. куб. м
	x_1	x_2	x_3	y
06/01/2013	171	93,1	104	68,63
07/01/2013	161,2	251,9	107	482,06
08/01/2013	151,9	251,9	109,5	833,89
09/01/2013	141	133,7	110	405,95
10/01/2013	192	20	110,4	45,13
11/01/2013	192	20	109,5	25,97
12/01/2013	186	20	109	12,48

Программа Python [5] автоматически выполнила нормализацию данных в соответствии с требованиями к их формату на входе нейронной сети (см. рис. 2).

```
array([[0.00498163, 0.0687195, 0.9192709, 0.7462683 ],
       [0.02352186, 0.03241958, 0.0000001, 0.5820894 ],
       [0.01796542, 0.03241958, 1.0000001, 0.44776154],
       [0.01796542, 0.03241958, 0.8333334, 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, 1.000001 ],
       [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, 0.0, 0.5223875 ],
       [0.01945315, 0.03241958, 1.0000001, 0.3731346 ],
       [0.04323423, 0.0, 0.8333334, 0.22388077],
       [0.03693393, 0.00888722, 0.7174479, 0.14925385],
       [0.07032888, 0.3374223, 0.48177087, 0.0 ],
       [0.53629154, 1.0, 0.35416663, 0.44776154],
       [0.932827, 1.0, 0.23307288, 0.8208952 ]], dtype=float32)
```

Рис. 2. Структурный синтез нейронной сети

При проектировании нейронной сети использована формула, являющаяся следствием теорем Арнольда – Колмогорова – Хехта-Нильсена, которая определяет необходимое число синаптических весов. С помощью этой форму-

лы определено минимальное число нейронов, необходимых для приближения любой непрерывной функции на заданном компакте с заданной точностью. Формула имеет следующий вид [6]:

$$\frac{N_y \cdot Q}{1 + \log_2 Q} \leq N_w \leq N_y \left(\frac{Q}{N_x} + 1 \right) (N_x + N_y + 1) + N_y, \quad (2)$$

где N_y – размерность выходного сигнала; Q – число элементов обучающей выборки; N_w – необходимое число синаптических весов; N_x – размерность входного сигнала. С помощью этой формулы получены следующие результаты: $3,76 \leq N_w \leq 37,5$. При этом число нейронов скрытого слоя двухслойного персептрона определяется формулой:

$$N = \frac{N_w}{N_x + N_y}. \quad (3)$$

С помощью вышеприведенных формул при $N_x = 3$, $N_y = 1$, $Q = 20$ получены минимальные

и максимальные значения $N = 1$ и $N = 9$. Далее определена 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. Использованы функция потерь средней абсолютной ошибки и эффективная версия Adam для стохастического градиентного спуска. Модель рассчитана на 295 тренировочных периодах.

Обучение нейронной сети является одним из основных этапов в разработке и использовании таких сетей. На этом этапе нейронная сеть

настраивается на конкретную задачу путем обучения на обучающих данных. Процесс 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 нормализация, 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 adam; повторение процесса. Весь процесс 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, например 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. TensorFlow обрабатывает обратное распространение автоматически, поэтому глубокое понимание алгоритма не требуется.

Важной частью построения модели является разделение данных для обучения и тестирования. Это гарантирует, что получена модель, ко-

торая может обобщать за пределами обучающих данных, и что производительность и выходные данные будут статистически значимыми.

Для прогноза притока воды на плотине Кокинской ГЭС были использованы метеорологические и гидрологические данные за 2012–2013 гг., которые были предварительно обработаны путем удаления шума и нормализации данных (рис. 2). Прогнозирование осуществлялось методом ИНС на основе многослойного перцептрона (MLP), написанного на языке программирования Python с использованием передаточной функции RELU и различных архитектур.

Предлагаемая нейронная сеть (персептрон) обучена прогнозировать приток для следующего временного шага на основе входных характеристик текущего временного шага. Это означает, что для любого заданного входного сигнала сеть выдает прогноз всего на один временной шаг вперед. Входные данные нейронной сети состоят из характеристик для одного временного шага, а выходные данные – это входные данные для следующего временного шага. Эта структура не меняется в зависимости от желаемого горизонта прогнозирования. Сеть всегда обрабатывает данные одного временного шага, чтобы предсказать ближайший следующий временной шаг. Обычно для небольшого набора данных (ограниченных данных) лучше подходит модель прогнозирования с одним временным шагом.

Обучаем нашу модель на данных за 20 месяцев и тестируем модель на данных за 4 месяца. Поскольку базовая модель может прогнозировать только на один шаг вперед, используем метод, называемый рекурсивным прогнозированием, чтобы расширить прогнозы на будущее на несколько временных шагов.

Персептрон (или нейронная сеть) изначально предназначен для прогнозирования следующего временного шага на основе текущих входных характеристик. Он, по своей сути, не учитывает различные горизонты прогнозирования. Используя рекурсивное прогнозирование, расширяем прогнозы на несколько временных шагов, итеративно корректируя входные данные на основе предыдущих прогнозов, чтобы получить прогнозы для различных горизонтов.

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.

Производительность каждой модели (A–D) оценивается с использованием среднеквадратичной ошибки (MSE) и коэффициента эффективности (R^2), которые являются одними из наиболее часто используемых статистических

методов в гидрологическом моделировании. Эти методы могут измерить, насколько хорошо регрессия соответствует данным. Уравнения (4) и (5), используемые для расчета MSE и R^2 соответственно, приведены ниже:

$$MSE = \frac{\sum_{i=0}^n (y_i - y_{io})^2}{n} \quad (4)$$

$$R^2 = \left(\sum_{i=1}^n (y_{io} - y_{mean})^2 \right) - \left(\sum_{i=1}^n (y_i - y_{io})^2 \right) / \left(\sum_{i=1}^n (y_{io} - y_{mean})^2 \right), \quad (5)$$

где y_i и y_{io} – прогнозируемые и фактические значения выходных данных соответственно, y_{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 [7].

В данной статье была использована структура из четырех 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 R^2 , представленными в табл. 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. Таким образом, прогнозируемые значения притока соответствуют целевым значениям, и поэтому валидность моделей для прогнозирования расхода доказана.

Таблица 2

Модели искусственных нейронных сетей, рассмотренные в исследовании

Модели	Тип сети	Функция активации	Архитектура	Оптимизатор	MSE	R ²
A	MLP	RELU	3-9-1	ADAM	0,001769	0,934316
B	MLP	RELU	3-8-1	ADAM	0.001701	0,936846
C	MLP	RELU	3-7-1	ADAM	0.001792	0,933467
D	MLP	RELU	3-6-1	ADAM	0.001499	0,944323

Выводы

В этом исследовании многослойные персептронные нейронные сети были использованы 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 оценки MSE и R^2 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.

На графиках (рис. 3) показаны тенденции, которые описывают взаимосвязь между прогнозируемыми и фактическими значениями притока воды за четыре месяца (сентябрь – декабрь).






Рис. 3. Многослойные модели персептронов (A–D) (см. также с. 14)

(C)



(D)





Рис. 3. Окончание

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. *Хайкин, С.* Нейронные сети: полный курс / С. Хайкин; под ред. Н. Н. Куссуль; пер. с англ. Н. Н. Куссуль, А. А. Шелестова. – 2-е изд., испр. – М.: Вильямс, 2006. – 1104 с.
2. Пат. 2820563 Российская Федерация, МПК G05D 9/12. Способ автоматического регулирования уровня воды в водохранилище ГЭС / А. Н. Шилин, С. С. Дементьев, Л. А. Коновалова, М. А. Богале; заявитель ФГБОУ ВО ВолГТУ. – № 2820563; заявл. 20.05.2023; опубл. 15.01.2024. – 12 с.
3. Полез. модель 226828 Российская Федерация, МПК G01F 23/76. Плавающий измеритель испарения открытой воды / А. Н. Шилин, Л. А. Коновалова, М. А. Богале; заявитель ФГБОУ ВО ВолГТУ. – № 226828; заявл. 10.03.2023; опубл. 25.12.2024. – 8 с.
4. *Козырев, А. В.* Система автоматического регулирования уровня воды в водохранилище ГЭС: пат. РФ № 2629456 / А. В. Козырев, А. В. Лашин, В. А. Семенов, В. И. Турунин; заявл. 20.05.2016; опубл. 29.08.2017. – Бюл. № 24. – 9 с.
5. *Ильичев, В. Ю.* Создание программ на языке Python для исследования множества Мандельброта / В. Ю. Ильичев, А. В. Качурин // E-Scio. – 2021. – № 5 (56). – С. 362–371.
6. *Ясницкий, Л. Н.* Введение в искусственный интеллект / Л. Н. Ясницкий. – М.: Наука, 2008. – 320 с.
7. *Chicco, D.* The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation / D. Chicco, M. J. Warrens, G. Jurman // PeerJ Computer Science. – 2021. – Vol. 7. – P. e623. – DOI: 10.7717/peerj-cs.623.