

Научная статья  
УДК 004.932, 004.89, 549.08  
doi:10.37614/2949-1215.2025.16.3.007

## ЭКСПРЕСС-ТЕХНОЛОГИЯ ФОРМИРОВАНИЯ ОБУЧАЮЩЕЙ ВЫБОРКИ ДЛЯ ПЛАНИМЕТРИЧЕСКОГО МИНЕРАЛОГИЧЕСКОГО АНАЛИЗА НА ОСНОВЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ

**Владимир Витальевич Диковицкий<sup>1✉</sup>, Максим Геннадьевич Шишаев<sup>2</sup>**

<sup>1, 2</sup>Институт информатики и математического моделирования имени В. А. Путилова  
Кольского научного центра Российской академии наук, Апатиты, Россия

<sup>1</sup>[v.dikovitsky@ksc.ru](mailto:v.dikovitsky@ksc.ru)<sup>✉</sup>, <https://orcid.org/0000-0003-0329-9979>

<sup>2</sup>[m.shishaev@ksc.ru](mailto:m.shishaev@ksc.ru), <https://orcid.org/0000-0001-7070-7878>

### Аннотация

В работе рассматривается реализация планиметрического метода минералогического анализа как задачи классификации. Для ее решения используется машинное обучение, а для формирования обучающей выборки предложена экспресс-технология, основанная на аугментации данных. Для получения признаков вектора объектов классификации использован предобученный нейросетевой векторизатор на базе сверточной искусственной нейронной сети ResNet-18. Проведенные эксперименты на примере анализа апатитовых руд Хибинского месторождения показали, что использование такого вектора обеспечивает весьма высокую точность классификации чистых образцов апатита (до 99 % в зависимости от вида руды и размера планиметрической сетки). А с учетом специфики рассматриваемых в работе объектов классификации аналогичный подход может использоваться и для решения задачи определения удельного содержания минералов в рудах площадным методом. Предложенная в работе технология экспресс-разметки образцов обеспечивает приемлемую итоговую точность решения этой задачи при минимальных трудозатратах на создание обучающей выборки.

### Ключевые слова:

минералогический анализ, машинное обучение, классификация, планиметрический метод

### Благодарности:

исследование выполнено в рамках государственного задания Института информатики и математического моделирования Кольского научного центра Российской академии наук, Министерства науки и высшего образования Российской Федерации, темы научно-исследовательской работы «Методы и технологии создания интеллектуальных информационных систем для поддержки развития сложных динамических систем с региональной спецификой в условиях неопределённости и риска» (шифр темы FMEZ-2025-0053).

### Для цитирования:

Диковицкий В. В., Шишаев М. Г. Экспресс-технология формирования обучающей выборки для планиметрического минералогического анализа на основе методов машинного обучения // Труды Кольского научного центра РАН. Серия: Технические науки. 2025. Т. 16, № 3. С. 106–116. doi:10.37614/2949-1215.2025.16.3.007.

Original article

## EXPRESS TECHNOLOGY FOR FORMING A TRAINING SET FOR PLANIMETRIC MINERALOGICAL ANALYSIS BASED ON MACHINE LEARNING METHODS

**Vladimir V. Dikovitsky<sup>1✉</sup>, Maxim G. Shishaev<sup>2</sup>**

<sup>1, 2</sup>Putilov Institute for Informatics and Mathematical Modeling of the Kola Science Centre  
of the Russian Academy of Sciences, Apatity, Russia

<sup>1</sup>[v.dikovitsky@ksc.ru](mailto:v.dikovitsky@ksc.ru)<sup>✉</sup>, <https://orcid.org/0000-0003-0329-9979>

<sup>2</sup>[m.shishaev@ksc.ru](mailto:m.shishaev@ksc.ru), <https://orcid.org/0000-0001-7070-7878>

### Abstract

This paper examines the implementation of the planimetric method of mineralogical analysis as a classification problem. Machine learning is used to solve this problem, and an express technology based on data augmentation is proposed for generating a training set. A pre-trained neural network vectorizer based on the ResNet-18 convolutional artificial neural network is used to obtain the feature vector for classification objects. Experiments conducted using the analysis of apatite ores from the Khibiny deposit demonstrated that using this vector ensures a very high classification accuracy for pure apatite samples (up to 99 %, depending on the ore type and the size of the planimetric grid). Given the specific nature of the classification objects considered in this paper, a similar approach can also be used to determine the specific mineral content in ores using the areal method. The proposed express sample labeling technology ensures acceptable final accuracy for this problem with minimal effort required to generate the training set.

**Keywords:**

mineralogical analysis, machine learning, classification, planimetric method

**Acknowledgments:**

The study was carried out within the framework of the Putilov Institute for Informatics and Mathematical Modeling of the Kola Science Centre of the Russian Academy of Sciences state assignment of the Ministry of Science and Higher Education of the Russian Federation, research topic “Methods and technologies for creating intelligent information systems to support the development of complex dynamic systems with regional specifics in conditions of uncertainty and risk” (registration number of the research topic FMEZ-2025-0053).

**For citation:**

Shishaev M. G., Dikovitsky V. V. Express technology for forming a training set for planimetric mineralogical analysis based on machine learning methods. *Trudy Kol'skogo nauchnogo centra RAN. Seriya: Tekhnicheskie nauki* [Transactions of the Kola Science Centre of RAS. Series: Engineering Sciences], 2025, Vol. 16, No. 3, pp. 106–116. doi:10.37614/2949-1215.2025.16.3.007.

**Введение**

Планиметрический минералогический анализ относится к так называемым площадным методам, когда делается оценка объемного содержания минерала в образце на основе соответствующей оценки доли минерала на плоском изображении. Площадной анализ опирается на принцип Делессе [1], в соответствии с которым предполагается, что площадная оценка эквивалентна объемной. Это предположение справедливо, если используется «правильная» проекция образца (для слоистых руд — сечение, поперечное слоям минерала) или большое количество случайных проекций, а также если измеряемая площадь сечения много больше площади сечения отдельных зерен изучаемого минерала. Отметим, что для рассматриваемых в данной работе апатитовых руд эти условия выполнимы.

Для получения площадной оценки планиметрическим методом на изображение образца руды накладывается прямоугольная сетка, после чего каждая ячейка сетки (далее по тексту именуемая также секцией) идентифицируется с тем или иным минералом. Таким образом, планиметрический анализ эквивалентен задаче классификации изображений, для решения которой широко применяются методы машинного обучения.

В целом, при использовании методов машинного обучения в площадном минералогическом анализе, задача интерпретируется чаще всего как задача сегментации изображений [2–9]. Главной проблемой такого подхода является необходимость в качественных размеченных наборах данных, получение которых является трудоемким и затратным по времени процессом. Поэтому планиметрический метод анализа может рассматриваться как альтернатива методам, основанным на сегментации изображений.

Ключевыми проблемами при решении задачи классификации с помощью методов машинного обучения являются получение набора признаков объектов, обеспечивающего хорошую разделимость классов, а также формирование размеченного набора данных (датасета) достаточно большого размера для тренировки модели. В данной работе рассматривается технология автоматизированного получения обучающей выборки для тренировки нейросетевых классификаторов, использующих для получения признакового вектора предобученную сверточную нейронную сеть ResNet. Исследования проводились на примере задачи определения удельной доли полезного компонента<sup>1</sup> (ПК) в апатитовой руде.

**Исследование эффективности классификации апатита на базе признаковых векторов ResNet-18**


В настоящее время лучшие результаты в качестве универсального векторизатора изображений для различных приложений показывают сверточные нейронные сети [10]. В нашей работе в качестве классифицирующего признака использовались векторы изображений, полученные с помощью предобученной сверточной остаточной (residual) нейронной сети ResNet-18 [11]. Отметим, что в качестве векторизатора могут рассматриваться и другие варианты сверточных сетей [12], однако на задаче

---

<sup>1</sup> Строго говоря, термин «полезный компонент» означает некоторое химическое соединение, определяющее полезные свойства руды. Однако, ввиду того что объемное содержание минерала в руде однозначно определяет содержание полезного компонента, в данной статье для упрощения изложения мы будем использовать этот термин для обозначения минерала, содержащего искомое химическое соединение.

распознавания апатита уже ResNet-18, с относительно небольшими количеством слоев и размером выходного вектора (512 компонентов), обеспечила достаточно высокое качество результата.

Для подтверждения перспективности использования такого признакового вектора был проведен предварительный анализ имеющегося экспериментального датасета с помощью метода главных компонент. Для эксперимента были отобраны ячейки, представляющие положительный («апатит») и отрицательный («не\_апатит») классы, полученные наложением планиметрической сетки размером  $20 \times 20$  пикселей (всего 100 000 объектов). Полученное распределение секций по классам на редуцированном пространстве изображено на рис. 1. По результатам эксперимента можно сделать вывод о хорошей разделимости объектов по использованному признаку, что позволяет говорить о перспективности создания классификатора для решения рассматриваемой задачи.






**Рис. 1.** Распределение объектов в редуцированном пространстве признаков

Специфической проблемой планиметрического метода анализа как задачи классификации является неоднозначность отнесения к тому или иному классу ячеек, находящихся на границе двух и более минералов («пограничных» ячеек). Строго говоря, в данном случае мы имеем дело с задачей мягкой (нечеткой) классификации, когда объект принадлежит тому или иному классу с не стопроцентной достоверностью. Степень принадлежности объекта классу, как правило, оценивают в диапазоне от 0 до 1, при этом крайние значения степени принадлежности соответствуют ячейкам, представляющим чистые положительный или отрицательный классы, а промежуточные — ячейкам, лежащим на границе минерального пятна. Далее рассмотрены эксперименты по классификации ячеек планиметрической сетки, представляющих чистые классы, и пограничных ячеек.

В экспериментах использовались датасеты, полученные наложением планиметрической сетки различных размеров на эталонные размеченные изображения образцов апатитовой руды различных типов, представленные в табл. 1. Разметка образцов осуществлялась экспертами-минералогами и представлена соответствующими изображениями-масками, на которых черный цвет соответствует апатиту. Изображения образцов были получены с помощью обычной фотокамеры, разрешение 300 dpi, размер  $915 \times 709$  пикселей. В качестве классификатора использовалась ИНС прямого распространения с пятью полносвязными слоями. Тренировка классификатора осуществлялась на датасетах, сформированных из одной части изображений образцов руды, а для тестирования использовались объекты, полученные из изображений, не участвовавших в тренировке, то есть, наряду с кросс-валидацией, осуществлялась проверка нейросетевого классификатора на внешних данных.

Таблица 1

Использованные в экспериментах образцы апатитовой руды

| Вид руды          | Апатитовый уртит                                                                  | Пятнисто-полосчатая                                                               | Пятнистая                                                                          | Линзовидно-полосчатая                                                               | Блоковая                                                                            |
|-------------------|-----------------------------------------------------------------------------------|-----------------------------------------------------------------------------------|------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------|
| Индекс образца    | a                                                                                 | b                                                                                 | c                                                                                  | d                                                                                   | e                                                                                   |
| Исходное фото     |  |  |  |  |  |
| Изображение-маска |  |  |  |  |  |
| Содержание ПК     | 25 %                                                                              | 41 %                                                                              | 50 %                                                                               | 40 %                                                                                | 25 %                                                                                |

Результаты тестирования классификаторов, натренированных на различных наборах объектов (полученных из изображений руды разных типов), представлены в табл. 2. Серым цветом выделены ячейки, отражающие результаты кросс-валидации, ячейки без заливки содержат результаты проверки точности квалификации на внешних данных. Для формирования датасетов использовалась планиметрическая сетка размером  $10 \times 10$  пикселей.

Таблица 2

Результаты тестирования бинарного классификатора на чистых классах

|                                         | Классификатор, натренированный |      |      |      |      |                |      |      |      |      |                          |      |
|-----------------------------------------|--------------------------------|------|------|------|------|----------------|------|------|------|------|--------------------------|------|
|                                         | на образце "a"                 |      |      |      |      | на образце "b" |      |      |      |      | на образцах "a, b, d, e" |      |
| Предъявляемые для классификации образцы | a                              | b    | c    | d    | e    | a              | b    | c    | d    | e    | a, b, d, e               | c    |
| Точность классификации (Precision), %   | 98,6                           | 93,8 | 36,5 | 85,4 | 51,1 | 59,8           | 99,9 | 38,6 | 95,1 | 93,5 | 98,5                     | 98,8 |

Особенностью рассматриваемой задачи классификации, определяемой природой исследуемых объектов (изображений минералов), является однородность классов. Это свойство заключается в том, что при достаточно крупном размере ячейки, принадлежащей строго одному классу, ее элементы (более мелкие разбиения) будут также принадлежать этому же классу. Очевидно, что при достижении некоторого предельно малого размера ячейки это свойство перестанет выполняться. Предельный размер ячейки в этом смысле определяется морфологическими свойствами рассматриваемого минерала (размером характерных визуальных признаков). В рамках работы были проведены эксперименты по определению предельного размера ячейки, позволяющего эффективно идентифицировать апатит с использованием признакового вектора ResNet-18. Результаты, представленные в табл. 3, показывают, что для рассматриваемого минерала свойство однородности класса соблюдается вплоть до размера планиметрической ячейки  $2 \times 2$  пикселя.

Таблица 3

Эффективность бинарной классификации при различных размерах ячейки

| Размер ячейки                                         | $2 \times 2$ | $5 \times 5$ | $10 \times 10$ | $20 \times 20$ |
|-------------------------------------------------------|--------------|--------------|----------------|----------------|
| Точность классификации на валидационной части выборки | 0,78         | 0,90         | 0,98           | 0,99           |

Таким образом, использование векторизатора ResNet-18 для получения признакового вектора образцов изображений в задаче идентификации чистых классов в рассматриваемой задаче дает высокий эффект. Классификатор, натренированный на датасете, полученном на основе 4 из 5 имеющихся

эталонных изображений («a, b, d, e»), демонстрирует очень высокую точность классификации как на валидационной выборке, так и на внешних данных (секциях, полученных из изображения «с»).

Однако, как отмечалось выше, при минералогическом анализе планиметрическим методом мы имеем дело не только с представителями чистых классов (ячейками сетки, полностью принадлежащими положительному или отрицательному классу), но и с пограничными секциями, содержащими изображения минералов как положительного (в нашем случае — апатита), так и отрицательного классов. Одним из вариантов решения задачи определения удельного содержания ПК в данном случае является непосредственная интерпретация оценки вероятности принадлежности входного объекта положительному классу, получаемой на выходе бинарного классификатора, как доли ПК в ячейке.

С целью проверки эффективности такого подхода к определению ПК планиметрическим методом использовалось размеченное изображение апатита повышенного разрешения с размером секции  $20 \times 20$  пикселей. Бинарному нейросетовому классификатору, натренированному на размеченном датасете, включающем объекты положительного и отрицательного классов, были предъявлены 99 пограничных объектов с различным содержанием минерала, представляющих промежуточный класс. Результаты классификации пограничных объектов представлены на рис. 2 (объекты отсортированы в порядке убывания степеней принадлежности к положительному классу). Как видим, классификатор уверенно относит к положительному классу объекты с содержанием минерала выше 0,5 и практически утрачивает способность к классификации при содержании минерала менее 0,5.



Рис. 2. Результаты классификации пограничных объектов бинарным классификатором

Расчетное значение предсказанного содержания ПК в рассмотренных пограничных объектах составило 0,84 при истинном значении 0,55, что свидетельствует о невозможности непосредственного использования бинарного классификатора для определения удельного содержания полезного компонента в руде планиметрическим методом. Однако можно сделать предположение о том, что пограничные объекты в нашем случае будут в среднем содержать идентичные объемы положительного и отрицательного классов, то есть оценка удельного содержания ПК в таких объектах будет стремиться к 0,5 с увеличением их количества. В свою очередь, количество пограничных объектов при том же изображении образца будет возрастать с уменьшением размера ячейки планиметрической сетки.

В случае справедливости данного предположения, при определении удельного содержания ПК планиметрическим методом с использованием бинарного классификатора будет иметь место систематическая ошибка, зависящая от количества пограничных объектов в датасете, сформированном из рассматриваемого образца изображения руды. В табл. 4 приведены расчетные значения содержания ПК в пограничных ячейках при наложении планиметрической сетки различного размера на имеющиеся образцы. Как видим, предположение о сбалансированности содержания ПК в пограничных ячейках в целом подтверждается.

Таблица 4

Удельное содержание ПК в пограничных ячейках

| Размер ячейки | Индекс образца |      |      |      |      |
|---------------|----------------|------|------|------|------|
|               | a              | b    | c    | d    | e    |
| 5 × 5         | 0,50           | 0,48 | 0,52 | 0,51 | 0,52 |
| 10 × 10       | 0,49           | 0,45 | 0,53 | 0,50 | 0,54 |
| 15 × 15       | 0,48           | 0,42 | 0,54 | 0,48 | 0,53 |
| 20 × 20       | 0,46           | 0,40 | 0,53 | 0,47 | 0,53 |

Введем следующие обозначения:  $c$  — истинное удельное содержание полезного компонента в образце;  $\tilde{c}$  — оценка удельного содержания ПК в образце, полученная с помощью бинарного классификатора;  $N^+$  — количество ячеек положительного класса в образце;  $N^b$  — количество пограничных ячеек в образце;  $N$  — общее количество ячеек в образце;  $\lambda$  — относительная ошибка бинарного классификатора на пограничных ячейках.

Тогда с учетом сбалансированности содержания ПК в пограничных секциях фактическое содержание ПК в образце может быть рассчитано по формуле:

$$c = \frac{N^+ + N^b/2}{N}. \quad (1)$$

В свою очередь, предсказанное бинарным классификатором содержание ПК в том же образце с учетом единичной точности идентификации чистых классов и ошибки на пограничных ячейках:

$$\tilde{c} = \frac{N^+ + \lambda N^b/2}{N}. \quad (2)$$

Из формул (1) и (2) следует:

$$c = \tilde{c} - (\lambda - 1) \frac{N^b}{2N}.$$

Таким образом, при соблюдении условия сбалансированности классов в пограничных ячейках и известном количестве последних, бинарный классификатор может быть использован для оценки удельного содержания полезного компонента в образцах руды с применением планиметрического метода.

### Экспресс-технология формирования обучающей выборки

Проведенные эксперименты показывают эффективность применения машинного обучения (нейросетевого классификатора) для определения удельного содержания минерала в руде площадным методом. Основным сдерживающим фактором широкого применения данного подхода на практике является необходимость обучения классификатора на образцах, наиболее полно представляющих возможные варианты анализируемой руды с точки зрения ее цвето-яркостных и морфологических характеристик. Разумно предположить, что затруднительно построить классификатор, универсальный для всех типов и разновидностей руд. С другой стороны, наши эксперименты показывают, что использование при обучении классификатора более представительной выборки, включающей образцы руды тех типов, которые будут анализироваться на этапе использования классификатора (в нашем случае это различные апатитовые руды Хибинского месторождения), обеспечивает определенный уровень универсальности при сохранении высоких показателей точности классификации.

Тем не менее при изменении типа или разновидности анализируемой руды возникает необходимость обучения нового классификатора. Это, в свою очередь, требует наличия качественно размеченных образцов, используемых для формирования обучающей выборки. Ручная разметка изображения руды является трудоемким и продолжительным по времени процессом. Однако с учетом свойства однородности классов для рассматриваемого типа руд, отмеченного ранее, возможно сократить трудоемкость и длительность этого процесса путем разметки лишь части изображения

образца руды с последующей аугментацией полученной обучающей выборки. Схема соответствующей экспресс-технологии представлена на рис. 3 и включает в себя следующие основные этапы:


1. Формирование базового набора объектов выборки (альтернативно: либо способом (а), либо способом (б)):

а. Выбор и ручная разметка малого фрагмента изображения руды с последующим наложением планиметрической сетки на фрагмент и его маску и автоматизированным формированием множества размеченных объектов.

б. Наложение планиметрической сетки на исходное изображение целиком с последующим ручным заданием набора планиметрических ячеек, достаточно полно представляющих положительный, отрицательный и (при многоклассовой постановке задачи) промежуточные классы.

2. Аугментация выборки путем смещения и/или поворота ячеек относительно геометрического центра.

3. Тренировка классификатора.



**Рис. 3.** Технология формирования обучающего набора с помощью аугментации

Технология была опробована на примере определения содержания ПК планиметрическим методом в образце пятнисто-полосчатой апатитовой руды Хибинского месторождения. Для формирования выборки использовался способ (а): на исходном изображении был выделен и размечен фрагмент  $200 \times 100$  пикселей (рис. 4), на который затем была наложена планиметрическая сетка размером  $5 \times 5$  пикселей. Далее полученный набор объектов положительного и отрицательного классов подвергся аугментации путем последовательного сдвига планиметрической сетки. Полученный в результате набор объектов был сбалансирован по классам методом случайного сокращения мажоритарного класса (субдискретизации, under-sampling) [13].



**Рис. 4.** Используемые для формирования обучающей выборки фрагмент изображения (а) и соответствующая ему маска (b)

В итоге обучение проводилось в 8 эпох на 3181 образце, 796 образцов использовались для валидации. Значение точности на обучающем наборе составило 0,9053, на валидационном наборе — 0,8935. Результаты обучения представлены на рис. 5.

Полученный классификатор затем был использован для разметки полного исходного изображения. Результаты разметки маски минеральных пятен апатита в образце и расчета на ее основе процентного содержания искомого минерала при различных способах разметки представлены в табл. 5.





Рис. 5. Результаты тренировки классификатора на аугментированном наборе данных

Таблица 5

Результаты ручной и автоматизированной разметки образца апатитовой руды

|                                 | Ручная разметка                                                                     | Разметка классификатором, натренированным на всех образцах апатитовой руды           | Разметка классификатором, натренированным на обучающем наборе, полученном экспресс-методом |
|---------------------------------|-------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------|
| Маска минеральных пятен апатита |  |  |       |
| Расчетное содержание ПК         | 33,40 %                                                                             | 33,73 %                                                                              | 35,97 %                                                                                    |

Таким образом, при использовании экспресс-метода формирования обучающего набора точность определения содержания ПК образце, в сравнении с классификатором, обученным на полном наборе образцов, снизилась лишь на 2,24 %. Это является, на наш взгляд, вполне адекватной «платой» за кардинальное сокращение временных затрат на ручную минералогическую разметку образцов.

Следует также отметить, что применение в рамках экспресс-технологии второго способа формирования обучающей выборки возможно лишь при использовании планиметрического подхода к площадному анализу. При этом возможна отметка в качестве образцов положительного и отрицательного классов произвольных прямоугольных областей, которые в нашем случае, в силу свойства однородности классов, могут быть разделены на более мелкие фрагменты для формирования более объемной обучающей выборки.

Заключение

В результате проделанной работы исследованы возможность и эффективность реализации количественного минералогического анализа планиметрическим методом как задачи классификации с применением методов машинного обучения, а также предложена технология формирования соответствующих обучающих выборок экспресс-методом на основе аугментации.

Для получения признакового вектора, идентифицирующего целевой минерал по изображению, в работе использована предобученная сверточная ИНС ResNet-18. В целом использование сверточных

ИНС для извлечения признаков соответствует современным трендам в применении методов машинного зрения в минералогическом анализе. При этом наши эксперименты показывают, что предобученные сверточные ИНС могут быть использованы для извлечения признаков в контексте рассматриваемой прикладной задачи без каких-либо изменений в архитектуре или дообучения.

Проведенные эксперименты с образцами апатитовой руды различных видов продемонстрировали весьма высокую эффективность классификации чистых образцов апатита на основе признакового вектора, полученного с помощью ИНС ResNet-18. Причем высокая точность классификации сохраняется даже при относительно малых размерах идентифицируемого изображения ячейки планиметрической сетки и существенно деградирует лишь при размере ячейки  $2 \times 2$  пикселя. Очевидно, что оптимальный размер используемой планиметрической сетки определяется, с одной стороны, морфологическими свойствами рассматриваемой руды, а с другой — разрешением используемых изображений. Большой размер сетки обеспечивает более высокую точность идентификации целевого минерала, но при этом усложняет получение обучающей выборки достаточного объема. Также верхняя граница размера ячейки определяется возрастающей систематической ошибкой определения удельного содержания ПК в силу увеличения количества объектов, включающих смесь целевого минерала с прочими компонентами руды.

Основной проблемой при решении задачи автоматизированного планиметрического анализа в мультиклассовой постановке является получение обучающей выборки, в которой в достаточной мере представлены объекты всех рассматриваемых классов. В качестве решения этой проблемы в работе предложена и опробована экспериментально экспресс-технология формирования обучающего набора данных с использованием аугментации и частичной разметки изображения образца. В рамках технологии предложены два способа частичной разметки — полная минералогическая разметка фрагмента изображения образца с последующим автоматическим формированием размеченного датасета и непосредственное указание меток классов произвольным фрагментам изображения образца, соответствующим ячейкам наложенной планиметрической сетки. При использовании первого способа появляется возможность получения набора данных для мультиклассовой классификации. Однако в этом случае фрагмент изображения должен быть в достаточной мере представлен в смысле возможных вариаций визуализации каждого идентифицируемого класса. Обеспечить это условие не всегда возможно: вследствие неравномерности освещения и иных причин изображение целевого минерала и иных компонентов руды на различных участках изображения может существенно отличаться. Этого недостатка лишен второй способ, при котором пользователь может отметить любые элементы исходного изображения, обеспечив представленность в выборке различных вариаций изображения идентичных компонентов (классов) образца. В рамках данной работы осуществлено предварительное тестирование технологии, показавшее перспективность предложенного подхода в формировании обучающих наборов данных для рассматриваемой категории задач анализа изображений. В целом возможность получения обучающей выборки с невысокими трудозатратами создает условия для быстрой адаптации технологии к новым видам минералов и руд и повышает универсальность предложенного подхода.

Продолжение работы возможно в различных направлениях. Очевидно, что требуется экспериментальная проверка гипотезы о применимости рассмотренного подхода к количественному анализу других типов руд, а также к площадному анализу изображений в рамках иных прикладных задач. Анализ использованного в данной работе экспериментального датасета показал, что при наложении планиметрической сетки расчетная ошибка определения удельного содержания минерала является близкой к симметричной — в пограничных ячейках сетки доли компонентов, соответствующих положительному и отрицательному классам, примерно равны. С учетом этого перспективным представляется использование многоэтапной (иерархической) классификации, при которой на стартовых этапах анализируются макропараметры образцов руды — вид руды с точки зрения минерального состава, морфологические особенности и т. п., а на последующих этапах в соответствии с идентифицированными макропараметрами производится детальный минералогический анализ. При этом в зависимости от результатов классификации на макроуровне для последующего анализа могут применяться различные модели и алгоритмы.

## Список источников

1. Weibel E. R., Elias H. Introduction to stereologic principles // *Quantitative Methods in Morphology / Quantitative Methoden in der Morphologie* / eds. E. R. Weibel, H. Elias. Berlin, Heidelberg: Springer, 1967. P. 89–98.
2. Grad-CAM++: Generalized Gradient-Based Visual Explanations for Deep Convolutional Networks / A. Chattopadhyay [и др.] // 2018 IEEE Winter Conference on Applications of Computer Vision (WACV) 2018 IEEE Winter Conference on Applications of Computer Vision (WACV). 2018. Grad-CAM++. С. 839–847.
3. Srinivas S., Fleuret F. Full-Gradient Representation for Neural Network Visualization // *Advances in Neural Information Processing Systems*. Curran Associates, Inc., 2019. Vol. 32.
4. Baklanova O., Shvets O. Cluster analysis methods for recognition of mineral rocks in the mining industry // 2014 4th International Conference on Image Processing Theory, Tools and Applications (IPTA) 2014 4th International Conference on Image Processing Theory, Tools and Applications (IPTA). 2014. P. 1–5.
5. Baklanova O. E., Baklanov M. A. Methods and Algorithms of Image Recognition for Mineral Rocks in the Mining Industry // *Advances in Swarm Intelligence: Lecture Notes in Computer Science* / eds. Y. Tan, Y. Shi, L. Li. Cham: Springer International Publishing, 2016. P. 253–262.
6. Launeau P., Cruden A., Bouchez J. Mineral recognition in digital images of rocks: a new approach using multichannel classification // *Canadian Mineralogist*. 1994. Mineral recognition in digital images of rocks. No. 32. P. 919–933.
7. Review of Nodule Mineral Image Segmentation Algorithms for Deep-Sea Mineral Resource Assessment / W. Song [et al.] // *Computers, Materials and Continua*. 2022. Vol. 73. No. 1. P. 1649–1669.
8. Deep learning-based method for SEM image segmentation in mineral characterization, an example from Duvernay Shale samples in Western Canada Sedimentary Basin / Z. Chen [et al.] // *Computers & Geosciences*. 2020. Vol. 138. P. 104450.
9. Deep neural networks for improving physical accuracy of 2D and 3D multi-mineral segmentation of rock micro-CT images / Y. D. Wang [et al.] // *Applied Soft Computing*. 2021. Vol. 104. P. 107185.
10. A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects / Z. Li [et al.] // *IEEE Transactions on Neural Networks and Learning Systems*. 2022. Vol. 33. A Survey of Convolutional Neural Networks. No. 12. P. 6999–7019.
11. Deep Residual Learning for Image Recognition / K. He [et al.] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016. P. 770–778.
12. MineralImage5k: A benchmark for zero-shot raw mineral visual recognition and description / S. Nesteruk [et al.] // *Computers & Geosciences*. 2023. Vol. 178. MineralImage5k. P. 105414.
13. Yen S.-J., Lee Y.-S. Under-Sampling Approaches for Improving Prediction of the Minority Class in an Imbalanced Dataset // *Intelligent Control and Automation: International Conference on Intelligent Computing, ICIC 2006 Kunming, China, August 16–19, 2006: Lecture Notes in Control and Information Sciences* / eds. D.-S. Huang, K. Li, G. W. Irwin. Berlin, Heidelberg: Springer, 2006. P. 731–74.

## References

1. Weibel E. R., Elias H. Introduction to stereologic principles. *Quantitative Methods in Morphology / Quantitative Methoden in der Morphologie* / eds. E. R. Weibel, H. Elias. Berlin, Heidelberg, Springer, 1967, pp. 89–98.
2. Chattopadhyay A. et al. Grad-CAM++: Generalized Gradient-Based Visual Explanations for Deep Convolutional Networks. *2018 IEEE Winter Conference on Applications of Computer Vision (WACV) 2018 IEEE Winter Conference on Applications of Computer Vision (WACV)*, 2018, Grad-CAM++, pp. 839–847.
3. Srinivas S., Fleuret F. Full-Gradient Representation for Neural Network Visualization. *Advances in Neural Information Processing Systems*. Curran Associates, Inc., 2019, vol. 32.
4. Baklanova O., Shvets O. Cluster analysis methods for recognition of mineral rocks in the mining industry. *2014 4th International Conference on Image Processing Theory, Tools and Applications (IPTA) 2014 4th International Conference on Image Processing Theory, Tools and Applications (IPTA)*, 2014, pp. 1–5.
5. Baklanova O. E., Baklanov M. A. Methods and Algorithms of Image Recognition for Mineral Rocks in the Mining Industry. *Advances in Swarm Intelligence: Lecture Notes in Computer Science* / eds. Y. Tan, Y. Shi, L. Li. Cham, Springer International Publishing, 2016, pp. 253–262.
6. Launeau P., Cruden A., Bouchez J. Mineral recognition in digital images of rocks: a new approach using multichannel classification. *Canadian Mineralogist*, 1994, Mineral recognition in digital images of rocks, no. 32, pp. 919–933.

7. Song W. et al. Review of Nodule Mineral Image Segmentation Algorithms for Deep-Sea Mineral Resource Assessment. *Computers, Materials and Continua*, 2022, vol. 73, no. 1, pp. 1649–1669.
8. Chen Z. et al. Deep learning-based method for SEM image segmentation in mineral characterization, an example from Duvernay Shale samples in Western Canada Sedimentary Basin. *Computers & Geosciences*, 2020, vol. 138, p. 104450.
9. Wang Y. D. et al. Deep neural networks for improving physical accuracy of 2D and 3D multi-mineral segmentation of rock micro-CT images. *Applied Soft Computing*, 2021, vol. 104, p. 107185.
10. Li Z. et al. A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, vol. 33, A Survey of Convolutional Neural Networks, no. 12, pp. 6999–7019.
11. He K. et al. Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 770–778.
12. Nesteruk S. et al. MineralImage5k: A benchmark for zero-shot raw mineral visual recognition and description. *Computers & Geosciences*, 2023, vol. 178, MineralImage5k, p. 105414.
13. Yen S.-J., Lee Y.-S. Under-Sampling Approaches for Improving Prediction of the Minority Class in an Imbalanced Dataset. *Intelligent Control and Automation: International Conference on Intelligent Computing, ICIC 2006 Kunming, China, August 16–19, 2006: Lecture Notes in Control and Information Sciences* / eds. D.-S. Huang, K. Li, G. W. Irwin. Berlin, Heidelberg: Springer, 2006, pp. 731–740.

#### **Информация об авторах**

**В. В. Диковицкий** — кандидат технических наук, старший научный сотрудник;

**М. Г. Шишаев** — доктор технических наук, главный научный сотрудник.

#### **Information about the authors**

**V. V. Dikovitsky** — Candidate of Science (Tech.), Senior Research Fellow;

**M. G. Shishaev** — Doctor of Science (Tech.), Chief Research Fellow.

Статья поступила в редакцию 30.10.2025; одобрена после рецензирования 14.11.2025; принята к публикации 17.11.2025.  
The article was submitted 30.10.2025; approved after reviewing 14.11.2025; accepted for publication 17.11.2025.