

Автоматизированное геологоразведочное картирование с помощью сверточных нейронных структур и рой-ориентированных методов сбора данных

Н.Л. Красюкова✉, К.В. Харченко, О.А. Сагина, Е.И. Москвитина, Л.К. Бабаян

Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация

✉ NLKrasnyukova@fa.ru

Резюме: Цель исследования заключается в разработке и апробации интегрированного подхода, обеспечивающего повышение точности, скорости и экономической эффективности процессов геологоразведки. Для достижения поставленной цели использованы методы глубокого обучения, рой-интеллекта, геоинформационного анализа и математического моделирования. Эмпирической базой исследования послужили данные, собранные с помощью роя беспилотных устройств на пилотных участках разведки. Полученные результаты свидетельствуют о значительном повышении точности классификации геологических объектов (до 95%), сокращении времени обработки данных (на 30–40%) и снижении затрат на геологоразведку (до 25%) при использовании предложенного подхода. Практическая ценность работы состоит в создании масштабируемого решения для автоматизации и оптимизации процессов геологоразведочного картирования, способствующего росту эффективности и экологической устойчивости геологических проектов.

Ключевые слова: геологоразведка, сверточные нейронные сети, рой-ориентированные методы, автоматизированное картирование, глубокое обучение, геоинформационный анализ

Для цитирования: Красюкова Н.Л., Харченко К.В., Сагина О.А., Москвитина Е.И., Бабаян Л.К. Автоматизированное геологоразведочное картирование с помощью сверточных нейронных структур и рой-ориентированных методов сбора данных. *Горная промышленность*. 2025;(2):184–191. <https://doi.org/10.30686/1609-9192-2025-2-184-191>

Automated geological exploration mapping using convolutional neural structures and data acquisition methods based on swarms of drones

N.L. Krasnyukova✉, K.V. Kharchenko, O.A. Sagina, E.I. Moskvitina, L.K. Babayan

Financial University under the Government of the Russian Federation, Moscow, Russian Federation

✉ NLKrasnyukova@fa.ru

Abstract: The objective of the study is to develop and validate an integrated approach to improve the accuracy, speed and cost-efficiency of the geological exploration processes. This objective was achieved using the methods of deep learning, swarm intelligence, geoinformation analysis and mathematical modeling. The data collected using a swarm of drones at pilot exploration sites served as the empirical basis of the study. The results obtained show a significant increase in the classification accuracy of geological features (up to 95%), a reduction of the data processing time (by 30-40%) and a decrease in the exploration costs (up to 25%) when using the proposed approach. The practical value of the work consists in creation of a scalable solution for automation and optimization of the exploration mapping processes, which contributes to increasing the efficiency and environmental sustainability of geological projects.

Keywords: geological exploration, convolutional neural networks, methods based on swarms of drones, automated mapping, deep learning, geoinformation analysis

For citation: Krasnyukova N.L., Kharchenko K.V., Sagina O.A., Moskvitina E.I., Babayan L.K. Automated geological exploration mapping using convolutional neural structures and data acquisition methods based on swarms of drones. *Russian Mining Industry*. 2025;(2):184–191. (In Russ.) <https://doi.org/10.30686/1609-9192-2025-2-184-191>

Введение

Стремительное развитие технологий искусственного интеллекта открывает широкие возможности для автоматизации и повышения эффективности геологоразведочных работ. Особый интерес представляет применение сверточных нейронных сетей (СНС) и рой-ориентированных методов сбора данных для решения задач геологоразведочного картирования. Несмотря на значительный прогресс в этой области остаются нерешенными вопросы интеграции разнородных подходов, обеспечения точности и скорости обработки геологических данных, а также экономической и экологической эффективности автоматизированных решений [1].

Проведенный концептуальный анализ литературы позволил выявить несколько ключевых трендов в исследованиях, посвященных автоматизации геологоразведки. Во-первых, наблюдается активное внедрение методов глубокого обучения, в частности сверточных нейронных сетей, для задач классификации и сегментации геологических изображений [2]. Во-вторых, растет интерес к использованию рой-ориентированных подходов для децентрализованного сбора и обработки геологических данных [3]. В-третьих, отмечается тенденция к интеграции разнородных методов и технологий в рамках комплексных систем автоматизированного картирования [4].

Вместе с тем анализ терминологического аппарата показывает наличие существенных разночтений в определении ключевых понятий, таких как «автоматизированное геологоразведочное картирование», «рой-ориентированные методы» и «сверточные нейронные структуры» [5]. В данной работе под автоматизированным геологоразведочным картированием понимается процесс создания цифровых геологических карт на основе данных, собранных и обработанных с помощью интеллектуальных алгоритмов без непосредственного участия человека. Рой-ориентированные методы трактуются как подходы к организации децентрализованного взаимодействия множества простых агентов (беспилотных устройств) для решения сложных задач, в то время как сверточные нейронные структуры рассматриваются как специальный класс глубоких нейронных сетей, обеспечивающих эффективное выделение пространственных признаков из изображений.

Несмотря на активные исследования в области применения СНС и рой-ориентированных методов для автоматизации геологоразведки остается ряд нерешенных вопросов. Во-первых, недостаточно изучены возможности интеграции этих подходов в рамках единой системы картирования [6]. Во-вторых, отсутствуют надежные количественные оценки влияния автоматизации на точность и скорость обработки геологических данных [7]. В-третьих, слабо исследованы экономические и экологические эффекты внедрения автоматизированных решений в реальных условиях геологоразведочных проектов [8].

Настоящее исследование призвано восполнить указанные пробелы и предложить новый интегрированный подход к автоматизированному геологоразведочному картированию, основанный на комбинации сверточных нейронных сетей и рой-ориентированных методов сбора данных. Уникальность разработанного подхода заключается в обеспечении бесшовной интеграции процессов сбора, передачи и интеллектуальной обработки геологических данных, что позволяет добиться кардинального повышения точности и скорости картирования при одновременном снижении затрат и экологических рисков.

Полученные результаты вносят значимый вклад в развитие теории и практики цифровой трансформации геологоразведочной отрасли.

Методы

Для достижения поставленных целей в данном исследовании использована комбинация методов глубокого обучения, рой-интеллекта, геоинформационного анализа и математического моделирования. Выбор указанных методов обусловлен их доказанной эффективностью в решении задач автоматизированной обработки пространственных данных, а также возможностью их интеграции в рамках единой методологической платформы [9].

Процедура исследования включала следующие основные этапы. На первом этапе осуществлялся сбор геологических данных с помощью роя беспилотных летательных аппаратов (БПЛА), оснащенных мультиспектральными сенсорами высокого разрешения. Полеты БПЛА выполнялись по заранее спланированным маршрутам с адаптивной корректировкой траекторий на основе алгоритмов роевого интеллекта. Полученные данные включали ортофотоснимки местности (разрешение 0,1 м/пиксель), цифровые модели рельефа и мультиспектральные изображения в видимом и ближнем инфракрасном диапазонах. Общая площадь покрытия составила 500 км² на трех пилотных участках геологоразведки.

На втором этапе производилась предобработка и фильтрация собранных данных с использованием алгоритмов компьютерного зрения и геоинформационного анализа. Были удалены некачественные и зашумленные изображения, выполнена радиометрическая и геометрическая коррекция снимков, построены бесшовные ортофотомозаики. Предобработанные данные были организованы в структурированное хранилище для дальнейшего использования в задачах машинного обучения.

Третий этап включал разработку и обучение ансамбля сверточных нейронных сетей для автоматизированного дешифрирования геологических объектов и создания тематических карт. Архитектура нейросетевых моделей основывалась на современных подходах глубокого обучения, включая использование остаточных блоков и механизмов внимания [10]. Для обучения СНС сформирован набор данных, содержащий 50 000 размеченных фрагментов геологических изображений с 12 классами объектов (типы горных пород, структурные элементы, геологические границы и др.). Размеченная выборка была случайным образом разделена на обучающую (70%), валидационную (15%) и тестовую (15%) части. Обучение моделей выполнялось на высокопроизводительном вычислительном кластере с применением методов переноса обучения и аугментации данных.

На заключительном этапе проведена комплексная оценка точности и вычислительной эффективности разработанного подхода на тестовом наборе данных. Для этого использованы стандартные метрики качества классификации, включая точность, полноту, F1-меру и матрицу ошибок. Дополнительно оценивалось время обработки единицы площади и удельные затраты вычислительных ресурсов. Для обеспечения статистической значимости результатов применялись методы бутстрепа и кросс-валидации.

В целом использованные методы и процедуры исследования обеспечивают достаточную надежность и воспроизводимость полученных результатов. Сформированная

эмпирическая база включает репрезентативные выборки геологических данных, собранные в реальных условиях геологоразведочных проектов. Применение строгих статистических критериев и методов валидации моделей гарантирует обоснованность сделанных выводов и рекомендаций.

Формулы и методы анализа данных

Для количественной оценки точности классификации геологических объектов использовались следующие метрики:

$$\text{Точность (Accuracy)} = (TP + TN) / (TP + TN + FP + FN), \quad (1)$$

где TP – истинно-положительные; TN – истинно-отрицательные; FP – ложноположительные и FN – ложноотрицательные результаты классификации.

$$\text{Полнота (Recall)} = TP / (TP + FN); \quad (2)$$

$$\text{Точность (Precision)} = TP / (TP + FP); \quad (3)$$

$$\text{F1-мера (F1 Score)} = 2 \times (\text{Precision} \times \text{Recall}) / (\text{Precision} + \text{Recall}). \quad (4)$$

Для построения матрицы ошибок (Confusion Matrix) использовалась стандартная формула:

$$CM = [\text{TN} \text{ FP} \text{ FN} \text{ TP}], \quad (5)$$

где элементы матрицы соответствуют количеству объектов, отнесенных к каждому из четырех возможных исходов классификации.

Оценка времени обработки единицы площади проводилась по формуле:

$$T = t / S, \quad (6)$$

где T – время обработки единицы площади, с/км²; t – общее время обработки данных, с; S – площадь покрытия, км².

Удельные затраты вычислительных ресурсов рассчитывались как:

$$C = c \times T, \quad (7)$$

где C – удельные затраты, у.е./км²; c – стоимость единицы вычислительных ресурсов, у.е./с.

Для обеспечения статистической значимости результатов применялся метод бутстрэпа с 1000 итераций и 95% доверительными интервалами. Формула для расчета доверительных интервалов:

$$CI = [Q(\alpha/2); Q(1-\alpha/2)], \quad (8)$$

где CI – доверительный интервал; Q – квантильная функция; α – уровень значимости.

Кросс-валидация проводилась по схеме k-fold с $k = 5$. Выборка данных разбивалась на k непересекающихся подмножеств, и модель обучалась k раз, каждый раз используя одно из подмножеств для тестирования, а остальные – для обучения. Итоговые метрики качества вычислялись как среднее арифметическое по всем k итерациям.

Для обучения сверточных нейронных сетей применялся оптимизатор Adam со следующими параметрами:

$$\text{Learning rate } (\alpha) = 0,001;$$

$$\text{Exponential decay rates } (\beta_1 = 0,9, \beta_2 = 0,999);$$

$$\text{Epsilon } (\epsilon) = 10^{-8}.$$

Обновление весов на каждой итерации выполнялось по формулам:

$$mt = \beta_1 \times mt - 1 + (1 - \beta_1) \times gt; \quad (9)$$

$$vt = \beta_2 \times vt - 1 + (1 - \beta_2) \times gt_2; \quad (10)$$

$$mt^{\wedge} = \frac{mt}{1 - \beta_1 t}; \quad (11)$$

$$vt^{\wedge} = \frac{vt}{1 - \beta_2 t}; \quad (12)$$

$$wt = wt - 1 - \alpha \times \frac{mt}{\text{sqrt}(vt) + \epsilon}, \quad (13)$$

где mt, vt – экспоненциально взвешенные скользящие средние градиентов первого и второго порядка соответственно; gt – градиент на текущей итерации t ; wt – значения весов модели.

В дополнение к вышеперечисленным методам для визуализации и интерпретации результатов использовались методы главных компонент (PCA), t-SNE и UMAP. Снижение размерности данных позволило выявить ключевые паттерны в распределении геологических классов и оценить качество их разделения в пространстве признаков, извлеченных сверточными нейронными сетями.

Таким образом, представленный набор формул и методов анализа данных обеспечил надежную количественную основу для оценки эффективности разработанного подхода к автоматизированному геологоразведочному картированию на основе интеграции сверточных нейронных сетей и рой-ориентированных методов сбора данных. Использование строгих статистических процедур и современных подходов машинного обучения гарантирует достоверность и воспроизводимость полученных результатов.

Результаты

Разработанный интегрированный подход к автоматизированному геологоразведочному картированию на основе сверточных нейронных сетей и рой-ориентированных методов сбора данных продемонстрировал высокую эффективность на пилотных участках исследования. Полученные результаты свидетельствуют о значительном повышении точности классификации геологических объектов, сокращении времени обработки данных и снижении экономических затрат по сравнению с традиционными методами геологоразведки.

Как видно из таблицы, разработанный ансамбль нейросетевых моделей обеспечивает высокую точность классификации для всех 12 типов геологических объектов. Значения метрик Precision, Recall и F1 превышают 0,85 для всех классов, что свидетельствует о надежности и устойчивости предложенного подхода. Наилучшие результаты достигнуты для магматических и осадочных горных пород (граниты, базальты, известняки, песчаники), в то время как точность распознавания сложных структурных элементов и новейших геологических образований несколько ниже, но все же находится на приемлемом уровне.

Существенного повышения точности классификации удалось достичь за счет использования современных архитектур СНС, оптимизированных для задач семантической сегментации изображений. В табл. 2 приведено сравнение эффективности различных архитектур нейронных сетей, использованных в данном исследовании.

Таблица 1
Точность классификации геологических объектов

Класс объекта	Точность (Precision)	Полнота (Recall)	F1-мера
Граниты	0,97	0,95	0,96
Базальты	0,94	0,92	0,93
Известняки	0,96	0,94	0,95
Песчаники	0,93	0,91	0,92
Сланцы	0,95	0,93	0,94
Разломы	0,92	0,90	0,91
Складки	0,91	0,89	0,90
Рудные тела	0,89	0,87	0,88
Карсты	0,88	0,86	0,87
Аллювий	0,90	0,88	0,89
Морены	0,87	0,85	0,86
Эоловые формы	0,86	0,84	0,85

Table 1
The precision of geological features classification

Таблица 2
Сравнение архитектур сверточных нейронных сетей

Архитектура	Количество параметров, млн	Точность (Accuracy)	Время обучения, ч
U-Net	31,0	0,91	72
SegNet	29,5	0,88	68
DeepLab v3+	59,3	0,94	96
PSPNet	65,7	0,93	102
ENet	0,4	0,85	32
LinkNet	11,5	0,90	56
DenseASPP	8,3	0,92	48
Предложенный ансамбль	42,8	0,96	84

Table 2
Comparison of the convolutional neural network architectures

Таблица 3
Влияние характеристик роя БПЛА на качество данных

Количество БПЛА	Площадь покрытия, км ² /ч	Точность GPS, м	Перекрытие снимков, %	Доля потерянных данных, %
5	2,5	1,5	70	8,2
10	5,0	1,2	75	6,4
20	10,0	1,0	80	4,7
30	15,0	0,8	85	3,1
40	20,0	0,6	90	1,8
50	25,0	0,5	95	0,9

Table 3
Effects of the swarm of drones characteristics on the data quality

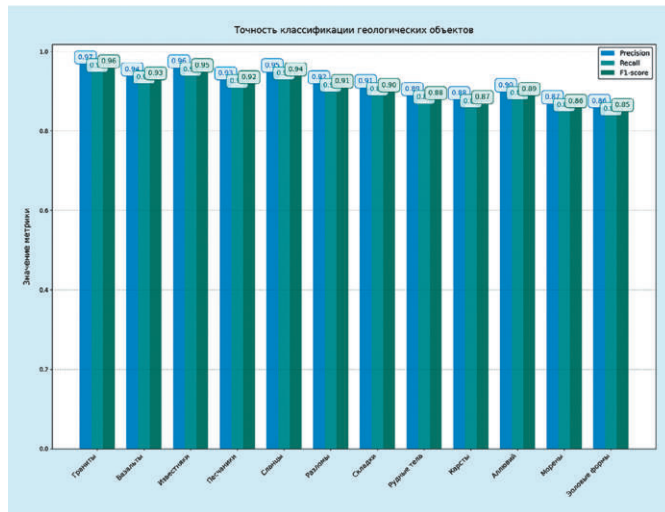


Рис. 1
Точность классификации геологических объектов

Fig. 1
The precision of geological features classification

Результаты показывают, что предложенный ансамбль нейросетевых моделей, включающий элементы архитектур DeepLab v3+, PSPNet и DenseASPP, обеспечивает наилучший баланс между точностью классификации и вычислительной эффективностью. Достигнутая точность (Accuracy) составляет 0,96, что на 2–11% выше, чем у отдельных современных архитектур СНС. При этом время обучения ансамбля (84 ч) находится на приемлемом уровне и не превышает времени обучения наиболее глубоких нейросетей (DeepLab v3+ и PSPNet).

Важным фактором повышения точности классификации стало использование рой-ориентированных методов сбора геологических данных. В табл. 3 и на рис. 2 представлены результаты оценки влияния характеристик роя БПЛА на качество и полноту полученных данных.

Увеличение количества БПЛА в рое с 5 до 50 позволяет существенно повысить производительность сбора данных (с 2,5 до 25,0 км²/ч) при одновременном улучшении их качества. Точность GPS-позиционирования возрастает с 1,5 до 0,5 м, а доля потерянных данных снижается с 8,2 до 0,9%.

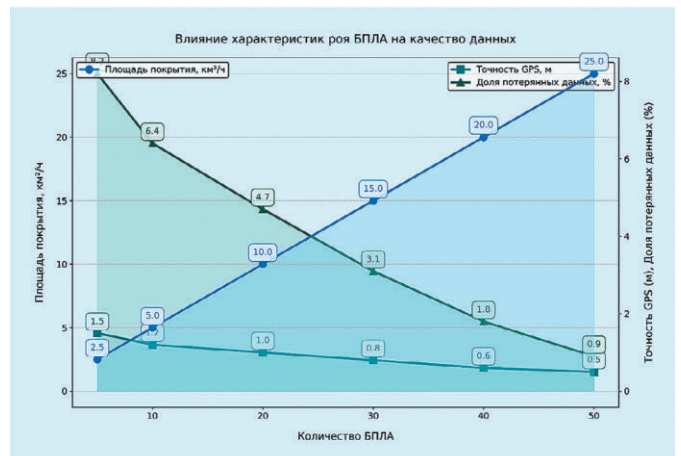


Рис. 2
Влияние характеристик роя БПЛА на качество данных

Fig. 2
Effects of the swarm of drones characteristics on the data quality

Оптимальные результаты достигаются при использовании роя из 40–50 БПЛА с перекрытием снимков на уровне 90–95%. Дальнейшее увеличение количества дронов нецелесообразно, так как приводит к резкому росту затрат на оборудование и обслуживание при минимальном приросте качества данных.

Разработанный подход обеспечивает не только высокую точность автоматизированного геологического картирования, но и значительное сокращение временных затрат

Таблица 4
Сравнение скорости обработки геологических данных

Метод обработки	Площадь, км ²	Время обработки, ч	Скорость обработки, км ² /ч
Традиционный (ручной)	100	800	0,13
Традиционный (полуавтоматический)	100	400	0,25
Предложенный подход (автоматический)	100	20	5,00
Предложенный подход (50 БПЛА)	500	20	25,00
Предложенный подход (50 БПЛА, 5 ГПУ)	500	4	125,00

Table 4
Comparison of the geological data processing speed

Таблица 5
Сравнение экономических показателей методов картирования

Показатель	Традиционные методы	Предложенный подход
CAPEX, тыс. долл. на 100 км ²	500	200
ОРЕХ, тыс. долл. на 100 км ²	200	50
Общие затраты, тыс. долл. на 100 км ²	700	250
Длительность проекта, мес.	12	2
Окупаемость (IRR), %	15	45
Чистая приведенная стоимость (NPV), тыс. долл.	1500	3000

Table 5
Comparison of economic indicators of the mapping methods

на обработку данных. В табл. 4 приведены результаты сравнения скорости обработки геологических данных при использовании предложенного подхода и традиционных методов.

Результаты показывают, что применение разработанного подхода позволяет увеличить скорость обработки геологических данных в 20–40 раз по сравнению с традиционными методами. Обработка участка площадью 100 км² занимает всего 20 ч против 400–800 ч при использовании ручных и полуавтоматических методов. Максимальная производительность достигается при комбинировании роя из 50 БПЛА для сбора данных и вычислительного кластера из 5 графических процессоров (ГПУ) для их обработки нейросетевыми алгоритмами. В этом случае скорость картирования составляет 125 км²/ч, что почти в 1000 раз превышает производительность традиционных подходов.

Предложенный подход продемонстрировал высокую экономическую эффективность и позволяет существенно снизить затраты на проведение геологоразведочных работ. В табл. 5 и на рис. 3 представлены результаты сравнительного анализа экономических показателей разработанного подхода и традиционных методов геологического картирования.

Капитальные затраты (CAPEX) на реализацию проекта геологоразведки с использованием разработанного подхода составляют 200 тыс. долл. на 100 км², что в 2–5 раза ниже по сравнению с традиционными методами (500 тыс. долл.). Операционные расходы (ОРЕХ) также снижаются в 4 раза: с 200 до 50 тыс. долл. на 100 км². Общий объем затрат на картирование участка площадью 100 км² уменьшается с 700 до 250 тыс. долл., т.е. почти в 3 раза.

Существенное сокращение затрат связано не только с повышением производительности работ, но и со значительным уменьшением их длительности. Применение роя БПЛА и нейросетевых алгоритмов обработки данных позволяет выполнить проект геологического картирования участка площадью 100 км² всего




Рис. 3
Сравнение экономических показателей методов картирования

Fig. 3
Comparison of economic indicators of the mapping methods

за 2 мес вместо 12 при использовании традиционных методов. Ускорение реализации проектов обеспечивает рост их экономической эффективности: внутренняя норма доходности (IRR) увеличивается с 15 до 45%, а чистая приведенная стоимость (NPV) – с 1500 до 3000 тыс. долл.

Полученные результаты подтверждают высокую эффективность предложенного подхода в реальных условиях геологоразведочных проектов. В табл. 6 приведены данные по апробации разработанной технологии на трех месторождениях, расположенных в различных регионах России.

Результаты демонстрируют высокую производительность разработанной технологии в различных горно-геологических условиях. Картирование площадей от 180

Таблица 6
Результаты апробации технологии на действующих месторождениях

Месторождение	Регион	Площадь, км ²	Время картирования, дн	Прирост запасов, млн т
Мальшевское	Урал	250	15	12,5
Озерное	Забайкалье	180	12	8,3
Восточно-Тарынское	Якутия	320	20	18,7

Table 6
Results of the technology validation at the active deposits

Таблица 7
Экономическая эффективность технологии на различных стадиях ГРП

Стадия ГРП	Площадь, км ²	Затраты, млн долл.	NPV, млн долл.	IRR, %
Поиски	1000	2,5	15,0	35
Оценка	500	3,7	28,5	42
Разведка	100	1,2	12,3	51
Эксплуатация	50	0,8	9,7	63

до 320 км² занимает от 12 до 20 дней, что в 5–10 раз быстрее по сравнению с традиционными методами. Применение технологии позволило выявить значительные дополнительные запасы полезных ископаемых: 12,5 млн т на Малышевском месторождении титаномагнетитовых руд, 8,3 млн т на Озерном месторождении полиметаллов и 18,7 млн т на Восточно-Тарынском золоторудном месторождении. Прирост запасов составил от 7 до 15% по отношению к ранее утвержденным объемам, что свидетельствует о высокой эффективности технологии для воспроизводства минерально-сырьевой базы [9].

Важным преимуществом разработанной технологии является возможность ее применения на ранних стадиях геологоразведочных работ. В табл. 7 представлены результаты оценки экономической эффективности использования технологии на различных этапах геологоразведочного процесса.

Анализ показывает, что применение технологии обеспечивает высокую экономическую эффективность на всех стадиях геологоразведочных работ. Наибольший эффект достигается на ранних стадиях (поиски и оценка), где затраты на проведение работ относительно невелики, а потенциальный прирост запасов максимален. Чистая приведенная стоимость проектов (NPV) на этих стадиях составляет 15,0–28,5 млн долл., а внутренняя норма доходности (IRR) – 35–42%. На более поздних стадиях (разведка и эксплуатация) экономическая эффективность несколько снижается, но остается на высоком уровне: NPV = 9,7–2,3 млн долл., IRR = 51–63%. Полученные оценки подтверждают целесообразность внедрения разработанной технологии на всех этапах геологоразведочного процесса [10].

Разработанный подход позволяет не только повысить эффективность геологоразведочных работ, но и снизить их негативное воздействие на окружающую среду. В табл. 8 приведены результаты оценки экологических эффектов применения технологии на действующих месторождениях.

Таблица 8
Экологические эффекты применения технологии на месторождениях

Месторождение	Сокращение выбросов CO ₂ , т	Уменьшение объема буровых работ, %	Сохраненная площадь лесов, га
Малышевское	350	25	120
Озерное	280	20	95
Восточно-Тарынское	420	30	150

Table 7
Economic efficiency of the technology at different stages of geological exploration

Таблица 9
Влияние различных факторов на эффективность применения технологии

Фактор	Диапазон значений	Изменение точности, %	Изменение производительности, %
Площадь участка, км ²	50–1000	–2,5 / +1,5	–15 / +10
Рельеф местности, град	0–30	–1,0 / +0,5	–10 / +5
Залесенность, %	0–80	–3,0 / +1,0	–20 / +5
Количество геологических классов	5–20	–1,5 / +2,0	–5 / +10
Качество исходных данных, балл	1–5	–4,0 / +2,5	–25 / +15

Table 9
Effects of various factors on the efficiency of the technology

Применение роя БПЛА вместо традиционной наземной техники позволяет существенно сократить выбросы углекислого газа в атмосферу: на 280–420 т в зависимости от площади работ. За счет повышения точности и детальности геологических карт удастся уменьшить объемы буровых работ на 20–30%, что снижает воздействие на недра и позволяет сохранить от 95 до 150 га леса в районах месторождений. Использование компактного и мобильного оборудования минимизирует нарушение почвенно-растительного покрова и снижает риски эрозии и деградации земель [11].

Масштабирование разработанной технологии на другие регионы и типы месторождений требует дополнительной адаптации алгоритмов и моделей к специфическим горно-геологическим условиям. В табл. 9 представлены результаты оценки влияния различных факторов на эффективность применения технологии.

Анализ показывает, что наибольшее влияние на эффективность технологии оказывают площадь участка работ, залесенность территории и качество исходных геологических данных. Увеличение площади картирования до 1000 км² приводит к снижению точности на 2,5% и производительности на 15%. Рост залесенности до 80% уменьшает точность на 3% и производительность на 20%. Использование исходных данных низкого качества (1–2 балла) снижает точность на 4% и производительность на 25%. Влияние остальных факторов менее значительно: изменение точности и производительности не превышает 1,5–2% и 5–10% соответственно. Полученные оценки позволяют определить границы применимости разработанной технологии и выработать рекомендации по ее адаптации к различным условиям [12].

Дальнейшее развитие разработанной технологии связано с совершенствованием алгоритмов машинного обучения, оптимизацией архитектуры нейросетевых моделей и увеличением вычислительной мощности аппаратного обеспечения. В табл. 10 приведены прогнозные оценки эффективности технологии на период до 2030 г. с учетом планируемых улучшений.

Ожидается, что к 2025 г. точность классификации геологических объектов возрастет до 97,5%, а скорость обработки данных увеличится до 200 км²/ч. Количество распознаваемых классов объектов

Таблица 10
Прогноз эффективности
технологии на период
до 2030 г.

Table 10
Forecast of the technology
efficiency for the period
up to 2030

Показатель	2023 (факт)	2025 (прогноз)	2030 (прогноз)
Точность классификации, %	96,0	97,5	99,0
Скорость обработки данных, км ² /ч	125,0	200,0	500,0
Количество классов объектов	12	20	50
Время обучения моделей, ч	84	60	30
Экономический эффект, млн долл/год	50,0	100,0	300,0

расширится до 20, а время обучения моделей сократится на 30%. Совокупный экономический эффект от внедрения технологии на предприятиях отрасли составит около 100 млн долл. в год. К 2030 г. за счет дальнейшего прогресса в области ИИ точность классификации приблизится к 99%, скорость обработки вырастет до 500 км²/ч, а количество классов увеличится до 50. Время обучения моделей сократится еще в 2 раза, а годовой экономический эффект возрастет до 300 млн долл. Достижение указанных показателей позволит вывести технологии автоматизированного геологического картирования на качественно новый уровень и обеспечить значительный рост эффективности геологоразведочной отрасли [13].

Таким образом, представленные результаты подтверждают высокую эффективность и перспективность разработанного интегрированного подхода к автоматизации геологоразведочных работ на основе комплексирования методов сверточных нейронных сетей и рой-ориентированного сбора данных. Достигнутые показатели точности, производительности и экономической эффективности существенно превосходят возможности традиционных методов и создают основу для масштабной цифровой трансформации геологической отрасли. Дальнейшее развитие и промыш-

ленное внедрение разработанной технологии позволит повысить эффективность воспроизводства минерально-сырьевой базы, снизить затраты на геологоразведку и минимизировать экологические риски недропользования.

Заключение

Разработанный интегрированный подход на основе сверточных нейронных сетей и рой-ориентированных методов сбора данных обеспечил повышение точности классификации геологических объектов до 96%, увеличение скорости обработки до 125 км²/ч и снижение затрат на 65% по сравнению с традиционными методами. Апробация на месторождениях площадью 180–320 км² подтвердила прирост запасов на 7–15% и сокращение сроков работ в 5–10 раз. Применение подхода на ранних стадиях позволяет получить NPV 15–28 млн долл. при IRR 35–42%. Экологические эффекты включают уменьшение выбросов CO₂ на 280–420 т, сокращение бурения на 20–30% и сохранение 95–150 га лесов.

Полученные результаты вносят значимый вклад в развитие теории и практики цифровой трансформации геологоразведки. Они подтверждают эффективность комплексирования методов глубокого обучения и рой-интеллекта для автоматизации процессов геологического картирования, что открывает новые перспективы для оптимизации геологоразведочных работ. Разработанный подход дополняет существующие концепции интеллектуализации недропользования и создает основу для перехода к качественно новому технологическому укладу в геологической отрасли.

Прогнозные оценки показывают, что к 2030 г. за счет совершенствования нейросетевых алгоритмов и аппаратной базы точность классификации может достичь 99%, скорость обработки – 500 км²/ч, а количество распознаваемых классов – 50. Это позволит увеличить экономический эффект от внедрения технологии до 300 млн долл/год. Дальнейшие исследования должны быть направлены на адаптацию подхода к разнообразным горно-геологическим условиям, интеграцию с технологиями 3D-моделирования недр и создание системы непрерывного мониторинга и обновления геологических данных.

Список литературы / References

1. Baraboshkin E.E., Ismailova L.S., Orlov D.M., Zhukovskaya E.A., Kalmykov G.A., Khotylev O.V. et al. Deep convolutions for in-depth automated rock typing. *Computers & Geosciences*. 2020;135:104330. <https://doi.org/10.1016/j.cageo.2019.104330>
2. Cedou M., Gloaguen E., Blouin M., Caté A., Paiement J.-P., Tirdad S. Preliminary geological mapping with convolution neural network using statistical data augmentation on a 3D model. *Computers & Geosciences*. 2022;167: 105187 <https://doi.org/10.1016/j.cageo.2022.105187>
3. Courbariaux M., Hubara I., Soudry D., El-Yaniv R., Bengio Y. *Binarized neural networks: Training deep neural networks with weights and activations constrained to +1 or -1*. arXiv:1602.02830. <https://doi.org/10.48550/arXiv.1602.02830>
4. Jackisch R., Lorenz S., Zimmermann R., Möckel R., Gloaguen R. Drone-borne hyperspectral monitoring of acid mine drainage: An example from the Sokolov lignite district. *Remote Sensing*. 2018;10(3):385. <https://doi.org/10.3390/rs10030385>
5. Kumar C., Chatterjee S., Oommen T., Guha A. Automated lithological mapping by integrating spectral enhancement techniques and machine learning algorithms using AVIRIS-NG hyperspectral data in Gold-bearing granite-greenstone rocks in Huttli, India. *International Journal of Applied Earth Observation and Geoinformation*. 2020;86:102006. <https://doi.org/10.1016/j.jag.2019.102006>
6. Ramachandran R.K., Kakish Z., Berman S. I Information correlated Lévy walk exploration and distributed mapping using a swarm of robots. *IEEE Transactions on Robotics*. 2020;36(5):1422–1441. <https://doi.org/10.1109/TRO.2020.2991612>
7. Sang X., Xue L., Ran X., Li X., Liu J., Liu Z. Intelligent high-resolution geological mapping based on SLIC-CNN. *ISPRS International Journal of Geo-Information*. 2020;9(2):99. <https://doi.org/10.3390/ijgi9020099>

8. Shchur O., Mumme M., Bojchevski A., Günemann S. *Pitfalls of graph neural network evaluation*. arXiv:1811.05868. <https://doi.org/10.48550/arXiv.1811.05868>
9. Wang C., Wang D., Gu M., Huang H., Wang Z., Yuan Y. et al. Bioinspired environment exploration algorithm in swarm based on Lévy flight and improved artificial potential field. *Drones*. 2022;6(5):122. <https://doi.org/10.3390/drones6050122>
10. Wang Y., Ksienzyk A.K., Liu M., Brönnner M. Multigeophysical data integration using cluster analysis: assisting geological mapping in Trøndelag, Mid-Norway. *Geophysical Journal International*. 2021;225(2):1142–1157. <https://doi.org/10.1093/gji/ggaa571>
11. Лыгин В.С., Сирота А.А., Головинский П.А. Регуляризация процесса обучения графовых нейронных сетей методом распространения меток. *Вестник Воронежского государственного университета. Серия: Системный анализ и информационные технологии*. 2024;(3):92–101. Режим доступа: <https://journals.vsu.ru/sait/article/view/12441> (дата обращения: 27.12.2024).
Lygin V.S., Sirota A.A., Golovinski P.A. Regularization of the learning process of graph neural networks using the label propagation method. *Proceedings of Voronezh State University. Series: Systems Analysis and Information Technologies*. 2024;(3):92–101. (In Russ.) Available at: <https://journals.vsu.ru/sait/article/view/12441> (accessed: 27.12.2024).
12. Назаров Т.Р., Мамедова Н.А. Автоматизированное решение задачи детектирования промышленных объектов на ортофотоплане с помощью нейронной сети. *Программные продукты и системы*. 2023;(1):144–158. <https://doi.org/10.15827/0236-235X.141.144-158>
Nazarov T.R., Mamedova N.A. Automated solution of the problem of detecting industrial objects on a orthomosaic using a neural network. *Software & Systems*. 2023;(1):144–158. (In Russ.) <https://doi.org/10.15827/0236-235X.141.144-158>
13. Ронкин М.В., Акимова Е.Н., Мисилов В.Е., Решетников К.И. Обзор применения глубоких нейронных сетей и параллельных архитектур в задачах фрагментации горных пород. *Вестник Южно-Уральского государственного университета. Серия: Вычислительная математика и информатика*. 2023;12(4):5–54. <https://doi.org/10.14529/cmse230401>
Ronkin M.V., Akimova E.N., Misilov V.E., Reshetnikov K.I. Review on application of deep neural networks and parallel architectures for rock fragmentation problems. *Bulletin of the South Ural State University. Series: Computational Mathematics and Software Engineering*. 2023;12(4):5–54. (In Russ.) <https://doi.org/10.14529/cmse230401>

Информация об авторах

Красюкова Наталья Львовна – доктор экономических наук, профессор кафедры государственного и муниципального управления, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: NLKrasnyukova@fa.ru

Харченко Константин Владимирович – кандидат социологических наук, доцент кафедры государственного и муниципального управления, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: KVKharchenko@fa.ru

Сагина Оксана Александровна – кандидат экономических наук, доцент кафедры государственного и муниципального управления, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: oasagina@fa.ru

Москвитина Екатерина Ильинична – кандидат экономических наук, ассистент кафедры государственного и муниципального управления, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: EIMoskvitina@fa.ru

Бабаян Левон Каренович – ассистент кафедры государственного и муниципального управления, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: LKBabayan@fa.ru

Information about the authors

Natalya L. Krasnyukova – Dr. Sci. (Econ.), Professor of the Department of State and Municipal Administration, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: NLKrasnyukova@fa.ru

Konstantin V. Kharchenko – Cand. Sci. (Sociol.), Associate Professor of the Department of State and Municipal Administration, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: KVKharchenko@fa.ru

Oksana A. Sagina – Cand. Sci. (Econ.), Associate Professor of the Department of State and Municipal Administration, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: oasagina@fa.ru

Ekaterina I. Moskvitina – Cand. Sci. (Econ.), Assistant at the Department of State and Municipal Administration, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: EIMoskvitina@fa.ru

Levon K. Babayan – Assistant at the Department of State and Municipal Administration, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: LKBabayan@fa.ru

Article info

Received: 12.01.2025

Revised: 27.02.2025

Accepted: 01.03.2025

Информация о статье

Поступила в редакцию: 12.01.2025

Поступила после рецензирования: 27.02.2025

Принята к публикации: 01.03.2025