

# Технологии нейронных сетей в интеллектуальном анализе данных гранулометрического состава взорванных пород

В.С. Великанов<sup>1, 2, 3</sup>✉, А.В. Дремин<sup>1</sup>, С.А. Чернухин<sup>3</sup>, Н.В. Ломовцева<sup>4</sup>

<sup>1</sup> ООО «ДАВТЕХ», г. Екатеринбург, Российская Федерация

<sup>2</sup> Уральский федеральный университет имени первого Президента России Б.Н. Ельцина, г. Екатеринбург, Российская Федерация

<sup>3</sup> Уральский государственный горный университет, г. Екатеринбург, Российская Федерация

<sup>4</sup> Уральский государственный аграрный университет, г. Екатеринбург, Российская Федерация

✉ v.s.velikanov@urfu.ru

**Резюме:** В современных условиях развития горнодобывающей отрасли растет роль средств, обеспечивающих и влияющих на скорость принятия решения, эти тенденции уже затронули практически все сферы деятельности и проникают в прикладные области в виде систем искусственного интеллекта. Использование нейронных сетей в технологии интеллектуального анализа данных является актуальным направлением, которое непрерывно развивается. В исследовании решается задача по установлению грансостава взорванных пород с использованием нейросетевых технологий, использована искусственная нейронная сеть U-Net для решения научно-практической задачи, прошедшая обучение и позволяющая по мере накопления ею опыта адаптироваться к происходящим изменениям исходных данных по грансоставу для разных месторождений полезных ископаемых. МЕТОДЫ. При решении поставленных задач использовался комплексный подход, включающий: системный научный анализ и обобщение ранее опубликованных исследований. Для предварительной оценки грансостава использована схема архитектуры U-Net. РЕЗУЛЬТАТЫ. С использованием в качестве аппаратно-программного сопровождения экспериментальных исследований отечественного оборудования компании «Давтех» определены параметры кусковатости взорванной горной массы. ВЫВОДЫ. Полученные в ходе исследования данные позволят разработать рекомендации по оптимизации режимов управления карьерным экскаватором, что в итоге позволит снизить количество отказов рабочего оборудования и увеличит его ресурс.

**Ключевые слова:** горнодобывающая отрасль, гранулометрический состав, горные породы, взрывные работы, карьерный экскаватор, нейронная сеть

**Для цитирования:** Великанов В.С., Дремин А.В., Чернухин С.А., Ломовцева Н.В. Технологии нейронных сетей в интеллектуальном анализе данных гранулометрического состава взорванных пород. *Горная промышленность*. 2024;(4):90–94. <https://doi.org/10.30686/1609-9192-2024-4-90-94>

## Neural network technologies in mining data on particle size distribution of muck pile rocks

V.S. Velikanov<sup>1, 2, 3</sup>✉, A.V. Dremin<sup>1</sup>, S.A. Chernukhin<sup>3</sup>, N.V. Lomovtseva<sup>4</sup>

<sup>1</sup> DAVTECH LLC, Ekaterinburg, Russian Federation

<sup>2</sup> Ural Federal University named after the first President of Russia B.N. Yeltsin, Ekaterinburg, Russian Federation

<sup>3</sup> Ural State Mining University, Ekaterinburg, Russian Federation

<sup>4</sup> Ural State Agrarian University, Ekaterinburg, Russian Federation

✉ v.s.velikanov@urfu.ru

**Abstract:** Current development of the mining industry increases the role of tools that support decision making and impact its speed. These trends have already affected almost all spheres of human activities and are expanding into the applied areas as artificial intelligence systems. The use of neural networks in the data mining technology is a current trend that is continuously evolving. The study solves the problem of defining the particle size distribution of muck pile rocks using the neural network technologies. The U-Net artificial neural network was used to solve the scientific and practical problem. This network had been trained to allow it to gain experience and adapt to the ongoing changes in the input data on the particle size distribution for different mineral deposits as it accumulates data. METHODS. A complex approach that included a system scientific analysis and generalization of previously published studies was used in addressing the tasks set. The U-Net architecture was used

for preliminary assessment of the particle size distribution. RESULTS. The lump size parameters of the muck pile rocks were determined using the Russian-made Davtech equipment as the hardware and software support for experimental studies. CONCLUSIONS. The data obtained in the course of the study will make it possible to develop recommendations to optimize the control modes of an open-pit excavator, which will ultimately reduce the number of equipment failures and increase its service life.

**Keywords:** mining industry, particle size distribution, rocks, blasting, open-pit excavator, neural network

**For citation:** Velikanov V.S., Dremin A.V., Chernukhin S.A., Lomovtseva N.V. Neural network technologies in mining data on particle size distribution of muck pile rocks. *Russian Mining Industry*. 2024;(4):90–94. (In Russ.) <https://doi.org/10.30686/1609-9192-2024-4-90-94>

## Введение

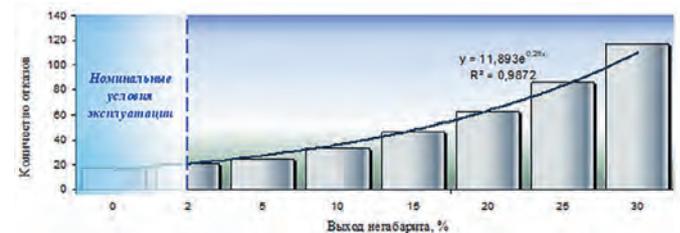
Суммарный объём потребления минерального сырья за последние полвека лет растёт, данный рост обусловлен увеличением численности населения и неуклонным ростом промышленного производства. Удельный вес открытых горных работ в общем объёме добычи полезных ископаемых по оценкам экспертов составляет в мире 72–73%, в США – 83%, в Российской Федерации (РФ) и странах СНГ – порядка 70%. Современное состояние открытой добычи полезных ископаемых на данном этапе развития открытой геотехнологии характеризуется увеличением глубины карьеров, повышением коэффициента вскрыши и чаще всего снижением содержания полезных компонентов [1–4].

Развитие минерально-сырьевой базы РФ определяется добычей стратегически важных полезных ископаемых, к которым относятся прежде всего – уголь, металлические руды (железная руда, медь и др.), т. е. полезные ископаемые первой группы, сырьевая база которых при любых прогнозных сценариях развития экономики достаточна для удовлетворения внутренних потребностей и при необходимости для обеспечения экспортных поставок.

Увеличение объёмов добычи стратегически важных полезных ископаемых влечёт за собой рост спроса на горнодобывающую технику. Мировой рынок горнодобывающей техники устойчиво растёт на 8–10% ежегодно, на долю российских производителей горной техники на отечественном рынке приходится свыше 70% продаж карьерных экскаваторов [1].

Буровзрывные работы (БВР) – это основа горного передела. БВР на карьерах проводятся с целью отбойки и дробления горной массы до требуемой кусковатости. Качество выполнения БВР определяет затраты на механическое дробление и измельчение, которые, как известно, являются наиболее энергозатратными операциями горно-обогатительного производства. В настоящее время усреднённая доля затрат для горнодобывающих предприятий РФ, приходящихся на отбойку горной массы, в зависимости от крепости горных пород находится в пределах 20–35%, причём каждое предприятие устанавливает свои собственные требования к кондиционному куску и, как следствие, к размеру негабарита [5]. На эту величину оказывают влияние следующие факторы: тип применяемого горного и дробильного оборудования (по габаритам технологического оборудования), используемое ВВ, тип и физико-механические свойства полезного ископаемого и т.д. При увеличении объёмов взрывных работ нередко происходит рост выхода негабаритной

фракции (рис. 1) [5; 6]. Это может обуславливаться ухудшением горно-геологических условий по мере увеличения глубины отработки, некорректно подобранными параметрами БВР, что вызвано желанием сократить производственные затраты, и т.д. Данное явление приводит к неконтролируемому росту дополнительных издержек на вспомогательные операции, что в целом негативно сказывается на экономической эффективности горнодобывающего предприятия.



**Рис. 1**  
Изменение количества отказов карьерного экскаватора ЭКГ-32Р от % выхода негабарита горной массы  
Источник: [5; 6].

**Fig. 1**  
Changes in the failure rate of the EKG-32R open-pit excavator in relation to the % of the oversized rocks  
Source: [5; 6].

## Методы

Для оценки влияния качества подготовки забоя на эксплуатационные показатели и техническое состояние металлоконструкций экскаваторов на одном из геодинамических полигонов был проведён производственный эксперимент по определению параметров кусковатости взорванной горной массы, а также контролировалось появление трещин. В качестве аппаратно-программного сопровождения экспериментальных исследований использовано отечественное оборудование компании «Давтех», разработанное в рамках программы импортозамещения высокотехнологичного оборудования. В аппаратно-программном комплексе реализован способ, защищенный патентом [7], определения гранулометрического состава, который заключается в том, что: посредством стереоскопической камеры получают стереоизображение развала горной породы; на основе полученного стереоизображения развала строят объемный рельеф поверхности развала, представляющий собой набор дальностей от матрицы стереоскопической камеры до поверхности выбранных участков развала горной породы и соответствующих им координат на изображении (рис. 2).

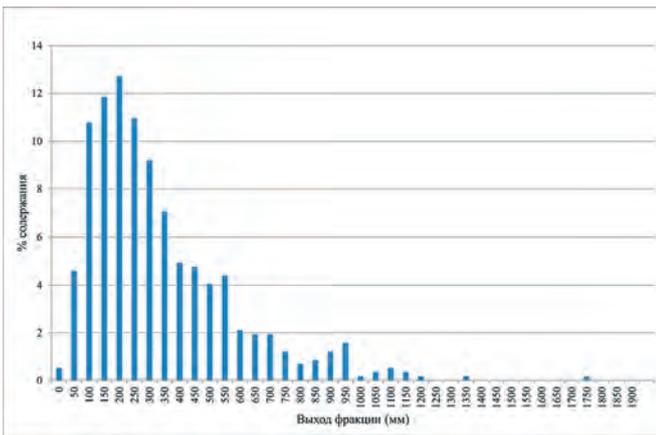
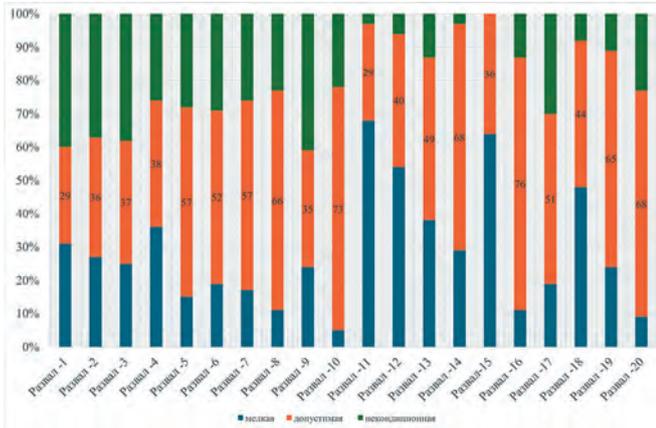


Рис. 2  
Результаты производственного эксперимента на геодинамическом полигоне Уральского федерального округа

Fig. 2  
Results of the industrial experiment at the geodynamic test site in the Ural Federal District

Результаты и обсуждение

Нейронные сети могут реализовываться как программно, так и аппаратно (нейрочипы, нейрокомпьютеры). В процессе функционирования нейронной сети осуществляется преобразование данных, конкретный вид которого определяется весами межнейронных связей, видом активационной функции нейронов, архитектурой и конфигурацией сети. Нейронные сети представляют собой модели, основанные на машинном обучении, т.е. приобретают необходимые свойства в процессе обучения, который заключается в итеративной подстройке весов сети по некоторому правилу, называемому алгоритмом обучения. Наиболее часто нейронные сети используются для решения следующих задач:

1. Аппроксимация функций – восстановление функциональных зависимостей из обучающих данных.

2. Классификация – определение принадлежности входного образа (объекта), представленного вектором признаков, к одному из предварительно заданных классов.
3. Кластеризация – группировка объектов на основе близости их свойств.
4. Прогнозирование – предсказание значения  $y(t_{n+1})$  при заданной последовательности  $y(t_1), y(t_2) \dots, y(t_n)$ .
5. Оптимизация – нахождение решения, удовлетворяющего системе ограничений и максимизирующего или минимизирующего целевую функцию.
6. Ассоциативная память – память, адресуемая по содержанию, используемая в системах сверхбыстрого поиска.
7. Управление – расчет такого входного воздействия на систему, при котором она следует по желаемой траектории.
8. Распознавание речи и машинный перевод.
9. Обработка изображений.

В качестве дополнительного исследовательского инструментария нами прорабатывался вопрос возможности использования для предварительного анализа развала горной массы сверточной нейронной сети. Она позволяет получать признаки искомым объектов автоматически и классифицировать пиксели с учетом окружающей их области, т. е. учитываются непосредственно свойства самого объекта. Таким образом, повышается робастность алгоритма сегментации к шумам и помехам. Структура модели сверточной нейронной сети параллельна, что делает идеальным применение графических процессоров (GPU) для их обучения [8]. Нами в работе использована архитектура нейронной сети U-Net, показавшая свою эффективность в решении задачи сегментации медицинских изображений. Сеть U-Net показала свою эффективность и в автоматической сегментации спутниковых изображений при малом количестве обучающих данных [8] (рис. 3).

Оригинальная U-Net состоит из двух частей: кодировщика и декодировщика. Кодировщик представляет собой сверточную нейронную сеть, состоящую из пяти блоков.

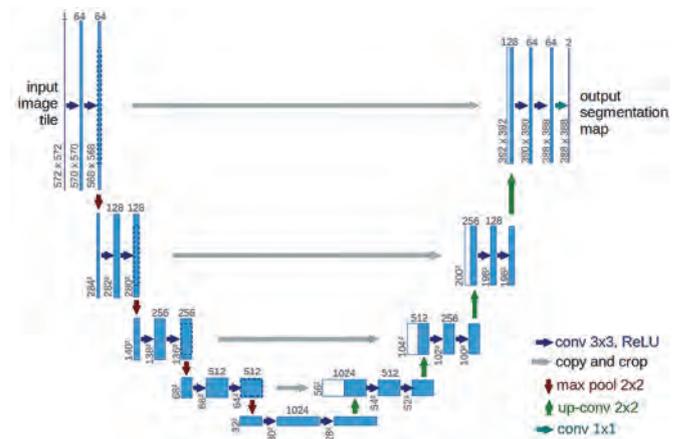


Рис. 3  
Схема архитектуры U-Net  
Источник: U-Net: нейросеть для сегментации изображений.

Режим доступа: <https://neurohive.io/ru/vidy-nejrosetej/u-net-image-segmentation/9> (дата обращения: 01.07.2024)

Fig. 3  
The U-Net architecture diagram  
Source: U-Net: neural network for image segmentation.

Available at: <https://neurohive.io/ru/vidy-nejrosetej/u-net-image-segmentation/9> (accessed: 01.07.2024)

Каждый такой блок состоит из двух сверточных слоев с фильтрами  $3 \times 3$  с функцией активации ReLU и batch normalization, применяемой к каждому из них, а также слоя понижения дискретизации с окном  $2 \times 2$ . Декодировщик имеет такое же количество блоков, что и кодировщик. Каждый блок декодировщика состоит из слоя повышения дискретизации с окном  $2 \times 2$ , слияния с соответствующим набором признаков из кодировщика, двух сверточных слоев с фильтрами  $3 \times 3$  и функцией активации ReLU, примененной к 42 каждому из них. Последний слой использует сигмоидную функцию активации признаков для классификации на уровне пикселей.

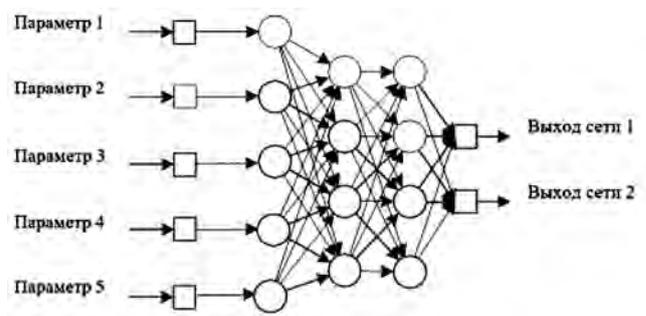
В части собственных разработок создание искусственной нейронной сети (ИНС) для решения задач прогнозирования методами нейросетевого анализа предлагается проводить согласно следующей последовательности:

1. Физическая постановка задачи с целью построения обучающих выборок. Основой для создания обучающих выборок могут быть базы данных, содержащие аналитическую информацию по гранулометрическому составу пород на различных месторождениях твердых полезных ископаемых с различными физико-механическими характеристиками пород: часть статистического материала для обработки взята из научно-технических источников, представленных в библиографическом списке, другая – данные по грансоставу с карьеров Уральского федерального округа.

2. Выбор архитектуры, топологии сети, а также выбор алгоритма ее обучения. Предварительная обработка данных и построение обучающих выборок.

3. Обучение, тестирование и возможное «дообучение» сети.

4. Анализ полученных результатов. Исходя из основных положений теории НЛ данные должны быть представлены в виде функций принадлежности. Данный этап называется фазсификацией, которая представляет собой процедуру нахождения значений функций принадлежности входных лингвистических переменных на основе обычных (не нечетких) исходных данных. Для построения модели необходимо определить функции принадлежности каждого параметра  $\mu(P1,1)$ ,  $\mu(P1,2)$ , ...,  $\mu(P2,7)$ , а также построить нечеткую базу правил. Для фазсификации привлекаются эксперты (10 человек, средний опыт



**Рис. 4**  
Искусственная нейронная сеть прогнозирования грансостава в условиях малого объема достоверных исходных данных и неопределенности  
Источник: [9]

**Fig. 4**  
Artificial neural network for predicting particle size distribution in conditions of limited amount of reliable input data and high level of uncertainty  
Source: [9]

работы 27,4 года). Экспертными методами определены терм-множества и функции принадлежности всех лингвистических переменных (рис. 4) [9].

При исследовании представленной ИНС точность результатов модели была подтверждена путем сопоставления прогноза с фактическими данными о фракционности в развале горных пород.

#### Заключение

Таким образом, в результате проведенных исследований установлено и доказано, что гранулометрический состав горных пород – это один из основных показателей, влияющих на экономику последующих операций. Комплексные исследования по установлению фактического распределения размеров кусков в развале с использованием технологий нейронных сетей, при условии обеспечения качества дробления взорванной горной массы в забое, определяемого содержанием негабаритного куска не более 3%, позволит разработать рекомендации по рациональным режимам управления карьерным экскаватором.

#### Список литературы / References

1. Дремин А.В., Великанов В.С. К вопросу о гранулометрическом составе взорванных скальных пород. *Горная промышленность*. 2023;(4):73–78. <https://doi.org/10.30686/1609-9192-2023-4-73-78>  
Dremin A.V., Velikanov V.S. Regarding the particle-size composition of blasted rocks. *Russian Mining Industry*. 2023;(4):73–78. (In Russ.) <https://doi.org/10.30686/1609-9192-2023-4-73-78>
2. Маринин М.А., Евграфов М.В., Должиков В.В. Производство взрывных работ на заданный гранулометрический состав руды в рамках концепции «mine-to-mill»: современное состояние и перспективы. *Известия Томского политехнического университета. Инжиниринг георесурсов*. 2021;332(7):65–74. <https://doi.org/10.18799/24131830/2021/7/3264>  
Marinin M.A., Evgrafov M.V., Dolzhikov V.V. Production of blasting operations for a given granulometric composition of ore within the framework of the «mine-to-mill» concept: current state and prospects. *Bulletin of the Tomsk Polytechnic University. Geo Assets Engineering*. 2021;332(7):65–74. (In Russ.). <https://doi.org/10.18799/24131830/2021/7/3264>

3. Ракишев Б.Р., Орынбай А.А., Ауэзова А.М., Куттыбаев А.Е. Гранулометрический состав взорванных пород при различных условиях взрыва. *Горный информационно-аналитический бюллетень*. 2019;(8):83–94. <https://doi.org/10.25018/0236-1493-2019-08-0-83-94>  
Rakishev B.R., Orynbay A.A., Auezova A.M., Kuttybaev A.E. Grain size composition of broken rocks under different conditions of blasting. *Mining Informational and Analytical Bulletin*. 2019;(8):83–94. (In Russ.). <https://doi.org/10.25018/0236-1493-2019-08-0-83-94>
4. Угольников В.К., Симонов П.С., Угольников Н.В. Прогнозирование гранулометрического состава взорванной горной массы. *Горный информационно-аналитический бюллетень*. 2007;(S7):63–70.  
Ugolnikov V.K., Simonov P.S., Ugolnikov N.V. Forecasting of particle size distribution of blasted rock mass. *Mining Informational and Analytical Bulletin*. 2007;(S7):63–70. (In Russ.).
5. Иванова П.В. Алгоритм прогнозирования наработки карьерного экскаватора ЭКГ-32Р в заданных условиях эксплуатации. В кн.: *Инновации и перспективы развития горного машиностроения и электромеханики: IPDME-2017: сборник тезисов Междунар. науч.-техн. конф., г. Санкт-Петербург, 23–24 марта 2017 г.* СПб.: Санкт-Петербургский горный университет; 2018. С. 79.
6. Иванова П.В., Иванов С.Л. Анализ отказов механического оборудования карьерных экскаваторов. В кн.: *Горное дело в XXI веке: технологии, наука, образование: тезисы докладов Междунар. науч.-практ. конф., г. Санкт-Петербург, 28–29 окт. 2015 г.* СПб.: Национальный минерально-сырьевой университет «Горный»; 2015. С. 54.
7. Дремин А.В., Марков Ю.В. Способ определения гранулометрического состава развала горной массы. Патент РФ, №RU 2 807 542, Заявл. 25.05.2023; Оpubл. 16.11.2023. Режим доступа: <https://patenton.ru/patent/RU2807542C1?ysclid=ly8xk9ss4h40366790> (дата обращения: 01.07.2024)
8. Шелковников Е.Ю., Шляхтин К.А., Шелковникова Т.Е., Егоров С.Ф. Применение нейронной сети архитектуры U-NET для сегментации СТМ-изображений. *Химическая физика и мезоскопия*. 2019;21(2):330–336. <https://doi.org/10.15350/17270529.2019.2.36>  
Shelkovnikov E.Yu., Shlyakhtin K.A., Shelkovnikova T.E., Egorov S.F. Application of neural network of U-Net architecture for segmentation of nanoparticles on СТМ-probes. *Chemical Physics and Mesoscopy*. 2019;21(2):330–336. (In Russ.). <https://doi.org/10.15350/17270529.2019.2.36>
9. Дремин А.В., Великанов В.С. Постановка многокритериальной задачи анализа и прогнозирования гранулометрического состава взорванных горных пород. *Горная промышленность*. 2023;(5):52–60. <https://doi.org/10.30686/1609-9192-2023-5-52-60>  
Dremin A.V., Velikanov V.S. Setting a multi-criteria problem to analyze and forecast particle size distribution of blasted rock. *Russian Mining Industry*. 2023;(5):52–60. (In Russ.) <https://doi.org/10.30686/1609-9192-2023-5-52-60>

**Информация об авторах**

**Великанов Владимир Семенович** – доктор технических наук, научный консультант, ООО «ДАВТЕХ», профессор кафедры подъемно-транспортных машин и роботов, Уральский федеральный университет имени первого президента России Б.Н. Ельцина, г. Екатеринбург, Российская Федерация, профессор кафедры автоматизации и компьютерных технологий, Уральский государственный горный университет, г. Екатеринбург, Российская Федерация; <https://orcid.org/0000-0001-5581-2733>; e-mail: [v.s.velikanov@urfu.ru](mailto:v.s.velikanov@urfu.ru)

**Дремин Александр Владимирович** – генеральный директор, ООО «ДАВТЕХ», г. Екатеринбург, Российская Федерация

**Чернухин Станислав Алексеевич** – кандидат технических наук, доцент кафедры автоматизации и компьютерных технологий, Уральский государственный горный университет, г. Екатеринбург, Российская Федерация

**Ломовцева Наталья Викторовна** – кандидат педагогических наук, доцент, проректор по образовательной деятельности и цифровизации, Уральский государственный аграрный университет, г. Екатеринбург, Российская Федерация; e-mail: [lomovtseva-nv@urgau.ru](mailto:lomovtseva-nv@urgau.ru)

**Информация о статье**

Поступила в редакцию: 19.05.2024

Поступила после рецензирования: 01.07.2024

Принята к публикации: 05.07.2024

**Information about the authors**

**Vladimir S. Velikanov** – Dr. Sci. (Eng.), Academic Adviser, DAVTECH LLC, Professor, Department of Hoisting and Hauling Machines and Robots, Ural Federal University named after the first President of Russia B.N. Yeltsin, Ekaterinburg, Russian Federation, Professor, Department of Automatics and Computer Technologies, Ural State Mining University, Ekaterinburg, Russian Federation; <https://orcid.org/0000-0001-5581-2733>; e-mail: [v.s.velikanov@urfu.ru](mailto:v.s.velikanov@urfu.ru)

**Aleksandr V. Dremin** – Director General, DAVTECH LLC, Ekaterinburg, Russian Federation

**Stanislav A. Chernukhin** – Cand. Sci. (Eng.), Associate Professor, Department of Automatics and Computer Technologies, Ural State Mining University, Ekaterinburg, Russian Federation

**Nataliya V. Lomovtseva** – Cand. Sci. (Educ.), Associate Professor, Vice-Rector for Educational Activities and Digitalization, Ural State Agrarian University, Ekaterinburg, Russian Federation; e-mail: [lomovtseva-nv@urgau.ru](mailto:lomovtseva-nv@urgau.ru)

**Article info**

Received: 19.05.2024

Revised: 01.07.2024

Accepted: 05.07.2024