

Идентификация зон поглощений бурового раствора при проектировании скважин средствами искусственного интеллекта

С.А. Бурлов, Д.В. Машков, К.А. Шиповский, В.А. Капитонов, М.Е. Коваль

Аннотация — При бурении скважин наличие геологических осложнений может приводить к увеличению непроизводительного времени. Отталкиваясь от известных методов решения задач с использованием моделей искусственного интеллекта для автоматизации анализа данных, авторами рассмотрены подходы по поиску интервалов поглощений бурового раствора на стадии проектирования строительства скважин. Представлены результаты сравнительных расчётов с применением метода ближайших соседей, логистической регрессии, дерева решений, нейронной сети по данным бурения на Западном куполе Южно-Орловского месторождения, имеющего рифовое строение. Выбор объекта обусловлен наличием достаточного объёма статистических данных по ранее пробуренным скважинам. Уникальность геологического строения месторождений рифового типа заключается в том, что при прохождении траектории скважин по ядру карбонатного массива возникает меньше поглощений, чем при бурении в шлейфовых зонах. Приведены результаты тестирования разработанного подхода, отмечены преимущества и недостатки каждого метода. Сделан вывод, что применение программного обеспечения на основе алгоритмов машинного обучения позволяет сократить трудозатраты инженеров и повысить эффективность проектных работ.

Ключевые слова — искусственный интеллект, методы машинного обучения, бурение, рифовый массив, нейронные сети, поглощения, анализ данных.

I. ВВЕДЕНИЕ

При бурении скважин в сложных геологических условиях возможно появление непроизводительного времени, связанного с ликвидацией поглощений, проработками ствола скважины по причине плохого выноса выбуренной породы, обрушения стенок

скважины или других осложнений. Для снижения геологических рисков на этапе проектных работ выполняется анализ данных по ранее пробуренным скважинам. Традиционный подход к выявлению зон осложнений основан на ручном сборе информации по ранее пробуренным скважинам, её консолидации и прогнозирования интервалов возможных осложнений. Работа с большим объёмом данных требует значительных временных ресурсов. Несмотря на большие трудозатраты, также возможно допущение ошибок, в результате которых возникают неточности в прогнозах, что увеличивает риски при бурении скважин.

Применение методов машинного обучения охватывает широкий спектр практических вопросов бурения и смежных задач [1, 2]. В статьях [3, 4] для прогнозирования наличия и интенсивности поглощений бурового раствора сопоставлены многослойный персептрон, радиально-базисная сеть (РБС) и карта Кохонена. Сделан вывод, что наибольшая эффективность достигнута гибридной нейронной сетью, в которой РБС обучалась с использованием алгоритма кластеризации на основе карты Кохонена. Позднее, на основе большого числа вычислительных экспериментов, авторы пришли к выводу, что наименьшую погрешность прогноза обеспечивает метод непараметрической регрессии [5].

Целью исследования, представленного в данной статье, является разработка и обоснование подхода к применению методов искусственного интеллекта для выявления зон осложнений при проектировании строительства скважин на примере поглощений бурового раствора (факта возникновения поглощений без учёта их интенсивности).

II. ПОЛУЧЕНИЕ ДАННЫХ И ОБУЧЕНИЕ МОДЕЛЕЙ

A. Исходные данные

В рамках первого этапа был выполнен сбор и анализ исходных геолого-технологических данных. Источником послужили информационные базы и отчеты по строительству скважин, реестры осложнений, журналы авторского надзора проектных организаций. Для оценки работоспособности создаваемых ИИ моделей был выбран Западный купол Южно-Орловского месторождения. Благодаря рифовому строению залежи и большому объёму статистических данных, Западный купол стал хорошим вариантом для исследования эффективности обнаружения интервалов

Статья получена 25 июня 2026.

С. А. Бурлов, Самарский филиал ООО «РН-Проектирование Добыча» (ОГ ПАО «НК «Роснефть»») (e-mail: Burlov.SA@yandex.ru)

Д. В. Машков, Обособленное подразделение Филиала ООО «РН-ГИР» в городе Уфе – БашНИПИнефть в г. Самаре (ОГ ПАО «НК «Роснефть»»)

К. А. Шиповский, к.т.н., Самарский филиал ООО «РН-Проектирование Добыча» (ОГ ПАО «НК «Роснефть»»), Самарский государственный технический университет

В. А. Капитонов, к.т.н., Самарский филиал ООО «РН-Проектирование Добыча» (ОГ ПАО «НК «Роснефть»»), Самарский государственный технический университет (e-mail: vibrancy@list.ru)

М. Е. Коваль, к.т.н., Самарский филиал ООО «РН-Проектирование Добыча» (ОГ ПАО «НК «Роснефть»»), Самарский государственный технический университет

поглощений с помощью ИИ.

В качестве исходных данных при проведении машинного обучения и создании моделей нейронных сетей выступала информация об интервалах осложнений по ранее пробуренным скважинам. Исходный набор данных для обработки представлял собой кортежи из семи элементов: координаты оси X и Y, абсолютная глубина текущего интервала скважины (DEPTH), наличие/отсутствие нефти (IS_OIL), номер горизонта (HORIZON), номер яруса (SECTION) и наличие/отсутствия осложнения (COMPLICATION) – здесь и далее в качестве анализируемых осложнений рассматривались только поглощения. Пример исходных данных для обучения модели представлен в таблице 1.

Таблица 1: Пример исходных данных до обработки

X	Y	DEPTH	IS_OIL
3264,74	278,62	2120	0
3264,74	278,62	2124	0

HORIZON	SECTION	COMPLICATION
19	5	0
19	5	1

В. Введение искусственных признаков

Для увеличения точности классификации разрабатываемых моделей посредством учета данных по окружению были введены дополнительные синтетические признаки.

Первым дополнительным признаком стала кластеризация данных по абсолютной глубине (DEPTH) – процесс разбиения выборки объектов скважины на подмножества на основе схожести признаков. Для определения оптимального количества кластеров был использован метод локтя [6, 7]. Применение данного метода заключается в подсчёте метрики WCSS для определённого количества кластеров, где WCSS – сумма квадратов расстояний между точками и центрами кластеров.

В результате данные по глубине были разбиты на 4 кластера. На рисунке 1 представлено разделение скважин по абсолютной глубине.




Рисунок 1. Диаграмма разделения скважин на кластеры по абсолютной глубине

Следующим искусственным признаком стала средняя

абсолютная глубина осложнений в окрестности. Данный признак используется для измерения влияния соседних точек на текущую. Расчёт признака осуществлялся с использованием объекта NearestNeighbors библиотеки машинного обучения Sklearn [8]. Радиус в проекции разреза скважины по результатам вычислительных экспериментов был ограничен 10 метрами.

Далее было выполнено построение послойного распределения осложнений по всему анализируемому объёму с шагом 20 м по вертикали (абсолютной глубине) с применением подсчёта радиально-базисной функции. Пример визуализации распределения осложнений на глубинах 270 м и 2085 м приведен на рисунке 2.




Рисунок 2. Срезы распределения с интерполяцией заданных глубин поглощений на Западном куполе Южно-Орловского месторождения

Следует отметить хорошую сходимость оконтуривания границ рифовой залежи (В-1+ДЗ-ФАМ+ДЗ-БУР), проявляющуюся в том, что на абсолютных глубинах 2040-2085 м при прохождении скважин по ядру рифа наблюдается отсутствие поглощений, по сравнению с тем, когда траектория скважин попадает в шлейфовые зоны рифовой постройки [9].

Исходя из данных, полученных по результатам предварительной обработки, были вычислены последние синтетические признаки, которые использовались в паре. Первый признак разбивает всю выборку на интервалы по 20 метров по глубине, а второй является результатом подсчёта всех плотностей осложнения на определённом интервале длиной 20 метров. Данный комплекс признаков оказал наибольшее влияние на точность прогнозирования осложнений.

С. Выбор обучающего алгоритма

После обработки данных, датасет имеет десять признаков. Объём выборки для обучения составил порядка двадцати тысяч записей, пропуски в датасете отсутствуют. Пример конечной записи представлен в таблице 2.

Таблица 2. Пример записи для обучения модели искусственного интеллекта

X	Y	DEPTH	IS_OIL	HORIZON	SECTION	Depth cluster	Mean complication depth	Complication density	COMPLICATION
3264,74	278,62	2120	1	19	5	4	2116,46	0,76	0
3264,74	278,62	2124	1	19	5	4	2121,72	0,81	1

На данном этапе происходил отбор алгоритмов и моделей искусственного интеллекта. Для решения поставленной задачи были использованы технологии машинного обучения и нейронных сетей. В работе применялись следующие модели машинного обучения: алгоритм k-ближайших соседей, дерево решений и логистическая регрессия.

Алгоритм KNN (*k-nearest neighbors*) предполагает, что подобные похожие объекты находятся в близости между собой в контексте признаковового пространства [10]. Для проводимого исследования пространство определения классов будет десятимерным. Данный подход имеет преимущества в отсутствии создания сложной модели, что даёт простоту реализации, локальность прогноза (т.е. вывод основан на ближайших точках) и гибкость настройки модели. Но вместе с этим присутствуют и минусы, связанные с чувствительностью к выбросам и отсутствию обобщения данных – прогноз выполняется по ближайшим точкам [11].

Логистическая регрессия – один из самых популярных алгоритмов машинного обучения, который представляет собой вид контролируемого обучения. Для выполнения логистической регрессии используются вероятностные переменные, которые лежат в границах от 0 до 1 [12]. В данном методе вместо регулировки линии регрессии мы изменяем логистическую функцию в форме буквы «S», которая предсказывает два максимальных значения (0 или 1). Логистическая регрессия может быть использована для классификации данных с использованием различных типов информации. Этот алгоритм имеет высокую устойчивость к переобучению, может легко обрабатывать большие массивы данных, но модель, обученная с помощью данного метода, предполагает линейность данных и их корректную обработку, что даёт низкую устойчивость к выбросам и делает эту модель более уязвимой к неточным прогнозам [13].

Последним рассмотренным в работе методом машинного обучения стало *дерево решений*. *Decision Tree* представляет собой граф, в котором производится описание пути от начального условия к какому-либо выводу [14]. В нашем случае, данный классификатор использовался как способ найти осложнение на определённой глубине. Преимуществом дерева решений является возможность обрабатывать нелинейные зависимости, отсутствие необходимости масштабирования признаков и быстрая работа модели, обусловленная её строением. При этом из-за архитектуры возможно переобучение. Также из-за шума в данных проявляется плохая обобщающая способность [15].

Основным методом решения поставленной задачи выявления зон осложнений стали нейронные сети. *Multilayer Perceptron (MLP)*, или *многослойный перцептрон* – это одна из базовых архитектур искусственных нейронных сетей, которая применяется во многих областях [16]. Основная идея MLP заключается в том, чтобы с помощью нескольких слоев нейронов и нелинейных функций активации научиться аппроксимировать сложные зависимости в данных. Для разрабатываемой модели нейронной сети была принята следующая конфигурация нейронной сети: входной слой – 64 нейрона, первый скрытый слой – 32 нейрона, второй скрытый слой – 16 нейронов, третий – 8 нейронов и выходной слой с одним нейроном, который определяет вероятность возникновения осложнения на определённом участке. В качестве функции активации использовалась ReLU [17].

Таким образом, общая последовательность работы с системой выявления зон осложнений представляет собой взаимодействие нескольких различных модулей: ИИ-агента, источников данных и модели ИИ. На рисунке 3 представлена схема работы компонентов предлагаемого решения.




Рисунок 3. Схема работы системы выявления зон осложнений

D. Оценка точности результатов моделирования

На последнем этапе разработки программного обеспечения было выполнено тестирование моделей искусственного интеллекта. Для оценки качества проводимого анализа использовались три метрики: *accuracy*, *precision* и *recall*. В таблице 3 представлена *матрица ошибок (Confusion matrix)*, которая отражает оценку метрики *precision* на примере двух классов.

Таблица 3 – Матрица ошибок (confusion matrix)

	y = 1	y = 0
$\hat{y} = 1$	True Positive (TP)	False Positive (FP)
$\hat{y} = 0$	False Negative (FN)	True Negative (TN)

Из таблицы 3 $\hat{y}$ – результат работы алгоритма, y – истинное значение. Метрика *precision* [18] будет иметь следующую формулу (1):

$$\text{precision} = \frac{TP}{TP + FP}. \quad (1)$$

Для того, чтобы оценить полноту выделенных объектов, используется метрика *recall* [18]. Recall отражает ту часть положительных меток, которую обнаружил алгоритм обучения, из всех меток, присутствующих в тестовом наборе. Формула (2) для метрики *recall* будет иметь вид:

$$\text{recall} = \frac{TP}{TP + FN}. \quad (2)$$

Метрика *accuracy* – это одна из самых простых и часто используемых метрик для оценки качества классификации в машинном обучении [18]. Она показывает долю правильно предсказанных примеров относительно общего количества примеров в наборе данных. Формула (3) для расчета *accuracy* выглядит следующим образом:

$$\text{accuracy} = \frac{TP + TN}{TP + FP + FN + TN}. \quad (3)$$

В таблице 4 представлены результаты исследования.

Е. Дополнительное исследование

Полученные результаты показали хороший прогноз поглощений, в связи с чем было принято решение о

Таблица 4. Результаты экспериментальных исследований

Алгоритмы	Precision отсутствия осложнений	Recall отсутствия осложнения	Precision обнаружения осложнения	Recall обнаружения осложнения	Accuracy
Метод KNN	0,99	0,99	0,97	0,94	0,98
Логистическая регрессия	0,91	0,98	0,90	0,61	0,90
Дерево решений	0,93	0,98	0,92	0,70	0,93
Нейронная сеть	0,99	0,99	0,98	0,93	0,97

Таблица 5. Результаты дополнительных расчётных исследований

Алгоритмы	Precision отсутствия осложнения	Recall отсутствия осложнения	Precision обнаружения осложнения	Recall обнаружения осложнения	Accuracy
Метод KNN	0,86	0,95	0,38	0,34	0,83
Логистическая регрессия	0,91	0,90	0,45	0,51	0,85
Дерево решений	0,92	0,92	0,50	0,51	0,86
Нейронная сеть	0,91	0,93	0,78	0,79	0,93

проведении дополнительного исследования. В расчете на основе приведенных методов набор тестовых данных формировался с помощью отбора случайных точек в периметре приведённого датасета. Для оценки другого подхода, в качестве тестового датасета была собрана информация о каждой скважине от устья до забоя. Далее модели обучались на полном датасете, из которого исключили тестируемую скважину. Обучение и тестирование проводилось методом кросс-валидации. Следующим шагом проводилось вычисление метрик, обобщённое в таблице 5.

Описанный метод выявил более слабую способность определения закономерностей для моделей машинного обучения в сравнении с нейронной сетью. Для интерпретации результатов работы программного обеспечения, была добавлена визуализация распределения поглощений по разрезу. На рисунке 4а приведено фактическое распределение осложнений по разрезу, на рисунке 4б показан результат работы программы. Красный цвет соответствует наличию поглощений, зелёный – его отсутствию. Также в рамках интерпретации была рассмотрен метод Шепли, результаты которого приведены на рисунке 5. Данный метод позволяет увидеть статистические вклады каждого признака в результат прогнозирования.




Рисунок 4. Расположение осложнений
а – фактическое, б – расчётное




Рисунок 5. Важность признаков, определенная методом Шепли

III. ЗАКЛЮЧЕНИЕ

Выполнен анализ массивов геолого-технологической информации по зонам осложнений пробуренных скважин с кластеризацией данных по глубинам.

При машинном обучении применены алгоритмы k-ближайших соседей, дерево решений и логистическая регрессия.

Разработана модель нейронной сети на основе

многослойного перцептрона (MLP) с тестированием по метрикам: accuracy, precision и recall.

Выполнено обучение модели нейронной сети на датасете с точностью прогноза по зонам возможных поглощений – 0,93.

Выбран метод прогнозирования зон поглощений на основе MLP модели машинного обучения нейронной сети.

Применение методов искусственного интеллекта для идентификации зон поглощений на стадии проектирования позволит снизить геологические риски бурения и за счет этого повысить эффективность строительства скважин.

БИБЛИОГРАФИЯ

- [1] Никитин В.И., Двойников М.В., Купавых К.С., Пантелева Т.А. Применение машинного обучения при моделировании параметров бурового раствора реологической модели Гершеля – Балкли для оптимизации промывки скважины // Записки Горного института. 2025. Т. 275. С. 70-80. EDN OLPTNY
- [2] Nikitin, V. I., Agrelkina, M. M. Justification for the Selection of a Relative Permeability Model in the Task of Predicting Drilling Fluid Filtrate Invasion into the Formation. International Journal of Engineering, 2025; 38(10): 2312-2320. doi: 10.5829/ije.2025.38.10a.08.
- [3] Линд Ю.Б., Мулюков Р.А., Кабиров А.Р., Мурзагалин А.Р. Оперативное прогнозирование осложнений при бурении // «Нефтяное хозяйство». – №2, 2013. – С. 55-57.
- [4] Линд Ю.Б., Кабиров А.Р., Елкибасва Г.Г., Мурзагалин А.Р., Мулюков Р.А. Современные информационные технологии в проектировании строительства скважин // Экспозиция Нефть Газ. – №5(30), 2013. – С. 34-36.
- [5] Ядрин В.В., Линд Ю.Б., Галиев А.Ф. Применение современных информационных технологий прогнозирования поглощений с целью их предупреждения при проектировании строительства скважин и эффективной ликвидации в процессе бурения // Проблемы сбора, подготовки и транспорта нефти и нефтепродуктов. – 2023, №1 (1). – С. 79-87.
- [6] Жилов Р. А. Интеллектуальные методы кластеризации данных // Известия Кабардино-Балкарского научного центра РАН. – 2023. – Т. 116, № 6. – С. 152-159.
- [7] Liu D, Deng Y. Determine the Number of Unknown Targets in Open World Based on Elbow Method. – IEEE Transactions on Fuzzy Systems. – 2020. – Vol. 26, no. 5. – P. 986-995.
- [8] Cunningham P., Delany S.J. k-Nearest Neighbour Classifiers 2nd Edition (with Python examples). – arXiv:2004.04523. – 2020.
- [9] Повышение эффективности прогнозирования и предупреждения зон полных и катастрофических поглощений бурового раствора в рифовых постройках Камско-Кинельской системы прогибов / К. А. Шиповский, В. С. Циркова, М. Е. Коваль [и др.] // Нефтяное хозяйство. – 2021. – № 12. – С. 97-101. – DOI 10.24887/0028-2448-2021-12-97-101.
- [10] Guo G., Wang H., Bell D., Bi Y., Greer K. KNN Model-Based Approach in Classification. – On The Move to Meaningful Internet Systems 2003: CoopIS, DOA, and ODBASE. – 2003. – V. 2888. – P. 986-996.
- [11] Zhang S., Li X., Zong M., Zhu X., Cheng D Learning k for kNN Classification. – ACM Transactions on Intelligent Systems and Technology (TIST). – 2017. – Vol. 8, no. 3. – P. 1-19.
- [12] Nick T.G., Campbell K.M. Logistic Regression. – In: Ambrosius, W.T. (eds) Topics in Biostatistics. Methods in Molecular Biology. – 2007. – Vol. 404. – P. 273-301.
- [13] Domínguez-Almendros S., Benítez-Parejo N., Gonzalez-Ramirez A.R. Logistic regression models. – Allergologia et Immunopathologia. – 2011. – Vol. 39, no. 5. – P. 295-305.
- [14] Шапиро, Л. "Компьютерное зрение" / Л. Шапиро, Дж. Стокман. – Москва: "БИНОМ", 2006. – 752 с. – ISBN 5-94774-384-1.
- [15] Mathuria M. Decision Tree Analysis on J48 Algorithm for Data Mining. – International Journal of Advanced Research in Computer Science and Software Engineering. – 2013. – Vol. 3, no. 6. – P. 1114-1119.
- [16] Рашид, Т. "Создаём нейронную сеть". – Москва: Компьютерное издательство "Диалектика", 2017. – 274 с.

- [17] Chen Y., Dai X., Liu M., Chen D., Yuan L., Liu Z. Dynamic ReLU. – Computer Vision – ECCV 2020. – 2020. – P. 351-367.
- [18] Naidu G., Zuva T., Sibanda E.M. A Review of Evaluation Metrics in Machine Learning Algorithms. – Lecture Notes in Networks and Systems. – 2023. – Vol. 724. – P. 15-25.

Identification of Drilling Fluid Absorption Zones in Well Design by Artificial Intelligence

S.A. Burlov, D.V. Mashkov, K.A. Shipovsky, V.A. Kapitonov, M.E. Koval

Abstract – When drilling wells, the presence of geological complications can lead to an increase in non-productive time. Based on the known methods of solving problems using artificial intelligence models to automate data analysis, the authors consider approaches to finding drilling fluid absorption intervals at the design stage of well construction. The results of comparative calculations using the nearest neighbor method, logistic regression, decision tree, neural network based on drilling data on the Western Dome of the Yuzhno-Orlovskoye field, which has a reef structure, are presented. The choice of the object is due to the availability of a sufficient amount of statistical data on previously drilled wells. The uniqueness of the geological structure of reef-type fields lies in the fact that when the trajectory of wells passes through the core of the carbonate massif, fewer losses occur than when drilling in plume zones. The results of testing the developed approach are presented, the advantages and disadvantages of each method are noted. It is concluded that the use of software based on machine learning algorithms can reduce the labor costs of engineers and increase the efficiency of design work.

Keywords – artificial intelligence, machine learning methods, drilling, reef array, neural networks, takeovers, data analysis.

REFERENCES

- [1] Nikitin V.I., Dvoynikov M.V., Kupavnykh K.S., Panteleeva T.A. Application of machine learning in modeling the parameters of drilling fluid using the Herschel-Bulkley rheological model to optimize well flushing // *Zapiski Gornogo Instituta*. 2025. Vol. 275. Pp. 70-80. EDN OLPTNY
- [2] Nikitin, V. I., Agrelkina, M. M. Justification for the Selection of a Relative Permeability Model in the Task of Predicting Drilling Fluid Filtrate Invasion into the Formation. *International Journal of Engineering*, 2025; 38(10): 2312-2320. doi: 10.5829/ije.2025.38.10a.08.
- [3] Lind Yu.B., Mulyukov R.A., Kabirova A.R., Murzagalin A.R. Operational forecasting of drilling complications // *"Neftyanoe Khozyaystvo"*. – No. 2, 2013. – Pp. 55-57.
- [4] Lind Yu.B., Kabirova A.R., Yelkibaeva G.G., Murzagalin A.R., Mulyukov R.A. Modern Information Technologies in Well Construction Design // *Exposition Oil Gas*. – No. 5(30), 2013. – Pp. 34-36.
- [5] Yadrin V.V., Lind Yu.B., Galiev A.F. Application of modern information technologies for predicting losses in order to prevent them when designing well construction and to ensure effective elimination during the drilling process // *Problems of Collection, Preparation and Transportation of Oil and Petroleum Products*. – 2023, No. 1 (1). – Pp. 79-87.
- [6] Zhilov R. A. Intelligent Data Clustering Methods // *Izvestiya of the Kabardino-Balkarian Scientific Center of the Russian Academy of Sciences*. – 2023. – Vol. 116, No. 6. – Pp. 152-159.
- [7] Liu D, Deng Y. Determine the Number of Unknown Targets in Open World Based on Elbow Method. – *IEEE Transactions on Fuzzy Systems*. – 2020. – Vol. 26, no. 5. – P. 986-995.
- [8] Cunningham P., Delany S.J. *k-Nearest Neighbour Classifiers* 2nd Edition (with Python examples). – arXiv:2004.04523. – 2020.
- [9] Improving the efficiency of forecasting and preventing zones of complete and catastrophic absorption of drilling mud in reef structures of the Kamsko-Kinelskaya trough system / K. A. Shipovsky, V. S. Cirkova, M. E. Koval [et al.] // *Oil Industry*. – 2021. – No. 12. – pp. 97-101. – DOI 10.24887/0028-2448-2021-12-97-101
- [10] Guo G., Wang H., Bell D., Bi Y., Greer K. KNN Model-Based Approach in Classification. – *On The Move to Meaningful Internet Systems 2003: CoopIS, DOA, and ODBASE*. – 2003. – V. 2888. – P. 986-996.
- [11] Zhang S., Li X., Zong M., Zhu X., Cheng D Learning k for kNN Classification. – *ACM Transactions on Intelligent Systems and Technology (TIST)*. – 2017. – Vol. 8, no. 3. – P. 1-19.
- [12] Nick T.G., Campbell K.M. Logistic Regression. – In: Ambrosius, W.T. (eds) *Topics in Biostatistics. Methods in Molecular Biology*. – 2007. – Vol. 404. – P. 273-301.
- [13] Domínguez-Almendros S., Benítez-Parejo N., Gonzalez-Ramirez A.R. Logistic regression models. – *Allergologia et Immunopathologia*. – 2011. – Vol. 39, no. 5. – P. 295-305.
- [14] Shapiro, L. "Komp'yuternoe zrenie" / L. Shapiro, Dzh. Stokman. – Moskva: "BINOM", 2006. – 752 s. – ISBN 5-94774-384-1.
- [15] Mathuria M. Decision Tree Analysis on J48 Algorithm for Data Mining. – *International Journal of Advanced Research in Computer Science and Software Engineering*. – 2013. – Vol. 3, no. 6. – P. 1114-1119.
- [16] Rashid, T. "Creating a Neural Network." – Moscow: Computer Publishing House "Dialectics," 2017. – 274 p.
- [17] Chen Y., Dai X., Liu M., Chen D., Yuan L., Liu Z. Dynamic ReLU. – *Computer Vision – ECCV 2020*. – 2020. – P. 351-367.
- [18] Naidu G., Zuva T., Sibanda E.M. A Review of Evaluation Metrics in Machine Learning Algorithms. – *Lecture Notes in Networks and Systems*. – 2023. – Vol. 724. – P. 15-25.