

АНАЛИЗ СОВРЕМЕННЫХ СПОСОБОВ ПРИКЛАДНОГО ИСПОЛЬЗОВАНИЯ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ В ГОРНОЙ ПРОМЫШЛЕННОСТИ

*И.В. Артемов, М.Б. Носырев,
Уральский государственный горный университет, Екатеринбург, Россия*

Аннотация: Сверточные нейронные сети являются одним из наиболее широко используемых методов машинного обучения в сфере обнаружения и классификации объектов на изображениях. Они могут быть применены для широкого класса задач, в том числе и в сфере горной промышленности. В статье проанализированы некоторые знаковые примеры того, как сверточные сети могут упрощать и увеличивать качество выполнения задач, связанных с горнодобывающей отраслью.

Ключевые слова: горная промышленность, обнаружение месторождений, обнаружение объектов, нейронные сети, машинное обучение, автоматическая классификация ископаемых.

Благодарности: Коллектив авторов выражает благодарность преподавательскому и руководящему составу Уральского государственного горного университета.

Для цитирования: Артемов И. В., Носырев М. Б. Анализ современных способов прикладного использования сверточных нейронных сетей в горной промышленности // Маркшейдерия и недропользование. 2024. №1. С. 90-94. DOI: 10.56195/20793332_2024_1_90_94.

ANALYSIS OF MODERN ENGINEERING APPLICATIONS OF CONVOLUTIONAL NEURAL NETWORKS IN MINING INDUSTRY

*I.V. Artemov, M.B. Nosyrev,
Ural State Mining University, Yekaterinburg, Russia*

Abstract: Currently there are a lot of image recognition tasks, that are being successfully solved by the use of different types of neural networks. In its turn, the leading type of neural networks architecture for mentioned tasks class is convolutional neural network (CNN).

Convolutional neural networks consist of multiple layers with small sets of neurons. Each of the neurons represents a small part of the original image. Combining all sets of neurons in a layer gives us a complete representation of the image. Other layers repeat this algorithm, but work with the same image presented in a different way, allowing the system as a whole to «learn» what the picture ultimately consists of. For example, each of the convolution layers can be responsible for highlighting certain features in the image (contour lines, flat areas, sharp edges).

Research results. In this article we present a classification of groups, that reflect main directions of neural networks usage in mining industry. Different examples of implemented real-world use-cases were presented. Some important CNN-algorithm alterations were mentioned and explained.

Conclusion. As we can see, many major mining process stages are positively affected by the usage of convolutional neural network. Machine learning algorithms help to find illegal deposits, maintain security and stability while mining and mineral processing goes on. Neural networks are being successfully trained by researchers to work with satellite map pictures, mineral surface photos and plots of signals from various engineering equipment.

It is worth mentioning, that many researchers work for solving similar industry problems, but every time they have to slightly (or drastically) change CNN algorithm details to complete the tasks for the certain material type or certain GIS object type.

Resume. The high growth rate of popularity of neural networks in the mining industry was made possible due to many factors. For example, the accumulation of large amounts of digital data (satellite images, dependency graphs, photo and video materials from real-world objects) has made the process of selecting materials for CNN training and testing easier and more efficient.

Keywords: mining industry, mineral deposits detection, object detection, neural networks, machine learning, automatic fossil classification.

Acknowledgment: The team of authors expresses gratitude to the teaching and management staff of the Ural State Mining University.

For citation: : Artemov I.V., Nosyrev M.B. Analysis of modern engineering applications of convolutional neural networks in mining industry. Surveying and subsoil use. 2024;(1):90-94.(In Russ.). DOI: 10.56195/20793332_2024_1_90_94.

В настоящее время множество задач распознавания изображений успешно решаются с использованием различных видов нейронных сетей. В свою очередь лидирующим типом архитектуры построения сетей для данного класса задач является сверточная нейронная сеть (Convolutional Neural Network или CNN).

Сверточные нейронные сети состоят из нескольких слоев с небольшими наборами нейронов. Каждый из нейронов представляет небольшую часть исходного изображения. Объединение всех наборов нейронов на слое в результате дает полное представление изображения. Другие слои повторяют этот алгоритм, но работают с тем же изображением, представленным (описанным) другим способом, позволяя системе в целом изучать то, из чего в итоге состоит картинка.

К примеру, каждый из слоев свертки может отвечать для выделения определенных признаков в изображении (линий-контуров, плоских участков, резких краев). В обобщенном виде функция свертки исходного изображения X с ядром свертки g (матрица коэффициентов размером $2K+1$ на $2L+1$) может быть записана так:

$$(X \times g)[m, n] = \sum_{k=-K}^K \sum_{l=-L}^L f[m-k, n-l] \times g[k+K, l+L].$$

История применения CNN в машинном обучении началась в ранних 1980-х, но только в 2010-х исследователи смогли добиться по-настоящему высоких результатов в решении задач распознавания изображений, что во многом связано с возможностью использования высокопроизводительных видеоадаптеров для тренировки и запуска CNN. Нарастание объема баз данных с готовыми наборами изображений для тренировки и тестирования нейронных сетей также позволили улучшить ситуацию.

Как результат, сверточные нейронные сети стали успешно помогать людям в решении все большего многообразия прикладных задач.

Цель исследований

Выделить и описать области горнодобывающей промышленности, которые наиболее сильно были оптимизированы благодаря применению сверточных нейронных сетей за последние несколько лет. Частично обобщить имеющийся опыт по успешному прикладному применению нейронных сетей в данной отрасли.

Материал и методы исследований

В данной работе были найдены и проанализированы относительно новые публикации по горнодобывающей тематике, в которых делался акцент на полезном эффекте от применения нейронных сетей в данной отрасли. Предпочтение отдавалось материалам, в которых описывалась конкретная разновидность нейросетевых алгоритмов — сверточные нейронные сети (как один из основных модулей, применяющийся в современном компьютерном зрении).

В результате удалось выделить несколько логических групп применений CNN в горном деле: многие авторы находят нейросети полезными при анализе карт, обработке фотоматериалов о добываемых породах, а также при навигации техники на местах добычи.

Результаты исследований

Сверточные сети для обнаружения объектов горной промышленности на карте

Нейронные сети часто используются для обработки данных геоинформационных систем (ГИС) [1-3]. Обнаружение

и анализ геообъектов, относящихся к горнодобывающей отрасли, также успешно осуществляются с помощью этого инструмента.

Например, авторы [4] успешно использовали сверточную нейронную сеть для обнаружения заброшенных шахт, использовавшихся для добычи золота в I-III веках нашей эры. Алгоритм был натренирован таким образом, чтобы анализировать снимки с дронов и обнаруживать элементы ландшафта, которые в прошлые века с большой вероятностью размещались неподалеку от всех шахт. Из-за высокой угрозы обрушения поиск таких объектов является важной задачей.

Авторы [5] представляют систему, в которой CNN используется для обнаружения нелегально разрабатываемых угольных шахт открытого типа. Система анализирует спутниковые снимки из открытого источника Sentinel-2 (для подготовки обучающих данных был использован тот же источник). В качестве особенности своего алгоритма авторы называют присутствие второго сверточного слоя. В работе [6] также описан процесс поиска угольных шахт (не обязательно нелегальных) на спутниковых снимках, но найденные объекты анализируются с точки зрения плотности их размещения для последующей оценки интенсивности выбросов СН4 (метана) в атмосферу.

Похожие цели преследуют авторы [7], обнаруживая при помощи сверточной сети кустарные места разработки полезных ископаемых на территории Западной Африки. Здесь подробно рассказано о методе подбора обучающих изображений, были проанализированы снимки 6 миллионов гектаров на протяжении четырех лет, с разбиением по 1 году.

В упомянутых выше работах основным источником данных для обучения нейросети и итогового анализа являются спутниковые снимки. В работе [8] предложен концептуально иной подход к георазведке с применением искусственного интеллекта — нейросеть анализирует аномалии в графике напряженности электрического поля на местности и тем самым прогнозирует вероятность присутствия в грунте углеводородных залежей.

В работе [9] используется модифицированная нейронная сеть (используется термин «semisupervised» — «частично контролируемая») для построения приближенной трехмерной модели скважины на основе небольшого числа входных параметров (географические координаты, толщина верхних слоев грунта, модели уже просчитанных близлежащих скважин).

Нейронные сети для анализа качества и определения типов добываемых пород

CNN отлично подходят для анализа фотоматериалов, в большом объеме получаемых при контроле качества добытых пород, а также при начальном изучении месторождений.

К примеру, в работе [10] описана методология разработки и применения сверточной сети, способной анализировать изображения срезов породы и логически отделять области с углем от областей с обыкновенной каменной текстурой. Авторы отмечают, что лучшие результаты показала модель, у которой был искусственно устранен эффект перетренировки (к значениям слишком высоких весовых коэффициентов применялась специальная функция модификации их стоимости).

Улучшение уже функционировавшей на то время системы автоматизации задач нефтегазовой и рудной отраслей

под названием DeepCore реализовали авторы [11]. Сверточная сеть, подключенная к ПО, ускорила процесс распознавания конкретного вида добытой породы примерно в 20 раз. Основное ускорение было достигнуто за счет обучения с аугментацией (т. е. для обучения нейронной сети используются не только реальные данные, но и алгоритмически модифицированные изображения).

В работе [12] описывается достаточно большой перечень производственных моментов цикла «Mine to Mill» (M2M, «от добычи до обработки» — подход к совместной работе специалистов разных этапов добычи пород), в которых успешно использовано машинное обучение. К примеру, нейронные сети помогают анализировать размер гранул материалов (гранулометрия) для автоматического выявления нежелательных крупных фракций материалов. Одна из систем производственных систем имеет возможность распознавания металлических осколков, возникающих при износе добывающего оборудования, на производственную линию.

Авторы [13] приводят результаты применения CNN в задачах построения литологических моделей горных пород, т. е. автоматического создания трехмерной карты с контурами разных типов пород на анализируемом участке недр. Результатом работы нейросети является модель месторождения, состоящая из элементарных блоков. Об успешном создании подобной системы, составляющей «атомарную» модель распределения полезных ископаемых на участках рудного тела, говорится и в работе [14].

В работе [15] авторы используют нейронную сеть для анализа состояния резервуаров с нефтью (в работе «резервуаром» называется «капсула» из каменной породы, которая и составляет нефтяное месторождение). В качестве показателей для анализа и обучения использовалась насыщенность хранимого вещества, пористость материала стенок, тип материала стенок (анализировались две породы: песчаник и известковая глина).

Сверточные сети для анализа безопасности добычи и транспортировки

Достаточно много работ посвящено еще одному популярному применению CNN — анализу закономерностей и аномалий во временных рядах.

Так, в работе [16] в общем виде описывается принцип анализа большого количества сигналов тревоги, поступающих от горного оборудования в единицу времени. Нейронная сеть может в целом оценивать состояние оборудования по потоку сигналов, а также прогнозировать вероятное состояние техники в последующие моменты времени. Об улучшенной методике (Process Mining) анализа потока событий при помощи сверточной нейронной сети также говорят авторы [17].

Работа [18] посвящена прогнозированию вероятных микросейсмических явлений в глубоких шахтах (система мониторинга «геостресса»). CNN изучает формы фронтов сейсмических волн (после их визуализации измеряющим прибором) и на основе собранных данных предсказывает возникновение микроударов. В работе [19] также изучается

возможность анализа сейсмических явлений, порожденных процессом добычи полезных ископаемых, посредством CNN. Нейросеть работала с данными, предоставляемыми Сейсмической сетью Южной Калифорнии (SCSN), а затем дополнительно обучалась на сейсмических данных от другого источника.

В работе [20] приводятся данные об успешной разработке нейросетевого алгоритма, позволяющего спрогнозировать состояние магистрального газопровода (вероятный объем повреждений от коррозии) в зависимости от значений нескольких показателей: расстояния до компрессорной станции, уровня кислотности среды грунта и др.

Сверточные сети для навигации подземной и наземной техники

Применение CNN не ограничивается анализом статичных цифровых изображений и графиков. Современные аппаратные компоненты вполне позволяют сверточным сетям осуществлять обработку видеопотока. Это, в свою очередь, позволяет обнаруживать объекты на видеозаписях, получаемых с регистраторов, устанавливаемых на подвижной георазведывательной и горнодобывающей технике.

В работе [21] приводятся сведения об алгоритме, основанном на CNN, который помогает процессу навигации миниатюрных летательных аппаратов при их перемещении в подземных шахтах (метод был испытан на настоящих подземных объектах в Швеции). В данном случае нейросеть обучалась на двух связанных наборах данных: большой объем реальных фотографий подземных тоннелей, к каждой из которых прикреплялась заранее просчитанная «карта глубины». В результате аппарат учился строить приблизительную карту глубины в реальном времени и избегать столкновений с препятствиями.

Авторы [12] в своей работе демонстрируют снимок из интерфейса нейросетевой системы, способной классифицировать образцы техники (самосвалы, погрузчики, бурильные установки), находящиеся в кадре камеры видеонаблюдения в карьере.

Заключение

В настоящее время нейронные сети находят все большее применение практически во всех отраслях человеческой деятельности. Геологическая разведка, анализ горных пород, оптимизация процессов и обеспечение безопасности функционирования при добыче не стали исключениями.

Высокие темпы роста популярности нейронных сетей в горной промышленности стали возможными благодаря многим факторам. К примеру, накопление больших объемов цифровых данных (спутниковые снимки, графики зависимостей, фото- и видеоматериалы с реальных разрабатываемых объектов) сделало более легким и эффективным процесс подбора материалов для обучения и тестирования CNN. Несмотря на рост стоимости многих полупроводниковых изделий, раздобыть аппаратуру (например, высокопроизводительный видеоадаптер) для тренировки и запуска нейросетевых алгоритмов стало проще. ■

ЛИТЕРАТУРА

1. Singer, D.A. Use of a neural network to integrate geoscience information in the classification of mineral deposits and occurrences / D.A. Singer, R. Kouda // *Geophysics and Geochemistry at the Millenium, Abstracts*. - Canada, 1997. - С. 127-134.
2. Brown, W. Artificial Neural Networks: A New Method for Mineral Prospectivity Mapping / W. Brown, T. Gedeon, D.I. Groves // *Australian Journal of Earth Sciences*. - 2000. - Vol. 47, № 4. - С. 757-770.

3. Замай, С.С. Нейронные сети и ГИС // Основы геоинформатики: Учеб. пособие / С.С. Замай, В.А. Охонин, О.Э. Якубайлик. - М.: Академия, 2004. - С. 255-266.
4. Fernandez-Alonso, D. Convolutional neural networks for accurate identification of mining remains from UAV-derived images / D. Fernandez-Alonso, J. Fernandez-Lozano, M. Garcia-Ordas // *Applied Intelligence*. - 2023. - Vol. 53. - P. 211-225.
5. Liy, Y. A lightweight convolutional neural network based on dense connection for open-pit coal mine service identification using the edge-cloud architecture / Y. Liy, J. Zhang // *Journal of Cloud Computing: Advances, Systems and Applications*. - Vol. 12. - P. 32-47.
6. Madhuanad, L. A Deep convolutional neural networks for surface coal mines determination from sentinel-2 images / L. Madhuanad, P. Sadavarte, J. Visschedijk // *European Journal of Remote Sensing*. - 2021. - Vol. 54, № 1. - P. 296-309.
7. Gallwey, J. A Sentinel-2 based multispectral convolutional neural network for detecting artisanal small-scale mining in Ghana: Applying deep learning to shallow mining / J. Gallwey, C. Robiati, J. Coggan // *Remote Sensing of Environment*. - 2020. - Vol. 248. - P. 415-439.
8. Янкушевич, В.Ф. Использование нейронных сетей в геоэлектроразведке на основе метода регистрации границ углеводородных залежей по аномальным изменениям напряжённости электрического поля на двух частотах / В.Ф. Янкушевич, Т.А. Алексеева // Актуальные проблемы физики, электроники и энергетики: Сб. статей I Межд. науч.-практ. конф. (Новополоцк, 27-28 окт. 2022 г.). - Новополоцк, 2023. - С. 124-127.
9. GeoPDNN: A Semisupervised Deep Learning Neural Network Using Pseudolabels for Three-dimensional Urban Geological Modelling and Uncertainty Analysis from Borehole Data / J. Guo, X. Xu, X. Wang [et al.] // *Geoscientific Model Development. Discussions*. - 2023. - Vol. 11. - P. 220-241.
10. A Deep Convolutional Neural Network Model for Intelligent Discrimination between Coal and Rocks in Coal Mining Face / L. Si, X. Xiong, Z. Wang, C. Tan // *Mathematical Problems in Engineering [Electronic Resourse]*. - 2020. - P. 115-127. URL: <https://www.hindawi.com/journals/mpe/2020/2616510/>
11. Core box image recognition and its improvement with a new augmentation technique / E.E. Baraboshkin, A.E. Demidov, D.M. Orlov, D.A. Korotev // *Computers & Geosciences*. - 2022. - Vol. 162. - P. 1034-1038.
12. Андреева, Е. Инновации для горной промышленности / Е. Андреева // *Control engineering Russia. 2023 [Электронный ресурс]*. - Режим доступа: <https://www.reksoft.ru/blog/2023/08/28/mining-innovations/> (дата обращения: 30.11.2023).
13. Мельниченко, И.А. Пространственное районирование месторождений полезных ископаемых / И.А. Мельниченко, Ю.В. Кириченко // Горный информационно-аналитический бюллетень. - 2021. - № 4. - С. 46-56.
14. Земскова, К. Нейросеть поможет искать полезные ископаемые / К. Земскова // *InScience*. - 20.09.2023. [Электронный ресурс]. - Режим доступа: <https://inscience.news/ru/article/russian-science/14336> (дата обращения: 30.11.2023).
15. Malvic, T. Neural networks in petroleum geology as interpretation tools / T. Malvic, J. Velic, J. Horvath // *Central European Geology*. - 2010. - Vol. 53, № 1. - P. 97-115.
16. Ибраева, Н. Анализ сферы применения нейронных сетей в горных машинах / Н. Ибраева // *Горное оборудование и электромеханика*. - 2021. - № 6 (158). - С. 21-25.
17. Obodoekwe, E. Convolutional Neural Networks in Process Mining and Data Analytics for Prediction Accuracy / E. Obodoekwe, X. Fang, K. Lu // *Electronics*. - (нет года). -Vol. 11. - P. 2128-2141.
18. Dong, L. Discrimination of mining microseismic events and blasts using convolutional neural networks and original waveform / L. Dong, Z. Tang, X. Li // *J. Cent. South University Technologies*. - 2020. - T. 27. - C. 3078-3089.
19. Johnson, S.W. Application of a convolutional neural network for seismic phase picking of mining-induced seismicity / S.W. Johnson, D.J. Chambers, M.S. Boltz // *Geophys J Int*. - 2021. - Vol. 224, № 1. - P. 230-240.
20. Хасанов, И.И. Обзор применения нейросетей в области добычи и транспорта нефти и газа / И.И. Хасанов, З.Р. Хасанова, Р.А. Шакиров // *Транспорт и хранение нефтепродуктов*. - 2022. - №3-4. - С. 11-15.
21. Mansouri, S.S. Vision-based MAV Navigation in Underground Mine Using Convolutional Neural Network / S.S. Mansouri, P. Karvelis, C. Kanellakis // *IECON 2019 - 45th Annual Conference of the IEEE Industrial Electronics Society, Lisbon, Portugal*. - Lisbon, 2019. - P. 750-755.

REFERENCES

1. Singer D.A, Kouda R. Use of a neural network to integrate geoscience information in the classification of mineral deposits and occurrences. *Geophysics and Geochemistry at the Millenium, Abstracts*. 1997:127-134.
2. Brown W., Gedeon T., Groves D.I. Artificial Neural Networks: A New Method for Mineral Prospectivity Mapping // *Australian Journal of Earth Sciences*, v. 47, № 4, 2000, p. 757-770.
3. Zamay SS, Ohonin VA, Yakubaylik OE Neural Networks and GIS // *Tutorial Basics of Geoinformatics*. Moscow, 2004: 255-266. (In Russ).
4. Fernandez-Alonso D, Fernandez-Lozano J, Garcia-Ordas M. Convolutional neural networks for accurate identification of mining remains from UAV-derived images. *Applied Intelligence*. 2023;53:211-225.
5. Liy Y, Zhang J. A lightweight convolutional neural network based on dense connection for open-pit coal mine service identification using the edge-cloud architecture. *Journal of Cloud Computing: Advances, Systems and Applications*. 12:32-47.
6. Madhuanad L, Sadavarte P, Visschedijk J. Deep convolutional neural networks for surface coal mines determination from sentinel-2 images. *European Journal of Remote Sensing*. 2021;54(1):296-309.
7. Gallwey J, Robiati C, Coggan J. A Sentinel-2 based multispectral convolutional neural network for detecting artisanal small-scale mining in Ghana: Applying deep learning to shallow mining. *Remote Sensing of Environment*. 2020;248:415-439.
8. Yankushevich VF, Alekseeva TA. Research of neural networks in geoelectroprospecting based on a method of edge registration of hydrocarbon deposits by anomaly changes in electric field strength at two frequencies. Actual problems of physics, electronics and energetics. *Collection of articles of the I International Scientific and Practical Conference*. Novopolotsk, 2023:124-127.

9. Guo J, Xu X, Wang X. GeoPDNN: A Semisupervised Deep Learning Neural Network Using Pseudolabels for Three-dimensional Urban Geological Modelling and Uncertainty Analysis from Borehole Data. *Geoscientific Model Development. Discussions*. 2023;11:220-241.
10. Si L, Xiong X, Wang Z et al. A Deep Convolutional Neural Network Model for Intelligent Discrimination between Coal and Rocks in Coal Mining Face. *Mathematical Problems in Engineering*. 2020. Available from: <https://www.hindawi.com/journals/mpe/2020/2616510/>.
11. Baraboshkin E.E, Demidov AE, Orlov DM et al. Core box image recognition and its improvement with a new augmentation technique. *Computers & Geosciences*. 2022;162:1034-1038.
12. Andreeva E. Innovations for the mining industry. *Control engineering Russia*. 2023. Available from: <https://www.reksoft.ru/blog/2023/08/28/mining-innovations/> (In Russ).
13. Melnichenko IA, Kirichenko UV. Spatial zoning of mineral deposits. *GIAB. Mining information and analytical bulletin*. 2021; 4:46-56. (In Russ).
14. Zemskova K. Neural network will help you search for minerals. *InScience*. 20.09.2023. Available from: <https://inscience.news/ru/article/russian-science/14336> (In Russ).
15. Malvic T, Velic J, Horvath J. Neural networks in petroleum geology as interpretation tools. *Central European Geology*. 2010;53(1):97-115.
16. Ibraeva N. Analysis of the scope of application of neural networks in mining machines. *Mining equipment and electromechanics*. 2021;6(158):21-25. (In Russ).
17. Obodoekwe E, Fang X, Lu K. Convolutional Neural Networks in Process Mining and Data Analytics for Prediction Accuracy. *Electronics*. 11:2128-2141.
18. Dong L, Tang Z, Li X. Discrimination of mining microseismic events and blasts using convolutional neural networks and original waveform. *J. Cent. South University Technologies*. 2020;27:3078-3089.
19. Johnson SW, Chambers DJ, Boltz MS. Application of a convolutional neural network for seismic phase picking of mining-induced seismicity. *Geophys J Int*. 2021;224(1):230-240.
20. Hasanov II., Hasanova ZR., Shakirov RA. Review of the use of neural networks in the field of oil and gas production and transport. *Transport and storage of petroleum products*. 2022;3(4):11-15.
21. Mansouri SS., Karvelis P., Kanellakis C. Vision-based MAV Navigation in Underground Mine Using Convolutional Neural Network. *IECON 2019 – 45th Annual Conference of the IEEE Industrial Electronics Society*. Lisbon, 2019:750-755.

ИНФОРМАЦИЯ ОБ АВТОРАХ



Артемов Иван Владимирович:
специалист,
аспирант направления «Искусственный интеллект
и машинное обучение» УГГУ,
Уральский государственный горный университет,
г. Екатеринбург, Россия,
Scopus Author ID: 57022242500,
e-mail: imperfect-post@yandex.ru

INFORMATION ABOUT THE AUTHORS

Artemov Ivan Vladimirovich:
specialist,
postgraduate student,
direction of Artificial Intelligence and Machine
Learning,
Ural State Mining University,
Yekaterinburg, Russia,
Scopus Author ID: 57022242500,
e-mail: imperfect-post@yandex.ru



Носырев Михаил Борисович:
доктор технических наук,
профессор,
Уральский государственный горный университет,
г. Екатеринбург, Россия,
Scopus Author ID: 57194022210,
e-mail: nosyrev.mb@mail.ru

Nosyrev Mikhail Borisovich:
PhD (technical sciences),
professor,
Ural State Mining University,
Yekaterinburg, Russia,
Scopus Author ID: 57194022210,
e-mail: nosyrev.mb@mail.ru

КРИТЕРИИ АВТОРСТВА / CONTRIBUTION:

Авторы заявляют о равном вкладе в работу над статьей. / The authors declare an equal contribution to the work on the article.

КОНФЛИКТ ИНТЕРЕСОВ / CONFLICT OF INTEREST:

Авторы заявляют об отсутствии конфликта интересов. / The authors declare no conflict of interest.