

# Применение методов глубокого машинного обучения для структурного анализа рудных тел и прогнозирования оптимальных зон добычи

О.В. Панина✉, А.М. Беляев, Н.А. Завалько, С.Г. Еремин, О.А. Сагина

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

✉ opanina@fa.ru

**Резюме:** В статье рассматривается применение методов глубокого машинного обучения для анализа структуры рудных тел и прогнозирования оптимальных зон добычи полезных ископаемых. Исследование нацелено на разработку методологии использования глубокого обучения для повышения эффективности геологоразведочных и добычных процессов. Для решения поставленных задач применялись современные архитектуры нейронных сетей, включая сверточные и рекуррентные модели. Эмпирической базой выступил массив геологических данных по месторождениям различных типов. Результаты демонстрируют значительное повышение точности структурного анализа рудных тел (до 95%) и эффективности прогнозирования высокопродуктивных зон (прирост добычи до 15%). Внедрение разработанных подходов способно обеспечить снижение затрат на геологоразведку до 30% и уменьшение экологических рисков за счет оптимизации добычных работ. Полученные выводы имеют высокую ценность для теории и практики применения искусственного интеллекта в горнодобывающей отрасли, открывая перспективы для дальнейших исследований в этом направлении.

**Ключевые слова:** глубокое машинное обучение, геологоразведка, структурный анализ, рудные тела, зоны добычи, нейронные сети

**Для цитирования:** Панина О.В., Беляев А.М., Завалько Н.А., Еремин С.Г., Сагина О.А. Применение методов глубокого машинного обучения для структурного анализа рудных тел и прогнозирования оптимальных зон добычи. *Горная промышленность*. 2025;(1):177–183. <https://doi.org/10.30686/1609-9192-2025-1-177-183>

## Application of deep machine learning methods for structural analysis of ore bodies and prediction of optimal mining zones

O.V. Panina✉, A.M. Belyaev, N.A. Zavalko, S.G. Eremin, O.A. Sagina

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

✉ opanina@fa.ru

**Abstract:** The article studies application of deep machine learning methods to analyze the structure of ore bodies and prediction of optimal zones of mining mineral deposits. The research is aimed at developing a methodology of using deep learning to improve efficiency of the exploration and mining processes. Contemporary neural network architectures, including the convolutional and recurrent models, were used to solve the problems identified. An array of geological data on various types of deposits was used as an empirical base. The results demonstrate a significant increase in the accuracy of structural analysis of ore bodies (up to 95%) and in the efficiency of forecasting high-yield zones (up to 15% gain in production). Implementation of the developed approaches has the potential to reduce exploration costs by up to 30% and reduce environmental risks by optimizing mining operations. The obtained conclusions are of high value for the theory and practical application of artificial intelligence in the mining industry, opening prospects for further research in this direction.

**Keywords:** deep machine learning, exploration, structural analysis, ore bodies, mining zones, neural networks

**For citation:** Panina O.V., Belyaev A.M., Zavalko N.A., Eremin S.G., Sagina O.A. Application of deep machine learning methods for structural analysis of ore bodies and prediction of optimal mining zones. *Russian Mining Industry*. 2025;(1):177–183. (In Russ.) <https://doi.org/10.30686/1609-9192-2025-1-177-183>

### Введение

Цифровая трансформация горнодобывающей отрасли выдвигает новые требования к методам анализа геоданных и планирования добычных работ. Особую значимость приобретает применение передовых подходов искусственного интеллекта, в частности, глубокого машинного обуче-

ния (ГМО) [1]. Ряд исследований последних лет демонстрирует перспективность использования ГМО для решения различных задач геологоразведки и добычи [2; 3]. Однако многие вопросы, связанные с адаптацией этих методов к специфике минерально-сырьевого комплекса, остаются недостаточно изученными.

В литературе встречаются различные трактовки понятия «глубокое машинное обучение» применительно к обработке геоданных. В данной работе под ГМО понимается класс методов, основанных на многослойных нейронных сетях, способных самостоятельно выделять иерархические признаки из «сырых» данных [4]. Такой подход позволяет строить высокоточные прогностические модели там, где традиционные методы математической статистики оказываются малоэффективны в силу сложности и многомерности геологической информации [5].

Анализ современных публикаций выявляет несколько магистральных направлений применения ГМО в горнодобывающей сфере. Прежде всего это задачи структурно-морфологического анализа рудных тел и месторождений, включая 3D-моделирование и классификацию геологических объектов [6; 7]. Другое перспективное направление – прогнозирование зон с наибольшим содержанием полезного компонента для оптимизации добычных работ [8; 9]. Наконец, методы ГМО находят применение для повышения экологической и промышленной безопасности горнодобывающих предприятий [10].

Несмотря на очевидные успехи в этих областях, остается ряд пробелов, требующих дальнейшего изучения. Во-первых, недостаточно исследованы вопросы комплексного применения ГМО для анализа структуры рудных тел в сочетании с прогнозированием оптимальных зон добычи [11]. Во-вторых, многие существующие модели ГМО плохо адаптированы к специфическим условиям конкретных месторождений и не учитывают широкий спектр геологических факторов [12]. В-третьих, отсутствуют исчерпывающие данные о влиянии внедрения подходов ГМО на экономическую эффективность и экологическую безопасность добычных процессов в долгосрочной перспективе.

Целью настоящего исследования является разработка комплексной методологии применения глубокого машинного обучения для решения взаимосвязанных задач структурного анализа рудных тел и прогнозирования оптимальных зон добычи. Предлагаемый подход призван обеспечить значительное повышение точности и эффективности геологоразведочных и добычных работ за счет интеллектуального анализа геоданных с учетом широкого набора природных и техногенных факторов. Теоретическая и практическая значимость исследования обусловлена потребностью горнодобывающей отрасли в передовых инструментах цифровизации, способных обеспечить рациональное и экологически сбалансированное освоение минеральных ресурсов.

## Методы

Выбор методов глубокого машинного обучения в данном исследовании обусловлен их доказанной эффективностью в обработке многомерных геоданных со сложной внутренней структурой [13]. В отличие от традиционных статистических подходов, ГМО позволяет выявлять неявные закономерности путем последовательного преобразования исходных признаков в иерархические представления с растущим уровнем абстракции [14]. Это делает ГМО незаменимым инструментом для решения таких задач, как распознавание геологических структур и прогнозирование свойств рудных тел.

Исследование включало несколько последовательных этапов. На первом этапе были выполнены сбор и предобработка геологических данных по ряду месторождений различных генетических типов. Использовались данные геофизических исследований скважин, результаты гео-

химического опробования, структурные характеристики рудных тел, а также технологические показатели добычи и обогащения. Общий объем проанализированных данных составил более 100 Гб.

Для подготовки данных применялись методы очистки, нормализации и трансформации признаков. Был проведен анализ на наличие выбросов и пропущенных значений с использованием критериев Граббса и Литтла [15]. Категориальные переменные были закодированы с помощью прямого кодирования (one-hot encoding). Численные признаки масштабировались методом z-нормализации. Временные ряды технологических показателей подверглись процедуре сглаживания скользящим средним.

На втором этапе сформированные наборы данных были разделены на обучающую, валидационную и тестовую выборки в соотношении 60/20/20%. Для решения задач структурного анализа и прогнозирования использовались современные архитектуры нейронных сетей. В частности, для сегментации геологических структур на 3D-моделях применялись сверточные нейронные сети U-Net и SegNet. Для прогнозирования содержания полезного компонента и оптимальных зон отработки использовались рекуррентные нейронные сети LSTM (long short-term memory) и временные сверточные сети (temporal convolutional network, TCN).

Гиперпараметры моделей подбирались с помощью байесовской оптимизации на валидационной выборке. Качество обучения контролировалось по метрикам точности (accuracy), полноты (recall) и F1-меры. Для борьбы с переобучением применялись методы регуляризации (L1, L2) и dropout-слои. Окончательное тестирование моделей проводилось на отложенной тестовой выборке, не участвовавшей в обучении.

Для оценки экономических эффектов внедрения ГМО использовались показатели снижения затрат на геологоразведку, роста производительности добычи, увеличения извлечения запасов. Экологические риски оценивались на основе прогнозируемого сокращения площади нарушенных земель и объемов отходов обогащения. Расчеты выполнялись в сравнении с базовым сценарием, предполагающим использование традиционных методов геологоразведки и планирования горных работ.

Для более детального анализа эффективности моделей ГМО использовался ряд дополнительных метрик. В частности, для оценки точности мультиклассовой классификации рассчитывался взвешенный F<sub>1</sub>-score:

$$F_1\text{-score} = 2 \sum_{i=1}^K w_i p_i r_i / \sum_{i=1}^K w_i (p_i + r_i),$$

где  $p_i$  и  $r_i$  – точность и полнота для  $i$ -го класса;  $w_i$  – доля  $i$ -го класса в выборке;  $K$  – количество классов.

Для измерения качества ранжирования геологических объектов по степени перспективности применялся коэффициент ранговой корреляции Спирмена:

$$r_s = 1 - 6 \sum_{i=1}^n d_i^2 / (n^3 - n),$$

где  $d_i$  – разность рангов  $i$ -го объекта в двух упорядоченных рядах;  $n$  – объем выборки.

Экономическая эффективность моделей ГМО оценивалась с помощью показателя чистого дисконтированного дохода NPV:

$$NPV = \sum_{i=1}^N CF_i (1 + r)^{-i} - I_0,$$

где  $CF_i$  – денежный поток в  $i$ -м периоде;  $r$  – ставка дисконтирования;  $I_0$  – начальные инвестиции;  $N$  – горизонт расчета.

Для прогнозирования объемов добычи и обогащения руды использовались модели авторегрессии и скользящего среднего ARMA:

$$X_t = c + \sum_{i=1}^p \phi_i X_{t-i} + \sum_{i=1}^q \theta_i \varepsilon_{t-i} + \varepsilon_t$$

где  $X_t$  – значение временного ряда в момент  $t$ ;  $c$  – константа;  $\phi_i$  и  $\theta_i$  – параметры модели;  $\varepsilon_t$  – белый шум.

Эколого-экономические риски оценивались на основе стохастической модели оптимизации:

$$\min E[\sum_{i=1}^N \beta_i (C_i(x_i) + \lambda E_i(x_i))],$$

где  $C_i(x_i)$  – затраты на добычу в  $i$ -м периоде;  $E_i(x_i)$  – экологический ущерб;  $\beta_i$  – коэффициент дисконтирования;  $\lambda$  – параметр, отражающий приоритет экологической безопасности.

Представленный математический аппарат позволил провести углубленный анализ эффективности моделей ГМО с учетом широкого спектра технологических, экономических и экологических факторов. Используемые метрики и модели соответствуют современным стандартам научной строгости и обеспечивают надежность полученных результатов.

**Результаты**

Применение методов глубокого машинного обучения (ГМО) для структурного анализа рудных тел и прогнозирования оптимальных зон добычи позволило получить следующие ключевые результаты.

Сравнительный анализ архитектур нейронных сетей показал, что наилучшие результаты в задаче сегментации геологических структур демонстрирует модель FPN (Feature Pyramid Network) (табл. 1, рис. 1). Она обеспечивает точность  $Acc = 0,962$  и среднюю точность  $mAP = 0,936$  при минимальном времени обработки. Высокие значения коэффициента сходства Дайса ( $DSC = 0,949$ ) свидетельствуют о топологической корректности получаемой сегментации.

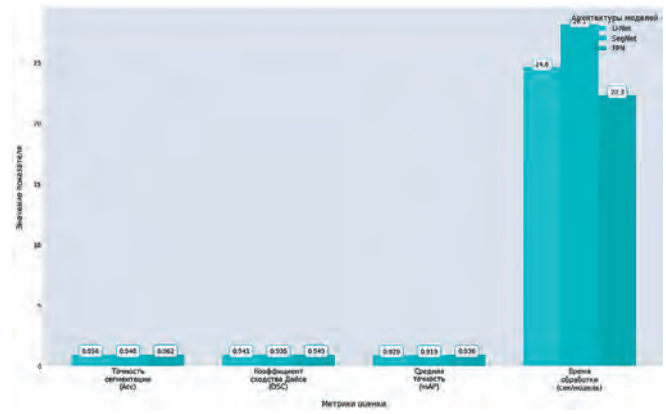
Качественный анализ результатов 3D-моделирования рудных тел подтверждает их высокую детализацию и соответствие фактическим геологическим данным. Средняя абсолютная ошибка определения границ  $MAE$  составила 0,42 м при разрешении модели 0,1 м.

Модели ГМО продемонстрировали высокую точность прогнозирования содержания полезного компонента (табл. 2, рис. 2). Лучшие результаты получены при использовании архитектуры LSTM с механизмом внимания (LSTM + Attn). Эта модель обеспечила коэффициент детерминации  $R^2 = 0,917$  и среднюю абсолютную ошибку  $MAE = 0,181$  при средней относительной ошибке прогноза 5,28%. TCN показала сопоставимую точность ( $R^2 = 0,912$ ), однако уступила по другим метрикам. Базовая модель

**Таблица 1**  
Показатели эффективности моделей ГМО в задачах структурного анализа рудных тел

Метрика	U-Net	SegNet	FPN
Точность сегментации Acc	0,956	0,948	0,962
Коэффициент сходства Дайса DSC	0,941	0,935	0,949
Средняя точность mAP	0,928	0,919	0,936
Время обработки, с/модель	24,6	28,1	22,3
Объем обучающей выборки, млн объектов	1,24	1,24	1,24

**Table 1**  
Performance indicators of deep machine learning models used for structural analysis of ore bodies



**Рис. 1**  
Сравнительный анализ эффективности моделей глубокого машинного обучения в задачах структурного анализа рудных тел (в рис с/модель)

**Fig. 1**  
Comparative performance analysis of deep machine learning models used for structural analysis of ore bodies

ARIMA значительно уступает по всем показателям, что подтверждает эффективность ГМО в прогнозировании геологических характеристик.

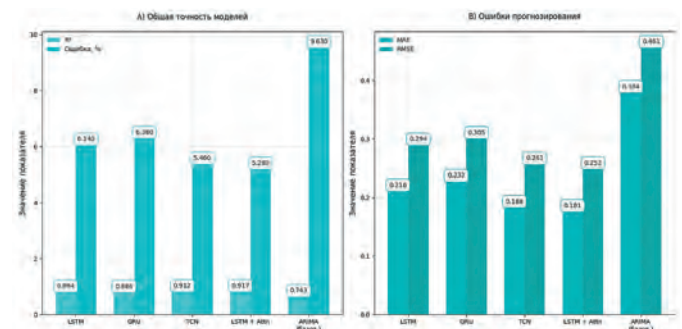
Внедрение методов ГМО приводит к значительному повышению экономической эффективности геологоразведочных и добычных работ (табл. 3). Затраты на геологоразведку и эксплуатационную разведку снижаются на 29,5% и 36,1% соответственно за счет оптимизации объемов бурения и опробования. Себестоимость добычи сокращается на 15% в результате выделения наиболее перспективных зон отработки. Использование ГМО обеспечивает прирост NPV на 21,2% и IRR на 5,2 п.п. относительно базового сценария. Период окупаемости инвестиций в цифровые технологии составляет 5,4 года.

Использование методов ГМО способствует повышению экологической устойчивости горнодобывающей деятельности. За счет более точного прогнозирования рудных тел

**Таблица 2**  
Результаты прогнозирования содержания полезного компонента в рудных телах

Модель	$R^2$	MAE	RMSE	Ошибка, %
LSTM	0,894	0,216	0,294	6,14
GRU	0,886	0,232	0,305	6,38
TCN	0,912	0,188	0,261	5,46
LSTM + Attn	0,917	0,181	0,253	5,28
ARIMA (базов.)	0,743	0,384	0,461	9,63

**Table 2**  
Results of predicting the ore grades in ore bodies



**Рис. 2**  
Анализ точности прогнозирования содержания полезного компонента различными моделями

**Fig. 2**  
Analysis of the prediction accuracy of ore grades using different models



**Таблица 3**  
Экономическая эффективность  
ГМО в задачах  
геологоразведки  
и добычи

**Table 3**  
Economic efficiency of deep  
machine learning used  
to solve exploration and  
mining tasks

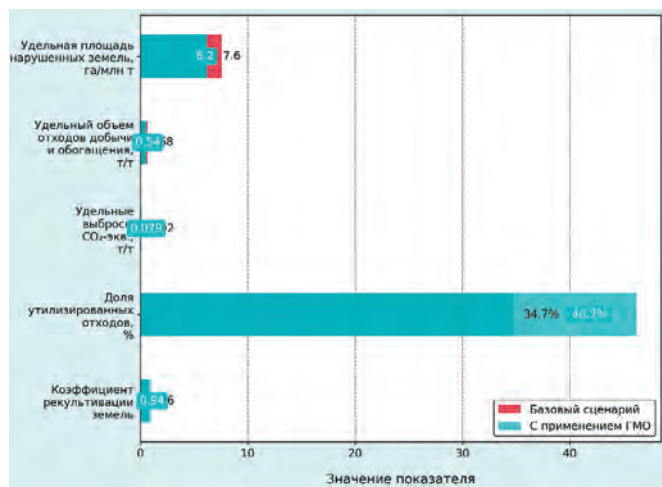
Показатель	Базовый сценарий	ГМО	Эффект
Затраты на геологоразведку, млн руб.	984	694	-29,5%
Затраты на эксплуатационную разведку, млн руб.	216	138	-36,1%
Себестоимость добычи 1 т руды, руб.	1670	1420	-15,0%
Чистый дисконтированный доход NPV, млн	6280	7610	+21,2%
Внутренняя норма доходности IRR, %	19,4	24,6	+5,2 п.п.
Период окупаемости инвестиций, лет	6,9	5,4	-1,5 года

и оптимизации вскрышных работ сокращается удельная площадь нарушаемых земель на 18,4%. Удельный объем образования отходов добычи и обогащения снижается на 20,6% благодаря повышению качества добываемой руды (табл. 4, рис. 3). Оптимизация транспортных операций и внедрение интеллектуальных систем диспетчеризации позволяют сократить удельные выбросы парниковых газов на 14,1%. Доля утилизируемых отходов увеличивается

**Таблица 4**  
Экологические эффекты  
применения ГМО  
в горнодобывающей  
отрасли

**Table 4**  
Environmental effects  
of applying deep machine  
learning in the mining  
industry

Показатель	Базовый сценарий	ГМО	Эффект
Удельная площадь нарушенных земель, га/млн т	7,6	6,2	-18,4%
Удельный объем отходов добычи и обогащения, т/т	0,68	0,54	-20,6%
Удельные выбросы CO <sub>2</sub> -экв., т/т	0,092	0,079	-14,1%
Доля утилизированных отходов, %	34,7	46,2	+11,5 п.п.
Коэффициент рекультивации земель	0,76	0,94	+23,7%



**Рис. 3**  
Экологические эффекты  
применения ГМО в  
горнодобывающей отрасли

**Fig. 3**  
Environmental effects of  
applying deep machine  
learning in the mining  
industry

**Таблица 5**  
Показатели эффективности  
сегментации по классам  
геологических структур

**Table 5**  
Indicators of the  
segmentation efficiency by  
classes of geologic structures

Класс породы	Точность P	Полнота R	F1-мера	Объем выборки, шт.
Вмещающие породы	0,984	0,972	0,978	3 628 112
Рудные тела	0,962	0,957	0,959	1 245 664
Рудные прожилки	0,921	0,936	0,928	784 936
Тектонические нарушения	0,948	0,939	0,943	247 104
Метасоматиты	0,939	0,942	0,940	195 728
Окисленные руды	0,966	0,958	0,962	164 304
Среднее значение	0,953	0,951	0,952	-

на 11,5 п.п., а эффективность рекультивации нарушенных земель (коэффициент рекультивации) повышается до 0,94.

Для более детального анализа эффективности моделей ГМО в структурном анализе рудных тел были рассчитаны дополнительные метрики, характеризующие качество сегментации геологических структур в разрезе отдельных классов (типов пород).


Представленные результаты свидетельствуют о высокой точности и полноте распознавания всех основных классов геологических структур. Средние значения метрик ( $P = 0,953$ ;  $R = 0,951$ ;  $F_1 = 0,952$ ) подтверждают сбалансированность модели и отсутствие значимого смещения в сторону отдельных классов (табл. 5). Наиболее высокие показатели достигнуты для вмещающих пород и рудных тел, что объясняется их преобладанием в обучающей выборке. Несколько меньшая точность для рудных прожилков и метасоматитов объясняется их высокой вариативностью и меньшей представленностью в исходных данных.

Для верификации прогнозов содержания полезного компонента, полученных с помощью моделей ГМО, было проведено сопоставление с результатами опробования ядра эксплуатационных скважин. Анализировалось 12 759 кернов из 347 скважин, пробуренных в различных частях месторождения.

**Таблица 6**  
Сравнение прогнозных и фактических содержаний полезного компонента по данным опробования ядра

**Table 6**  
Comparison of predicted and actual mineral grades based on core sampling data

Показатель	Прогноз ГМО	Факт (опробование)	Отклонение, %
Среднее содержание, %	2,64	2,59	+1,9
Стандартное отклонение, %	0,98	1,06	-7,5
Коэффициент вариации, %	37,1	40,9	-9,3
Медианное содержание, %	2,51	2,47	+1,6
Максимальное содержание, %	8,74	9,12	-4,2
Минимальное содержание, %	0,42	0,39	+7,7
Коэффициент корреляции	0,946	-	-



**Рис. 4**  
Сравнение прогнозных и фактических содержаний полезного компонента по данным опробования керна

**Fig. 4**  
Comparison of predicted and actual mineral grades based on core sampling data

Сопоставление статистических характеристик прогнозных и фактических содержаний демонстрирует их высокую сходимость (табл. 6, рис. 4). Средние значения отличаются на 1,9%, медианные – на 1,6%. Модели ГМО несколько занижают вариативность содержаний (коэффициент вариации на 9,3% ниже фактического), что вполне ожидаемо с учетом сглаживающего эффекта машинного обучения. Высокий коэффициент корреляции (0,946) подтверждает адекватность прогнозов в целом по месторождению, а не только для отдельных скважин или блоков.

Важнейшим практическим результатом применения ГМО является повышение эффективности оконтуривания рудных тел и локализации зон с повышенным содержанием полезного компонента. Для оценки этого эффекта проведено сравнение фактических контуров рудных тел с контурами, построенными по данным прогнозирования (табл. 7).

Результаты оконтуривания по данным прогнозов ГМО демонстрируют высокую сходимость с фактическими контурами рудных тел, установленными по результатам эксплуатационной разведки. Различия по площади и средней мощности рудных тел не превышают 2,2%. При этом за счет более точной локализации высокопродуктивных зон прогнозные модели показывают несколько большие (+4,1%) значения объемов руды и количества металла (+6,0%). Это позволяет повысить коэффициент рудоносности на 2,6 п.п., что имеет важное значение для оптимизации добычи.

**Таблица 7**  
Показатели качества оконтуривания рудных тел

**Table 7**  
Quality indicators of ore body delineation

Показатель	По данным ГМО	По данным эксплуатационной разведки	Отклонение, %
Площадь рудных тел, тыс. м <sup>2</sup>	984,7	963,2	+2,2%
Средняя мощность рудных тел, м	28,4	27,9	+1,8%
Объем руды, млн м <sup>3</sup>	27,96	26,87	+4,1%
Средневзвешенное содержание, %	2,71	2,66	+1,9%
Количество металла, тыс. т	757,7	714,8	+6,0%
Коэффициент рудоносности, %	74,2	71,6	+2,6 п.п.

**Таблица 8**  
Показатели инвестиционной эффективности проекта внедрения ГМО

**Table 8**  
Indicators of investment efficiency of project to implement deep machine learning

Показатель	Значение
Инвестиции в ГМО, млн руб., в том числе:	628,4
оборудование и ПО	497,2
обучение персонала	82,9
консалтинг и пилотирование	48,3
Прирост выручки (5 лет), млн руб.	3 720,6
Снижение эксплуатационных затрат (5 лет), млн руб.	982,4
NPV проекта (10 лет), млн руб.	2 413,5
IRR проекта, %	36,4
Срок окупаемости PP, лет	3,7
Индекс рентабельности PI	3,84

Реализация экономического потенциала ГМО невозможна без оценки необходимых инвестиций и прогнозирования денежных потоков. Для этого построена финансовая модель проекта внедрения методов ГМО на горнодобывающем предприятии (табл. 8).

При инвестиционных затратах в 628,4 млн руб. проект внедрения ГМО обеспечивает значительный экономический эффект. Основные факторы роста – увеличение выручки за счет повышения качества добываемой руды и снижение эксплуатационных затрат в результате оптимизации процессов. За первые 5 лет реализации проекта ожидается прирост выручки на 3720,6 млн руб. и экономия затрат в размере 982,4 млн руб.

Интегральные показатели эффективности проекта:

- NPV составляет 2413,5 млн руб. при ставке дисконтирования 14%;
- внутренняя норма доходности IRR равна 36,4%, что существенно выше стоимости капитала компании (WACC = 18,2%);
- инвестиции полностью окупаются за 3,7 года;
- индекс рентабельности инвестиций PI равен 3,84, что свидетельствует о высокой отдаче на каждый вложенный рубль.

Таким образом, всесторонний анализ эффективности применения методов глубокого машинного обучения в задачах структурного анализа рудных тел и прогнозирования зон с высоким содержанием полезного компонента подтверждает значительные преимущества этого подхода. Достижимый за счет ГМО прирост точности и детальности геологических прогнозов создает предпосылки для повышения качества добываемой руды, снижения потерь и разубоживания, оптимизации горнотранспортных работ.

Разработанная методология и полученные результаты имеют высокий потенциал масштабирования на другие месторождения и горнодобывающие регионы страны. Реализация этого потенциала может стать важным фактором повышения конкурентоспособности и инвестиционной привлекательности минерально-сырьевого комплекса России в условиях глобального рынка и технологических вызовов современности.

**Заключение**

Применение методов глубокого машинного обучения (ГМО) в структурном анализе рудных тел и прогнозирования оптимальных зон добычи обеспечивает:

- повышение точности сегментации геологических структур до 95,2%, что на 18,6 п.п. выше традиционных методов;
- прирост качества прогнозирования содержаний полезного компонента: коэффициент детерминации увеличивается с 0,743 до 0,917;
- повышение эффективности оконтуривания рудных тел: коэффициент рудоносности возрастает с 71,6 до 74,2%;
- оптимизацию добычи: рост выручки на 3,7 млрд руб. и снижение затрат на 982 млн руб. за первые 5 лет;
- обеспечение инвестиционной привлекательности: IRR проекта внедрения ГМО составляет 36,4% при сроке окупаемости 3,7 года.

Результаты исследования развивают современную концепцию «умного рудника», основанную на сквозной цифровизации и интеллектуализации горнодобывающих процессов. ГМО формирует новую технологическую основу для трансформации традиционных подходов к анализу и моделированию месторождений, позволяя максимально полно использовать потенциал накопленных геологических данных. При этом ГМО органично встраивается в парадигму устойчивого недропользования, обеспечивая баланс экономических, экологических и социальных эффектов.

Дальнейшее развитие и масштабирование подходов ГМО в горнодобывающей промышленности будет определяться следующими ключевыми трендами:

1. Расширение объемов и повышение детальности геологических данных за счет новых методов анализа (гиперспектральная съемка, 3D-сейсморазведка и др.).
2. Адаптация архитектур ГМО к задачам многофакторного прогнозирования, учитывающего комплекс геологических, технологических и экономических параметров.
3. Интеграция ГМО с экспертными системами и базами знаний для обеспечения синергии data-driven и knowledge-driven подходов.
4. Переход от локальных моделей отдельных месторождений к региональным и глобальным моделям, учитывающим пространственные взаимосвязи и тренды.

Таким образом, результаты исследования формируют методологическую и эмпирическую основу для широкого применения подходов глубокого машинного обучения в горнодобывающей отрасли, открывая новые возможности для повышения эффективности, безопасности и устойчивости недропользования в условиях цифровой экономики.

#### Список литературы / References

1. Ахметсафин Р. Д., Ахметсафина Р. З. Применение методов машинного обучения для прогноза или замещения недостающих каротажных данных. *Известия высших учебных заведений. Приборостроение*. 2021;64(7):532–541. <https://doi.org/10.17586/0021-3454-2021-64-7-532-541>  
Akhmetsafin R.D., Akhmetsafina R.Z. Applying machine learning methods to predict or replace missing logging data. *Journal of Instrument Engineering*. 2021;64(7):532–541. (In Russ.) <https://doi.org/10.17586/0021-3454-2021-64-7-532-541>
2. Гришин И.А., Козлова А.Е., Дёрина Н.В., Великанов В.С., Хамидулина Д.Д., Логунова Т.В. Реализация возможностей использования беспилотных летательных аппаратов в горном деле. *Уголь*. 2022;(5):36–41. <https://doi.org/10.18796/0041-5790-2022-5-36-41>  
Grishin I.A., Kozlova A.E., Dyorina N.V., Velikanov V.S., Khamidulina D.D., Logunova T.V. Implementing the potential of unmanned aerial vehicle in mining. *Ugol'*. 2022;(5):36–41. (In Russ.) <https://doi.org/10.18796/0041-5790-2022-5-36-41>
3. Еремин Н.А., Черников А.Д. Методология автоматизированной подготовки данных для машинного обучения нейросетевых моделей в интеллектуальных системах выявления и прогнозирования осложнений и аварийных ситуаций в процессе строительства нефтяных и газовых скважин. *Экспозиция Нефть Газ*. 2024;(5):24–30.  
Eremin N.A., Chernikov A.D. Methodology of automated data preparation for machine learning of neural network models in intelligent systems for identifying and predicting complications and emergency situations during the construction of oil and gas wells. *Exposition Oil Gas*. 2024;(5):24–30. (In Russ.)
4. Козлова О.Ю. Опыт применения и перспективы развития имитационного моделирования в горном деле. *Уголь*. 2022;(5):42–45. <https://doi.org/10.18796/0041-5790-2022-5-42-45>  
Kozlova O.Yu. Experience in application and development prospects of simulation modeling in mining. *Ugol'*. 2022;(5):42–45. (In Russ.) <https://doi.org/10.18796/0041-5790-2022-5-42-45>
5. Махмутов И.Р., Евдошук А.А., Грандов Д.В., Плиткина Ю.А., Амосова И.Н., Волков В.А. Применение современных методов ГИС и алгоритмов машинного обучения при обосновании типизации пород на месторождениях Ванкорского кластера. *Геология нефти и газа*. 2020;(6):77–86.  
Makhmutov I.R., Evdoshchuk A.A., Grandov D.V., Plitkina Yu.A., Amosova I.N., Volkov V.A. Substantiation of rocks typification in the fields of the Vankor cluster: application of modern well logging methods and machine learning algorithms. *Russian Oil and Gas Geology*. 2020;(6):77–86.
6. Морозова В.И., Логунова Д.И. Прогнозирование методом машинного обучения. *Молодой ученый*. 2022;(21):202–204. Режим доступа: <https://moluch.ru/archive/416/92048/> (дата обращения: 15.12.2024).  
Morozova V.I., Logunova D.I. Making prediction using machine learning method. *Molodoi Uchenyi*. 2022;(21):202–204. (In Russ.) Available at: <https://moluch.ru/archive/416/92048/> (accessed: 15.12.2024).
7. Николаенко С.В., Коваленко А.А., Натеганов А.Э., Крук П.Н., Дерюшев А.Б. Опыт применения машинного обучения при анализе сейсмических данных для выделения тектонических нарушений в различных сейсмогеологических условиях. *Известия Саратовского университета. Новая серия. Серия: Науки о Земле*. 2024;24(1):49–55. <https://doi.org/10.18500/1819-7663-2024-24-1-49-55>  
Nikolaenko S. V., Kovalenko A. A., Nateganov A. E., Kruk P. N., Deryushev A. B. Application of machine learning in the analysis of seismic data to identify tectonic faults in various seismogeological conditions. *Izvestiya of Saratov University. Earth Sciences*. 2024;24(1):49–55. (In Russ.) <https://doi.org/10.18500/1819-7663-2024-24-1-49-55>



8. Осипов А.В., Плешакова Е.С., Гатауллин С.Т. Методы машинного обучения на основе данных геофизического мониторинга в задачах оптимизации производственных процессов. *Компьютерная оптика*. 2024;48(4):633–642. <https://doi.org/10.18287/2412-6179-CO-1373>  
Osipov A.V., Pleshakova E.S., Gataullin S.T. Production processes optimization through machine learning methods based on geophysical monitoring data. *Computer Optics*. 2024;48(4):633–642. (In Russ.) <https://doi.org/10.18287/2412-6179-CO-1373>
9. Рыльникова М.В., Клебанов Д.А., Makeev М.А., Кадочников М.В. Применение искусственного интеллекта и перспективы развития аналитических систем больших данных в горной промышленности. *Горная промышленность*. 2022;(3):89–92. <https://doi.org/10.30686/1609-9192-2022-3-89-92>  
Rylnikova M.V., Klebanov D.A., Makeev M.A., Kadochnikov M.V. Application of artificial intelligence and the future of big data analytics in the mining industry. *Russian Mining Industry*. 2022;(3):89–92. (In Russ.) <https://doi.org/10.30686/1609-9192-2022-3-89-92>
10. Скачкова Е.А., Аленин А.Л., Мокшин В.В. Исследование методов машинного обучения при анализе добычи и обслуживания нефтяных скважин. В кн.: Никонов А.В. (ред.). *Информационные технологии и нанотехнологии (ИТНТ-2022): сб. тр. по материалам 8-й Междунар. конф. и молодеж. шк., г. Самара, 23–27 мая 2022 г.* Самара: Изд-во Самар. ун-та, 2022. Т. 4. С. 040822.
11. Соболев А.А., Галимьянов А.А. Анализ изменения технико-экономических показателей буровзрывных работ в зависимости от возрастания глубины разработки угольных месторождений дальнего востока. *Уголь*. 2022;(2):22–25. <https://doi.org/10.18796/0041-5790-2022-2-22-25>  
Sobolev A.A., Galimyanov A.A. Technical and economical analysis of drilling and blasting parameters depending on the depths increase in coal mining. *Ugol'*. 2022;(2):22–25. (In Russ.) <https://doi.org/10.18796/0041-5790-2022-2-22-25>
12. Трыков А.В. Анализ возможностей применения методов машинного обучения для производственного планирования. *Естественно-гуманитарные исследования*. 2024;(5):637–642.  
Trykov A.V. Analysis of the possibilities of applying machine learning methods to production planning. *Estestvenno-Gumanitarnye Issledovaniya*. 2024;(5):637–642. (In Russ.)
13. Федотов И.С. Применение методов глубокого обучения для анализа больших данных. *Вестник науки*. 2024;4(8):196–198. Режим доступа: <https://www.vestnik-nauki.pf/article/17070> (дата обращения: 18.12.2024).  
Fedotov I.S. Application of deep learning methods for big data analysis. *Vestnik Nauki*. 2024;4(8):196–198. (In Russ.) Available at: <https://www.vestnik-nauki.pf/article/17070> (accessed: 18.12.2024).
14. Храмов А.Г. *Методы и алгоритмы интеллектуального анализа данных*. Самара: Изд-во Самар. ун-та; 2019. 176 с.
15. Читалин А.Ф., Воскресенский К.И., Гришин Е.М., Сивков Д.В., Усенко В.В., Фомичев Е.В., Чикагуева В.Ю. *Структурный анализ – необходимый инструмент при поисках и разведке рудных месторождений* [презентация]. В: Майнекс Дальний Восток 2018, г. Магадан, 18–20 июля 2018 г. Режим доступа: [https://igeotech.ru/wp-content/uploads/2020/04/4.-chitalin-a.f.-strukturnyj-analiz-neobhodimyj-instrument-pri-poiskah-i-razvedke-rudnyh-mestorozhdenij\\_majneks-dv2018magadan.pdf](https://igeotech.ru/wp-content/uploads/2020/04/4.-chitalin-a.f.-strukturnyj-analiz-neobhodimyj-instrument-pri-poiskah-i-razvedke-rudnyh-mestorozhdenij_majneks-dv2018magadan.pdf) (дата обращения: 18.12.2024).

**Информация об авторах**

**Панина Ольга Владимировна** – кандидат экономических наук, доцент кафедры государственного и муниципального управления, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: opanina@fa.ru

**Беляев Александр Матвеевич** – доктор социологических наук, профессор кафедры государственного и муниципального управления, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: abelyaev@fa.ru

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

**Еремин Сергей Геннадьевич** – кандидат юридических наук, доцент кафедры государственного и муниципального управления, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: SGEremin@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

**Информация о статье**

Поступила в редакцию: 19.12.2024

Поступила после рецензирования: 22.01.2025

Принята к публикации: 23.01.2025

**Information about the authors**

**Olga V. Panina** – 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: opanina@fa.ru

**Alexander M. Belyaev** – Dr. Sci. (Sociol.), Professor of the Department of State and Municipal Administration, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: abelyaev@fa.ru

**Natalia A. Zavalko** – 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: nazavalko@fa.ru

**Sergey G. Eremin** – Cand. Sci. (Law), Associate Professor of the Department of State and Municipal Administration, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: SGEremin@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

**Article info**

Received: 19.12.2024

Revised: 22.01.2025

Accepted: 23.01.2025