

Использование искусственного интеллекта для документирования геомеханических характеристик керна разведочных скважин

Д. В. Сидорова¹, В. В. Хаустов^{2✉}, В. А. Варнавский³,
С. В. Донецкий¹, А. И. Карнюшкин⁴

¹ФГАОУ ВО «Белгородский государственный национальный исследовательский университет»,
г. Белгород, Российская Федерация

²ФГБОУ ВО «Национальный исследовательский Московский государственный строительный университет»,
г. Москва, Российская Федерация

³ООО «Краснотурьинск-Полиметалл», г. Краснотурьинск, Российская Федерация

⁴ФГАОУ ВО «Московский государственный технический университет
имени М. Э. Баумана», г. Москва, Российская Федерация

✉ okech@mail.ru

Резюме. Рассматривается внедрение искусственного интеллекта в процессы документирования геомеханических характеристик керна разведочных скважин. Для анализа изображений кернов использовались нейронные сети и языковая модель ChatGPT-4o. Исследование проводилось на базе более 100 образцов керна с параллельным сравнением результатов искусственного интеллекта и экспертных оценок. Модель искусственного интеллекта демонстрирует высокую точность в идентификации цельных сегментов керна длиной свыше 10 см. Выявлена определенная проблематичность анализа зон с метасоматитами и интенсивной трещиноватостью, обусловленная сложностью распознавания малозаметных трещин и искусственных повреждений, а также ошибками в классификации горных пород при их визуальной схожести. Отмечена необходимость регулярного мониторинга и обновления модели для предотвращения деградации ее прогностических возможностей. Применение технологий искусственного интеллекта существенно снижает трудозатраты и ресурсы, необходимые для выявления основных геомеханических параметров керна, при этом подчеркивается важность тесного взаимодействия геомехаников и специалистов по программированию для создания стандартизованных и релевантных методов исследования. Интеграция искусственного интеллекта в процессы анализа керна способствует значительному повышению эффективности, точности и воспроизводимости геомеханической документации.

Ключевые слова: искусственный интеллект, геомеханические характеристики, керн, нейронные сети, ChatGPT-4o, анализ изображений керна, трещиноватость пород, мультиспектральные данные, повышение контрастности изображений

Благодарность: Авторы выражают признательность и благодарность коллективу редакции научно-технического и производственного журнала «Маркшейдерия и недропользование» за поддержку и помощь в оформлении статьи.

Для цитирования: Сидорова Д.В., Хаустов В.В., Варнавский В.А., Донецкий С.В., Карнюшкин А.И. Использование искусственного интеллекта для документирования геомеханических характеристик керна разведочных скважин. *Маркшейдерия и недропользование*. 2026;26(1):4-12. <https://doi.org/10.56195/20793332-2026-26-1-4-12>.

Using AI to document geomechanical properties of exploration well core

D. V. Sidorova¹, V. V. Khaustov^{2✉}, V. A. Varnavsky³,
S. V. Donetskii¹, A. I. Karnyushkin⁴

¹Belgorod State National Research University, Belgorod, Russian Federation

²National Research Moscow State University of Civil Engineering, Moscow, Russian Federation

³Krasnoturinsk-Polimetall LLC, Krasnoturinsk, Russian Federation

⁴Moscow State Technical University named after M. E. Bauman, Moscow, Russian Federation

✉ okech@mail.ru

Rezume. This article examines the integration of artificial intelligence into documenting the geomechanical properties of exploration well core. Neural networks and the ChatGPT-4o language model were used to analyze core images. The study was conducted using over 100 core samples, with parallel comparison of artificial intelligence results and expert assessments. The artificial intelligence

model demonstrates high accuracy in identifying intact core segments longer than 10 cm. Certain challenges in analyzing zones with metasomatites and intense fracturing are identified, due to the difficulty of recognizing subtle cracks and artificial damage, as well as errors in classifying rocks despite their visual similarity. The need for regular monitoring and updating of the model to prevent the degradation of its predictive capabilities is noted. The use of artificial intelligence technologies significantly reduces the labor costs and resources required to identify key geomechanical parameters of core, while emphasizing the importance of close collaboration between geomechanics and programming specialists to create standardized and relevant research methods. Integrating artificial intelligence into core analysis processes significantly improves the efficiency, accuracy, and reproducibility of geomechanical documentation.

Keywords: artificial intelligence, geomechanical properties, core, neural networks, ChatGPT-4o, core image analysis, rock fracturing, multispectral data, image contrast enhancement

Acknowledgments: The authors express their appreciation and gratitude to the editorial staff of the scientific, technical and industrial journal "Mine Surveying and Subsoil Use" for their support and assistance in preparing the article.

For citation: Sidorova D.V., Khaustov V.V., Varnavsky V.A., Donetskii S.V., Karnyushkin A.I. Using AI to document geomechanical properties of exploration well core. *Mine Surveying and Subsurface Use*. 2026;26(1):4-12. (In Russ.). <https://doi.org/10.56195/20793332-2026-26-1-4-12>.

Введение

Геомеханическая документация керна разведочных скважин является основным элементом изучения механических свойств горных пород в процессе разведки и разработки месторождений полезных ископаемых.

Документация включает:

- анализ кернов, взятых в коренных золотых месторождениях Урала с применением методов искусственного интеллекта (ИИ) для детального определения геомеханических параметров;
- показатель качества массива по состоянию керна (Rock Quality Designation, RQD);
- число систем трещин (J_n);
- количество трещин (NJ);
- расстояние между трещинами (Spacing Distance, SD);
- шероховатость стенок (Joint Roughness, Jr);
- уровень измененности стенок трещин (Alteration Index, A45);
- ширину раскрытия трещин (Aperture Width, A43);
- характеристику трещин согласно индексу JCON76.

Вышеприведенные параметры геомеханической документации керна разведочных скважин обладают фундаментальным значением при оценке структурной целостности и прочностных характеристик горных массивов, что обеспечивает основу для инженерно-геологических расчетов и проектирования горных работ.

Актуальность исследований обоснована определенным вкладом в развитие автоматизированных подходов к геомеханическому документированию, способствуя росту точности измерений и скорости обработки керновых данных, что является важным условием повышения эффективности геологоразведочных и горнотехнических процессов [1–5].

Цель исследований: анализ и обоснование метода документирования геомеханических характеристик керна разведочных скважин на основе внедрения возможностей искусственного интеллекта.

Объект исследований

Полевой первичный материал представлен образцами керна разведочных скважин (более 100) коренных золоторудных месторождений Урала.

В предлагаемой модели идентификация и исключение искусственно возникших трещин (помеченных красным маркером) осуществлялись через методически выстроенный алго-

ритм машинного обучения, в который был заложен большой набор размеченных данных.

В процессе подготовки обучающей выборки экспертами вручную помечались зоны с искусственными трещинами, основанными на признаках их формирования, таких как локальная неправильная ориентация, аномальная морфология и несоответствие естественным геологическим структурам. Алгоритм анализировал совокупность признаков трещин, включая их форму, размеры, цветовые характеристики и пространственные взаимоотношения, чтобы автоматически выделять и классифицировать искусственные трещины, отличая их от естественных систем трещин.

В качестве основного исследовательского базиса для построения подобных классификаторов использовались публикации по применению методов компьютерного зрения и машинного обучения для автоматического распознавания дефектов и искажений в кернах, в том числе:

– работы ГК «Юзтех» по технологии «ЮзКерн», где акцент сделан на автоматическое распознавание и классификацию литологических компонентов керна с последующим исключением артефактов обработки;

– исследования, посвященные применению алгоритмов машинного обучения для сегментации и классификации трещиноватости на основании визуальных признаков с применением нейросетевых моделей.

Материал и методы исследований

Разработанная модель опирается на реальный опыт и опубликованные данные по цифровому анализу керна с использованием ИИ, что обеспечивает высокую точность исключения искусственных трещин, помеченных красным маркером, из общего массива данных.

В процессе анализа керна скважин использовалась модель ИИ ChatGPT-4o, схема работы которой представлена на рисунке 1.

В реальности использование модели искусственного интеллекта ChatGPT-4o в геологическом анализе керна скважин основано на архитектуре трансформеров, адаптированной под работу с изображениями и текстовыми данными. Трансформеры обладают способностью эффективно обрабатывать последовательности и выявлять сложные взаимосвязи в данных, что в геологических исследованиях позволяет интегрировать визуальную информацию с семантическими описаниями. В практическом применении модель анализи-

рует фотографии кернов разведочных скважин, распознавая цветовые и текстурные особенности, которые коррелируют с минералогическим составом, структурой и степенью трещиноватости массива.



Рис. 1. Последовательность работы искусственного интеллекта по определению

геомеханических характеристик керна /

Fig. 1. The sequence of AI work to determine the geomechanical characteristics of the core

Например, алгоритмы выделяют характерные цветовые зоны, идентифицируют слоистость и различные типы текстур, а также фиксируют присутствие трещин с оценкой их размера, ориентации, плотности и морфологии. Эти параметры являются ключевыми для последующего геомеханического документирования и построения моделей прочности и устойчивости горных пород. Одновременно модель интерпретирует вводимые текстовые данные и классификационные признаки, позволяя связывать визуальные атрибуты с геологической терминологией и стандартами описания керна. Такая мультимодальная интеграция способствует повышению точности и полноты анализа, сокращая время экспертизы и минимизируя влияние субъективных факторов при визуальной оценке специалистами. Следовательно, использование ChatGPT-4o и трансформеров в геологии позволяет обрабатывать и интерпретировать, в частности, комплексные данные керна в автоматическом режиме, обеспечивая качественную поддержку принятия решений в разведке и разработке месторождений. Это способствует повышению объективности, оперативности и детализации геомеханической документации, что особо важно при анализе сложных и измененных горных массивов.

Изображения кернов обрабатывались с использованием сверточных нейронных сетей (далее – CNN, от англ. Convolutional Neural Network), представляющих собой тип нейронной сети, используемой для анализа изображений. В геологическом контексте сверточные нейронные сети представляют собой мощный инструмент для анализа и интерпретации визуальных данных, таких как фотографии и гиперспектральные изображения кернов разведочных скважин. Архитектура CNN, основанная на принципе свертки и иерархического выделения признаков, позволяет эффективно распознавать сложные текстурные и структурные паттерны, характерные для горных пород. В геологоразведке CNN уже доказали эффективность в различных задачах: автоматическом выявлении и классификации объектов на сейсмических данных (примеры – решения Orefox, Geolearn), определении минералов-индикаторов в ледниковых отложениях (IOS Services Geoscientifiques), а также в количественном и качественном описании буровых кернов по фотографиям и гиперспектральным данным (Geolearn, Solve Geosolutions). Эти сети осуществ-

ляют многослойное извлечение признаков, начиная с базовой текстуры и заканчивая сложными структурными элементами, что позволяет детально характеризовать минералогическую и геомеханическую структуру образцов [6]. Применение CNN способствует автоматизации и ускорению обработки больших объемов данных керна анализа, улучшая точность интерпретаций и снижая человеческий фактор. Кроме того, глубокое обучение на специализированных датасетах (dataset) позволяет выявлять скрытые закономерности и аномалии, важные для оценки качества горных массивов и выявления трещиноватости, что оказывает существенное влияние на проектирование и эксплуатацию месторождений.

Сверточные нейронные сети в геологических исследованиях служат эффективным инструментом интеграции высокоточных визуальных данных с геомеханическими моделями, повышая надежность и детальность геологоразведочных исследований. Они представляют собой мощный инструмент для анализа и интерпретации визуальных данных, таких как фотографии и гиперспектральные изображения кернов разведочных скважин.

Применение CNN в автоматизации анализа кернов повышает точность интерпретаций, сокращает время обработки данных и минимизирует влияние субъективного фактора. Кроме того, глубокое обучение на специализированных наборах данных позволяет выявлять скрытые закономерности и аномалии, значимые для оценки трещиноватости и качества горных массивов, что критично для безопасного и эффективного проектирования и эксплуатации месторождений.

Таким образом, сверточные нейронные сети являются эффективным инструментом интеграции визуальной информации с геомеханическими моделями, способствуя повышению надежности и детализации геологоразведочных исследований.

Результаты исследований

В приведенных исследованиях сверточные нейронные сети использовались для выявления трещин, цельных отрезков и определения выветривания горных пород (рис. 2).



Рис. 2. Обработка изображения с помощью сверточной нейронной сети в архитектуре ResNet (Residual Network) для разбивки керна на участки и выделения трещин (без доработки) /

Fig. 2. Image processing using a convolutional neural network in the ResNet (Residual Network) architecture to divide the core into sections and identify cracks (without modification)

Далее оценка цельных отрезков (длиной более 10 см) проводилась при помощи методики, включающей подсчет видимых сегментов их длины на изображении. Затем эти данные переводились в шкалу метров для расчета RQD.

Сравнение расчетных данных модели и реальных дан-

ных показало наличие некоторых расхождений в параметрах RQD и SD. Наибольшее влияние на ошибки оказала субъективная интерпретация трещиноватости и визуальная оценка длин цельных отрезков керна. Отклонения варьируются от 1 до 10 % в зависимости от интервалов, качества фотографии, сложности структуры породы, состояния керна на фото (увлажненный или сухой).

Сравнение первичных данных представлено в таблице 1.

Полученные результаты визуализировались в виде соответствующих графиков.

Так, на рисунке 3 представлено сравнение реальных значений параметра RQD с данными, полученными с помощью модели искусственного интеллекта.




Рис. 3. Результаты определения параметра RQD специалистом (1) и ИИ (2) / Fig. 3. Results of RQD parameter determination by a specialist (1) and AI (2)

Видно, что в интервале 65,5...72,7 м наблюдается наибольшее отклонение модели от реальных данных, что связано с наличием зон дробления и трещиноватости пород. В интервалах 58,3...65,5 и 72,7...79,9 м значения модели демонстрируют удовлетворительную сходимость с полевыми данными, что подтверждает ее надежность при анализе относительно устойчивых пород.

Следует отметить, что модель показала уверенное определение цельных сегментов керна (длин более 10 см), однако в зонах с метасоматитами и высокоинтенсивной трещиноватостью результаты работы модели указывают на определенные сложности в определении параметров трещин, что требует доработки алгоритма распознавания мелких трещин.

Затем использовалось большее количество изображений кернов (20 шт.) с более сложной структурой породы и большей длиной керна. В результате существенно контрастнее проявилось расхождение между результатами обработки ИИ и человеком (рис. 4).

В сравнении с оценками специалиста ИИ демонстрирует меньшую точность в определении качества горной породы, что связано с недостаточной чувствительностью модели к визуально слабо выраженным признакам трещиноватости. Несмотря на это, модель эффективно выявляет основные

трещиноватые структуры и зоны дробления массива, показывая сопоставимые с экспертными результаты на однородных участках пород. В сложных структурных интервалах с нечетко выраженными трещинами алгоритм стабильно занижает значения показателя качества массива RQD, обусловленное ограничениями в распознавании малозаметных структурных дефектов. В связи с этим подчеркивается необходимость обязательной верификации результатов ИИ специалистами-геомеханиками и регулярного обновления модели для повышения точности прогнозирования геомеханических параметров. Такой подход обеспечит повышение надежности автоматизированного анализа и способствует развитию методов цифрового геомеханического моделирования [7, 8].




Рис. 4. Результаты определения параметра RQD специалистом (1) и ИИ (2) керна с более сложной структурой породы и большей длиной / Fig. 4. Results of RQD parameter determination by a specialist (1) and AI (2) of a core with a more complex rock structure and a greater length

Сравнение расстояния между трещинами (SD) для интервалов 58,3...79,9 м представлено на рисунке 5.

В интервале 58,3...65,5 м модель искусственного интеллекта занижает расстояние между трещинами, что связано с высокой плотностью трещиноватости и присутствием зон дробления. В интервалах 65,5...72,7 и 72,7...79,9 м эти различия минимальны, что подтверждает эффективность модели в условиях ненарушенной структуры пород. Отклонения в параметре SD указывают на необходимость более точного учета трещин, включая мелкие и пересекающиеся системы трещин, что может быть достигнуто путем доработки алгоритмов сегментации изображений.

ИИ вполне корректно подтверждает общий тренд изменения SD с глубиной, выявленный специалистом, что указывает на достоверность его интерпретации трещиноватости пород (рис. 6). Незначительные расхождения могут быть связаны с особенностями модели в интерпретации близко расположенных или слабозаметных трещин в керне.

Таблица 1 / Table 1

Параметры тестирования первых образцов керна скважины № 110 / Testing parameters for the first core samples from well No. 110

Интервал	RQD (реальное)	RQD (ИИ)	SD (реальное)	SD (ИИ)	Jп (реальное)	Jп (ИИ)
58,3–65,5 м	39%	41,67%	0,116	0,121	6	6
65,5–72,7 м	52,5%	49,29%	0,143	0,153	3	3
72,7–79,9 м	61%	61,43%	0,206	0,215	3	3




Рис. 5. Результаты определения параметра SD в интервале глубин 58,3...79,9 м при документировании керна человеком (1) и при помощи модели ИИ (2) /

Fig. 5. Results of determining the SD parameter in the depth range of 58.3...79.9 m using human core documentation (1) and the AI model (2)




Рис. 6. Результаты определения параметра SD в интервале глубин 0,0...84,0 м при документировании керна человеком (1) и при помощи модели ИИ (2) /

Fig. 6. Results of determining the SD parameter in the depth range of 0.0...84.0 m when documenting the core by a person (1) and using the AI model (2)

Одним из ключевых достижений модели ИИ стали успешное распознавание структур трещиноватости и расчет параметров трещин (J_n , NJ). ChatGPT-4o автоматически исключал трещины из расчетов, помеченные красным цветом. Определение зон дробления ($J_n = 20$) произведено с точностью более 95 %. Параметры SD (расстояние между трещинами) и A43 (раскрытие трещин) рассчитаны с минимальной погрешностью. В процессе работы с ИИ разработан четкий алгоритм его работы, который позволил модели учитывать все значимые составляющие анализа кернов, такие как определение сегментов длиной более 10 см для расчета RQD, исключение помеченных красным цветом трещин, распознавание зон дробления и корректное определение параметров J_n и NJ , расчет параметров на основе таблиц из технической документации. Итоговые данные по одному из кернов представлены в таблице 2.

Для оценки точности расчетов модели, сопоставленные результаты ИИ и специалиста по интервалам керна 0,0...84,0 м представлены в таблице 3. Средняя погрешность RQD составила менее 20 %, а параметры SD и NJ совпадали с результатами специалиста в 90 % случаев. Максимальные расхождения наблюдались при определении типов пород и в зонах с перекрывающимися трещинами [8].

Обсуждение результатов исследований

Проведенные исследования показали, что модель ИИ на основе ChatGPT-4o весьма эффективна при относительно устойчивых значениях геомеханических характеристик, но точность результатов ее работы снижается в зонах высокой трещиноватости и гидротермальных изменений горных пород. В таких условиях необходима разработка специализированных подмоделей, обученных на изображениях и данных из высокотрещиноватых и гидротермально измененных зон, с последующей интеграцией в основную систему для повышения точности прогнозов и моделирования в геомеханике. Подобный подход подтверждается исследованиями и об-

Таблица 2 / Table 2

Сводная таблица параметров по всем интервалам кернов GS-34 (расчеты искусственного интеллекта) /
Summary table of parameters for all GS-34 core intervals (AI calculations)

Интервал	RQD	SD	J_n	NJ	J_r	A43	J_a	JCON76	A45
58,3–65,5 м	41,67	0,121	6	10	1	9	12	22	W2/A2
65,5–72,7 м	49,29	0,153	3	7	3	1	3	6	W2/A2
72,7–79,9 м	61,43	0,215	3	7	3	1	3	6	W2/A2
79,9–86,7 м	71,67	0,215	3	6	1	1	3	6	W2/A2

Таблица 3 / Table 3

Сводная таблица параметров по всем интервалам документации керна скважины GS-58
(сравнение искусственного интеллекта и специалиста) /

Summary table of parameters for all intervals of the GS-58 well core documentation (AI and specialist comparison)

Интервал	RQD (чел.), %	RQD (AI), %	SD (чел.), м	SD (AI), м	J_n (чел.)	J_n (AI)	J_r (чел.)	J_r (AI)	A43 (чел.)	A43 (AI)	J_a (чел.)	J_a (AI)	JCON76 (чел.)	JCON76 (AI)
0,0–5,4 м	0	0	-	-	20	20	-	1	-	1	-	3	3	-
5,4–11,0 м	48	25	0,15	0,17	6	6	1	1	9	9	3	3	6	6
11,0–16,1 м	58	36	0,20	0,20	6	6	1	1	9	9	3	3	6	6
16,1–21,1 м	55	52	0,22	0,25	6	6	1	1	9	9	3	3	6	6
21,1–26,1 м	65,50	46	0,25	0,25	6	6	1	1	9	9	3	3	6	6
26,1–31,1 м	91	40	0,23	0,25	6	6	1	1	9	9	3	3	6	6
31,1–36,1 м	47	45	0,22	0,25	6	6	1	1	9	9	3	3	6	6
79,2–84,0 м	85	82	0,20	0,20	6	6	1	1	1	1	3	3	6	6

зорными статьями, опубликованными в 2023–2025 годах [6, 9] и позволит проводить более детальный анализ сложных геологических структур. В частности, в научных источниках акцентируется внимание на том, что при использовании ChatGPT для реализации численных моделей конечных элементов в геотехнической инженерии с описанием ограничений и возможностей в сложных задачах необходима точная настройка при различных геомеханических условиях [9].

Кроме того, исследователи отмечают, что для улучшения классификации горных массивов с учетом трещиноватости и гидротермальных изменений необходимо применение нескольких нейронных сетей и эволюционных алгоритмов и интеграция различных моделей для повышения точности измерений [10]. В обзорной статье Ю. В. Бекеле, посвященной использованию ИИ для численного моделирования в геомеханике, рассматривается интеграция ИИ с традиционными геомеханическими симуляциями, включая возможность создания помощников для сложных условий моделирования, что косвенно подтверждает целесообразность использования специализированных подмоделей по геологическим зонам [11]. Исследование Ю. Бахрами и Х. Хассани, посвященное методикам выделения и анализа зон гидротермальных изменений с применением ИИ и обучением моделей на таких данных для повышения качества прогнозирования и интерпретации, также подтверждает необходимость использования подмоделей и оптимизированных алгоритмов для более точной интерпретации данных [12]. Следовательно, подмодели позволяют создавать гибкие, точные и эффективные системы машинного обучения, адаптированные под различные особенности входных данных и условия задачи. Именно поэтому для работы в зонах высокой трещиноватости и гидротермальных изменений разработка специализированных подмоделей и их интеграция в основную систему является оправданной и необходимой стратегией. Точность прогнозов достигается за счет специализированного обучения подмоделей на разных типах данных или особенностях задачи. Например, в геомеханическом анализе подмодели могут быть обучены для различных геологических зон – трещиноватых, гидротермальных и стабильных. Это позволяет учитывать специфические характеристики каждой зоны и улучшать качество прогнозов. Автоматизация анализа керна с использованием ИИ позволила получать данные, близкие к результатам традиционного экспертного документирования геомеханических параметров керна скважин. Основные отличия и погрешности связаны преимущественно с визуальной интерпретацией, что подчеркивает актуальность дальнейших разработок моделей ИИ, направленных на автоматическое распознавание сложных систем трещин и зон дробления горного массива. Такой прогресс позволит повысить точность и объективность анализа, снижая влияние субъективного фактора и увеличивая скорость обработки данных, что существенно повысит качество геологического моделирования и прогноза.

Как уже отмечалось, при длительном использовании ИИ без обновления данных он начинал деградировать, что приводило к ошибкам определения [13–15]. Последнее указывает на то, что ИИ не способен обрабатывать и интерпретировать данные без постоянного контроля со стороны специалиста-геомеханика. Тем не менее благодаря возможности предварительного обучения модели ChatGPT может совершенствоваться алгоритмы обнаружения и расчета параметров, адаптируясь к условиям конкретного месторождения

и накапливая знания из реальных данных, что позволяет повышать точность с каждым новым набором данных.

Обучение ИИ различать искусственные и природные трещины оказалось сложной задачей. На данный момент этот аспект остается под непосредственным контролем специалиста-геомеханика (искусственные трещины помечаются на фотографии красным цветом и исключаются из расчетов). В продолжение исследований планируется обучить ИИ отличать естественные трещины от трещин, образовавшихся в результате механического воздействия на керн, исключительно по изображению.

В использованной же версии ChatGPT не способен различать природные и искусственные трещины, при том что это является важным аспектом документирования геомеханических характеристик керна скважин [5]. При работе с моделью выявлены также затруднения в автоматической классификации типов горных пород. Хотя классификация пород основывается на визуальных характеристиках, таких как цвет, структура и текстура, модель нередко демонстрирует ошибки, особенно при интерпретации неоднородных образцов. Данное явление обусловлено тем, что ряд горных пород обладает похожими визуальными признаками или подвергается вторичным изменениям, которые затрудняют их точную идентификацию. В связи с этим определение литологического типа породы сохраняет статус задачи, требующей экспертного участия геомеханика для обеспечения достоверности результатов и повышения надежности интерпретации геологических данных.

Заключение

1. В представленных исследованиях акцентируется важность интерпретируемости решений ИИ при геомеханической документации керна разведочных скважин. Для повышения достоверности и контроля за процессом анализа рекомендуется внедрение методов объяснимого ИИ (Explainable AI, XAI), таких как визуализация значимых признаков, что позволяет специалистам понимать логику работы модели и верифицировать ее выводы. Это особенно критично в условиях полевых геологических работ, где точность оценок напрямую влияет на последующие инженерные решения, включая оценку устойчивости горного массива и выявление потенциально опасных зон риска.

2. Анализ ошибок показал, что основные расхождения с экспертными оценками связаны с трудностями распознавания малозаметных трещин. Для решения подобной проблемы предлагается использование высоко детализированной съемки и алгоритмов продвинутого обнаружения границ, повышающих точность расчета показателя RQD. Кроме того, планируется интеграция дополнительных телеметрических и геофизических данных (например, спектральных сенсоров, мультиспектральной и тепловизионной съемки, акустических измерений), что позволит более полно фиксировать тонкие изменения геомеханических свойств пород и повысит точность классификации трещиноватости.

3. Для улучшения качества обработки изображений ИИ будет дополняться модулями предобработки, такими как адаптивная фильтрация, увеличение контрастности, гистограммная эквализация и подавление шумов, вызванных особенностями поверхности керна. Эти методы, безусловно, повысят точность выделения природных и искусственных трещин, обеспечивая более качественные данные для последующего анализа сверточными нейронными сетями.

4. Важной составляющей является разработка автоматизированной системы обратной связи, позволяющей корректировать параметры модели в реальном времени с учетом замечаний специалистов, в том числе работающих непосредственно в полевых условиях. Такой итеративный процесс обучения позволит повысить точность прогнозов и справиться с проблемами интерпретации неоднородных и осложненных структур пород, а также с различием природных и искусственных повреждений.

Постоянное обновление и переобучение модели под контролем экспертов предотвратит деградацию качества ее работы и позволит выявлять систематические погрешности.

Выводы

1. В статье приведены результаты исследования внедрения искусственного интеллекта в процессы документирования геомеханических характеристик керна разведочных скважин.

2. Выявлено, что разработанная модель искусственного интеллекта в целом продемонстрировала высокую точность в идентификации цельных сегментов керна длиной свыше 10 см. Однако отмечается некоторая проблематичность анализа зон с метасоматитами и интенсивной трещиноватостью, обусловленная сложностью распознавания малозаметных трещин и искусственных повреждений, а также ошибками в

классификации горных пород при их визуальной схожести.

3. Применение технологий искусственного интеллекта существенно снижает трудозатраты и временные ресурсы, необходимые для выявления основных геомеханических параметров керна.

4. Важнейшими факторами успешного внедрения ИИ в геологоразведочные процессы является междисциплинарное сотрудничество программистов, геомехаников, геологов и горных инженеров, а также модернизация образовательных программ с целью подготовки специалистов, способных эффективно работать с современными вычислительными технологиями. Подобные комплексные усилия способны обеспечить разработку стандартизированных и адаптированных к практическим задачам решений, что существенно повысит качество и надежность геомеханической документации керна и в дальнейшем прогнозирования рисков при разработке месторождений полезных ископаемых.

5. Результаты проведенных исследований интеграции искусственного интеллекта в процессы анализа керна способствуют значительному повышению эффективности, точности и воспроизводимости геомеханической документации и могут быть полезными при изучении и планировании геомеханических исследований в рамках геологоразведочных и горно-геологических работ для широкого круга месторождений полезных ископаемых.

СПИСОК ЛИТЕРАТУРЫ / REFERENCES

1. Абзалов М.З. Прикладная рудничная геология. Москва, 2016: 451. Abzalov M.Z. Applied mine geology. Moscow, 2016: 451. (In Russ.).
2. Киряева Т.А., Попов С.Е., Потапов В.П. Нейронные сети в задачах геомеханики, возможности применения, методы оценки. *Вестник Научного центра ВостНИИ по промышленной и экологической безопасности*. 2024; 4: 36-49. <https://doi.org/10.25558/VOSTNII.2024.58.64.004>. Kiryeva T.A., Popov S.E., Potapov V.P. Neural networks in geomechanics problems, application possibilities, evaluation methods. *Bulletin of the Scientific Center of the Eastern Research Institute for Industrial and Environmental Safety*. 2024; 4: 36-49. (In Russ.). <https://doi.org/10.25558/VOSTNII.2024.58.64.004>.
3. Хисамов Р.С., Бачков А.П., Войтович С.Е. и др. Искусственный интеллект – важный инструмент современного геолога. *Геология нефти и газа*. 2021; 2: 37-45. <https://doi.org/10.31087/0016-7894-2021-2-37-45>. Khisamov R.S., Bachkov A.P., Voitovich S.E. Artificial intelligence is an important tool of the modern geologist. *Geology of oil and gas*. 2021; 2: 37-45. (In Russ.). <https://doi.org/10.31087/0016-7894-2021-2-37-45>.
4. Краснов Ф.В., Буторин А.В., Ситников А.Н. Автоматизированное обнаружение геологических объектов в изображениях сейсмического поля с применением нейронных сетей глубокого обучения. *Бизнес-информатика*. 2018; 2 (44): 7-15. Krasnov F.V., Butorin A.V., Sitnikov A.N. Automated detection of geological objects in seismic field images using deep learning neural networks. *Business Informatics*. 2018;2(44):7-15. (In Russ.).
5. Нагайцев М.В. Применение нейросетевых и прогностических моделей искусственного интеллекта при проведении геологоразведочных работ. *Понизовье*, 2024: 124. Nagaytsev M.V. Application of neural network and predictive artificial intelligence models in geological exploration. *Ponizovye*, 2024: 124. (In Russ.).
6. Патук М.И., Наумова В.В. Методы искусственного интеллекта для научных исследований в геологии. *Электронные библиотеки*. 2023; 26 (5): 673-696. <https://doi.org/10.26907/1562-5419-2023-26-5-673-696>. Patuk M.I., Naumova V.V. Artificial intelligence methods for scientific research in geology. *Electronic libraries*. 2023; 26 (5): 673-696. (In Russ.). <https://doi.org/10.26907/1562-5419-2023-26-5-673-696>.
7. Краснов Д.И. Модули внимания в сверточных нейронных сетях для распознавания малоразмерных объектов. *Компьютерная оптика*. 2024; 48 (6): 963-967. <https://doi.org/10.18287/2412-6179-CO-1468>. Krasnov D.I. Attention modules in convolutional neural networks for small-scale object recognition. *Computer Optics*. 2024; 48 (6): 963-967. (In Russ.). <https://doi.org/10.18287/2412-6179-CO-1468>.
8. Шагарова Л. В. Языковая модель ChatGPT и данные дистанционного зондирования Sentinel платформы Google Earth Engine на примере Омской области. Всероссийская конференция, посвященная Дню радио «Радиоэлектронные устройства и системы для инфокоммуникационных технологий» (РЭУС-ИТ – 2024): Доклады. Москва, 31 мая 2024 года. Москва, 2024: 83-87. Shagarova L.V. The ChatGPT language model and Sentinel remote sensing data from the Google Earth Engine platform: a case study of the Omsk region. *All-Russian Conference dedicated to Radio Day «Radioelectronic Devices and Systems for In communication Technologies» (REUS-IT 2024): Reports, Moscow, May 31, 2024*. Moscow: 2024; 83-87. (In Russ.).
9. Kim T., Yun T.S., Suh H.S. Can ChatGPT implement finite element models for geotechnical engineering applications? *International Journal for Numerical and Analytical Methods in Geomechanics*. 2025; 49 (6): 1747-1766. <https://doi.org/10.48550/arXiv.2501.02199>.

10. Saadati G., Javankhoshdel S., Mohebbi Najm Abad J, et al. AI-Powered Geotechnics: Enhancing Rock Mass Classification for Safer Engineering Practices. *Rock Mechanics and Rock Engineering*. 2024; 58 (10): 11319-11349. <https://doi.org/10.1007/s00603-024-04189-7>.
11. Bekele Y.W., GeoSim. AI: AI assistants for numerical simulations in geomechanics. *ArXiv*. 2025: 13. <https://doi.org/10.48550/arXiv.2501.14186>.
12. Bahrami Y., Hassani H. Optimization of machine learning algorithms for remote alteration mapping. *Advances in Space Research*. 2024; 74 (4): 1609-1632. <https://doi.org/10.1016/j.asr.2024.05.045>.
13. Гришков Г.А., Устинов С.А., Нафигин И.О. и др. Нейронные сети и возможности их применения для анализа пространственных геологических данных. *XV Международная научно-практическая конференция «Развитие новых идей и тенденций в науках о Земле: инновационные технологии геологической разведки, горного и нефтегазового дела, бурение скважин, математическое моделирование и разведочная геофизика»: материалы*. Москва, 2021. Москва: 2021; 33-36.
Grishkov G.A., Ustinov S.A., Nafigin I.O., et al. Neural networks and their application in spatial geological data analysis. *XV International Scientific and Practical Conference "Development of New Ideas and Trends in Geosciences: Innovative Technologies in Geological Exploration, Mining, Oil and Gas, Well Drilling, Mathematical Modeling, and Exploration Geophysics": proceedings*. Moscow: S. Ordzhonikidze Russian State Geological Survey University, 2021. Moscow: 2021; 33-36. (In Russ.).
14. Caelen O., Blete M.-A. Developing Apps with GPT-4 and ChatGPT: Build Intelligent Chatbots, Content Generators, and More. *O'Reilly*, 2023: 157.
15. Alto V. Modern Generative AI with ChatGPT and OpenAI Models: Leverage the capabilities of OpenAI's LLM for productivity and innovation with GPT3 and GPT4. *Packt Publishing*. 2023: 285.

СВЕДЕНИЯ ОБ АВТОРАХ

ABOUT THE AUTHORS



Дарья Витальевна Сидорова – аспирант, Белгородский государственный национальный исследовательский университет, г. Белгород, Российская Федерация; <https://orcid.org/0009-0002-7683-1508>; e-mail: 1249460@bsuedu.ru

Darya V. Sidorova – postgraduate student, Belgorod National Research University, Belgorod, Russian Federation; <https://orcid.org/0009-0002-7683-1508>; e-mail: 1249460@bsuedu.ru



Владимир Васильевич Хаустов – доктор геолого-минералогических наук, доцент, Национальный исследовательский Московский государственный строительный университет, г. Москва, Российская Федерация; <https://orcid.org/0000-0002-1895-7367>; WoS Researcher ID: C-3838-2016; Scopus Author ID: 7003912446; e-mail: okech@mail.ru

Vladimir V. Khaustov – Dr. Sci. (Geol. & Mineral.), Associate Professor, National Research Moscow State University of Civil Engineering, Moscow, Russian Federation; <https://orcid.org/0000-0002-1895-7367>; WoS Researcher ID: C-3838-2016; Scopus Author ID: 7003912446; e-mail: okech@mail.ru



Вячеслав Александрович Варнавский – геомеханик, ООО «Краснотурьинск-Полиметалл», Свердловская область, г. Краснотурьинск, Российская Федерация; e-mail: varnavskiiVA@polymetal.ru

Vyacheslav V. Varnavskii – geomechanics, LLC "Krasnoturyinsk-Polymetal", Sverdlovsk region, Krasnoturyinsk, Russian Federation; e-mail: VarnavskiiVA@polymetal.ru



Сергей Владимирович Донецкий – кандидат технических наук, Белгородский государственный национальный исследовательский университет, г. Белгород, Российская Федерация; WoS Researcher ID: PCS-4483-2025; e-mail: donetskii@bsuedu.ru

Sergey V. Donetskii – Cand. Sci. (Eng.), Belgorod State National Research University, Belgorod, Russian Federation; WoS Researcher ID: PCS-4483-2025; e-mail: donetskii@bsuedu.ru



Александр Иванович Карнюшкин – кандидат технических наук, доцент, Московский государственный технический университет имени Н. Э. Баумана, г. Москва, Российская Федерация; <https://orcid.org/0000-0001-5685-162X>, e-mail: him_expert@mail.ru

Alexander I. Karnyushkin – Cand. Sci. (Eng.), Associate Professor, Moscow State Technical University named after N.E. Bauman, Moscow, Russian Federation; <https://orcid.org/0000-0001-5685-162X>; e-mail: him_expert@mail.ru

Критерии авторства:

Д. В. Сидорова – выполнение работы по систематизации материала, написание текста статьи, анализ результатов исследования; В. В. Хаустов – генерация идеи исследования; постановка задачи; В. А. Варнавский – проведение полевых работ, написание текста статьи; С. В. Донецкий – постановка задачи, анализ результатов исследования; А. И. Карнюшкин – выполнение работы по систематизации материала, анализ результатов исследования.

Конфликт интересов:

Авторы заявляют об отсутствии конфликта интересов.

Информация о статье

Поступила в редакцию: 15.12.2025

Поступила после рецензирования: 15.01.2026

Принята к публикации: 25.01.2026

Contribution:

D. V. Sidorova – writing the article, analyzing the research results, systematizing the material; V. V. Khaustov – generating the research idea; setting the problem; V. A. Varnavsky – conducting fieldwork, writing the article; S. V. Donetsky – setting the problem, analyzing the research results; A. I. Karnyushkin – systematizing the material, analysis of research results.

Conflict of interest:

The authors declare no conflict of interest.

Article info

Received: 15.12.2025

Revised: 15.01.2026

Accepted: 25.01.2026