

КЛАССИФИКАЦИЯ МИНЕРАЛЬНЫХ КОМПОНЕНТОВ ГРАНИТОИДОВ МЕТОДАМИ ЦИФРОВОЙ ПЕТРОГРАФИИ И МАШИННОГО ОБУЧЕНИЯ

Е. А. ВАСИЛЁНОК¹⁾

¹⁾Белорусский государственный университет, пр. Независимости, 4, 220030, г. Минск, Беларусь

Методы машинного обучения стали применяться в петрографии сравнительно недавно. Однако благодаря быстрому развитию программирования появляются более мощные алгоритмы и инструменты, использование которых для решения петрографических задач до настоящего времени не рассматривалось. Именно поэтому целью данной работы было применение современных методов машинного обучения для идентификации минеральных компонентов по макроизображениям образцов горных пород, а также методов обработки цифровых изображений. В статье представлены методика определения количественных характеристик и методика классификации минералов на макроизображениях горных пород. В качестве инструментария была использована программа для анализа и обработки изображений *ImageJ* с открытым программным интерфейсом, дополненная плагином *Trainable Weka Segmentation*. Макроизображения получены путем сканирования полированных образцов. Для эксперимента отобраны семь макрофотографий различных представителей семейства гранитов. Проведено обучение с учителем, где для классификации использован метод дерева решений. Для выборки объектов были созданы классы по каждому из породообразующих минералов: кварц (Q), калиевый полевой шпат (Fps), плагиоклаз (Pl) и биотит (Bi). Подготовлены области интереса и сохранены в одну базу данных, по которой и произведено обучение классификатора. По полученным классификационным изображениям созданы маски каждого минерала. Затем по этим маскам выполнен количественный анализ: определено процентное содержание и количество зерен минералов. Результаты представлены в табличной и графической формах.

Ключевые слова: цифровая петрография; гранит; идентификация горных пород; классификация минералов; машинное обучение.

CLASSIFICATION OF MINERAL COMPONENTS OF GRANITOID ROCKS BY USING METHODS OF DIGITAL PETROGRAPHY AND MACHINE LEARNING

A. A. VASILIONAK^a

^aBelarusian State University, 4 Niezaliežnasci Avenue, Minsk 220030, Belarus

Machine learning methods have begun to be used in petrography relatively recently. However, thanks to the rapid programming development, more powerful algorithms and tools appear, the use of which to solve petrographic tasks hasn't yet been considered. That's why the purpose of this work was to use modern machine learning methods to identify mineral components from macro images of rock samples, as well as to use digital image processing methods. This article presents the method of determination of quantitative characteristics and the method of classification of minerals on macro images

Образец цитирования:

Василёнок ЕА. Классификация минеральных компонентов гранитоидов методами цифровой петрографии и машинного обучения. *Журнал Белорусского государственного университета. География. Геология.* 2020;1:75–85. <https://doi.org/10.33581/2521-6740-2020-1-75-85>

For citation:

Vasilionak AA. Classification of mineral components of granitoid rocks by using methods of digital petrography and machine learning. *Journal of the Belarusian State University. Geography and Geology.* 2020;1:75–85. Russian. <https://doi.org/10.33581/2521-6740-2020-1-75-85>

Автор:

Елена Анатольевна Василёнок – аспирантка кафедры региональной геологии факультета географии и геоинформатики. Научный руководитель – кандидат геолого-минералогических наук, доцент В. П. Самодуров.

Author:

Alena A. Vasilionak, postgraduate student at the department of regional geology, faculty of geography and geoinformatics. manul1994@mail.ru

of rocks. An open source program for analyzing and processing images *ImageJ*, and its plugin *Trainable Weka Segmentation* were used as a toolkit. Macro images are obtained by scanning polished granite samples. Seven macro images of various representatives of the granites were selected for the experiment. Training with a teacher was conducted, where the decision tree method was used for classification. Based on this data set, classes were created for each of the rock-forming minerals: quartz (Q), potassium feldspar (Fps), plagioclase (Pl) and biotite (Bi). Regions of interest were prepared and stored in one database on the basis of which the classifier was trained. Based on the obtained classification data, masks of each mineral were created. A quantitative analysis was performed based on these masks: the percentage content and amount of grains of each mineral were determined. Results are presented in tabular and graphical forms.

Keywords: digital petrography; granite; rock identification; classification of minerals; machine learning.

Введение

Использование технологий одних научных областей в других является общепринятой практикой уже на протяжении нескольких десятков лет. Такое междисциплинарное взаимодействие, отклоняющееся от методологической строгости описания наук в целом, оказывает положительное влияние на их развитие, позволяя создавать новые методы и практики, формировать теории, получать более качественные результаты. Например, алгоритмы машинного обучения активно используются в биотехнологиях [1], хемоинформатике, фармацевтике, геномных исследованиях, растениеводстве [2], строительстве, инженерии [3], материаловедении, экономике, финансовой сфере, здравоохранении, юстиции, техническом обслуживании, маркетинге, физике, образовательных и информационных технологиях [4], политике, нефтегазовой промышленности, и это далеко не полный список. В географической отрасли искусственный интеллект (ИИ) нашел применение в картографии, геологии и геоинформационных системах [5–10].

Как известно, петрографический метод используется для анализа пород путем определения минерального состава и структурно-текстурных особенностей. С его помощью осуществляется систематизация исследуемых образцов по классам пород. Этот метод может быть использован в связке с методами ИИ.

Таким образом, целью настоящей работы является применение методов ИИ для идентификации минеральных компонентов образцов горных пород по их макроизображениям (данным цифровой петрографии).

Методика исследования

Классическое определение машинного обучения, по Митчеллу, звучит следующим образом: компьютерная программа обучается на основании опыта E в отношении некоторого класса задач T , если ее производительность, измеряемая как P , повышается при накоплении опыта E [11].

При разных методах обучения параметры T , P и E подразумевают под собой разные вещи. Под опытом E понимаются данные, и в зависимости от этого алгоритмы машинного обучения могут быть разделены на обучение с учителем и без учителя. В задачах обучения без учителя имеется выборка, состоящая из объектов, описываемых набором признаков. В задачах обучения с учителем, помимо этого, для каждого объекта некоторой выборки, называемой обучающей, известен целевой признак (по сути, это то, что хотелось бы прогнозировать для других объектов, не принадлежащих к обучающей выборке).

В случае обучения с учителем данные заранее категоризированы (или являются численными), а классом задач T может быть:

- классификация – присвоение объекту какой-либо категории на основании его признаков;
- регрессия – прогнозирование количественного признака объекта исходя из других его признаков.

При обучении без учителя данные никак не размечены и задачей T может являться:

- кластеризация – выделение групп объектов (кластеров) из множества на основании их признаков (главное отличие от классификации состоит в том, что перечень групп точно не задан и определяется уже в процессе работы алгоритма);

- определение аномалий – поиск объектов с ярко выраженными отличиями от основного множества.

Обучение с подкреплением представляет собой алгоритм, который натренирован принимать задомо определенные решения в среде без формирования базы данных. В сложнейших ситуациях, где крайне трудно выделить понятные (стабильные) признаки, используют нейронные сети либо ансамбли.

В качестве примера рассмотрим задачу определения минерального состава горной породы с использованием макроизображений. Здесь для алгоритма опыт E – это имеющаяся обучающая выборка: совокупность объектов (зерен минералов), каждый из которых характеризуется набором признаков (таких как параметры HSV (*hue, saturation, value*), геометрические показатели и т. д.), а также целевым

признаком. Если целевым признаком выступают цвет и его оттенки, то это задача (бинарной) классификации [12–14]. В случае если известно, что зерна данного минерала имеют широкий диапазон цветов либо обладают плеохроизмом, это будет задачей регрессии [15; 16].

Наконец, третья абстракция в определении машинного обучения – метрика оценки производительности алгоритма P . Такие метрики различаются для разных задач и алгоритмов [17; 18]. Самая простая метрика оценки качества алгоритма, решающего задачу классификации, – доля правильных ответов (*accuracy*), т. е. доля верных прогнозов алгоритма на тестовой выборке. А для оценки качества на каждом из классов в отдельности используются такие метрики, как точность (*precision*) и полнота (*recall*):

$$precision = \frac{TP}{TP + FP},$$

$$recall = \frac{TP}{TP + FN},$$

где TP – истинно положительное решение; FP – ложноположительное решение; FN – ложноотрицательное решение.

Сегментация же – это процесс разбиения цифрового изображения на сегменты, которые состоят из находящихся в непосредственной близости пикселей и выделены на основании определенных критериев однородности. Таким образом, выявляются группы элементов изображения, имеющих общий признак (свойство). При этом сегменты могут быть дополнительно сгруппированы в объекты, а те, в свою очередь, – в классы [19; 20].

Рассмотрим обучение с учителем, где для классификации используется метод дерева решений. Этот алгоритм машинного обучения представляет собой набор логических правил, объединенных в структуру данных. Преимущество деревьев решений в том, что они легко интерпретируемы, понятны человеку. Многие другие, хотя и более точные модели не обладают таким свойством и в какой-то мере выступают «черным ящиком», в который мы лишь добавляем исходные данные, и получаем ответ. В связи с этим деревья решений получили популярность, а их представитель $C4.5$ считается одним из лучших алгоритмов интеллектуального анализа данных [21].

Также были подготовлены объекты исследования – макроизображения образцов гранитов. Граниты являются магматическими plutonic горными породами кислого состава нормального ряда щелочности. В классическом представлении их модалный минеральный состав выглядит следующим образом: кварц (25–35 %), плагиоклаз (25–35 %), калиевый полевой шпат (20–40 %) и слюды (3–10 %).

Отдельно отметим плагиогранит, в составе которого преобладают кварц (25–35 %), плагиоклаз (30–60 %), калиевый полевой шпат (1–15 %) и слюды (3–10 %) [22], и аляскит – умеренно щелочную горную породу семейства лейкогранитов, отличающуюся крупными размерами кристаллов кварца (примерно 35 %), калиевого (55–65 %) и известково-натриевого (менее 10 %) полевого шпата, а также небольшим содержанием слюд (менее 1 %).

Макроизображения получены путем сканирования предварительно отполированных образцов. Для эксперимента были отобраны 7 макрофотографий различных представителей семейства гранитов (рис. 1).

Вся дальнейшая работа построена на использовании программы для анализа и обработки изображений *ImageJ* с открытым программным интерфейсом, дополненной плагином *Trainable Weka Segmentation* (TWS), распространяемым по лицензии General Public License (GPL).

TWS сочетает в себе алгоритмы машинного обучения с набором функций для сегментации изображения и основан на среде анализа данных *Weka* (Waikato Environment for Knowledge Analysis). Этот плагин использует предложенный Л. Брейманом [23] и А. Катлер алгоритм машинного обучения, заключающийся в применении ансамбля решающих деревьев, которые поодиночке дают невысокое качество классификации, но вместе за счет их большого количества обеспечивают довольно неплохой результат. Значимым для петрографических задач фактором является то, что такой алгоритм одинаково хорошо обрабатывает как непрерывные, так и дискретные признаки объектов.

Классификация минералов на макроизображениях горных пород осуществляется по следующей методике:

- 1) создать каждому минералу, который может быть в данном типе породы, отдельный класс;
- 2) выделить области интереса (ROI) для каждого класса;
- 3) добавить всю информацию о ROI в базу данных (*data set*);
- 4) натренировать классификатор на подготовленных данных;
- 5) применить классификатор к макроизображению породы;
- 6) сохранить результаты классификации.




Рис. 1. Макрофотографии различных представителей семейства гранитов:
а – образец 1; б – образец 2; в – образец 3; г – образец 4;
д – образец 5; е – образец 6; жс – образец 7

Fig. 1. Macro images of various members of the granites:
a – sample 1; b – sample 2; c – sample 3; d – sample 4;
e – sample 5; f – sample 6; g – sample 7

Определение количественных характеристик уже известных минералов выполняется по следующему плану:

- произвести предварительную обработку классификационного изображения;
- применить порог (*thresholding*) [24; 25];
- создать маску и при необходимости применить к ней фильтры;
- выполнить разделение перекрывающихся объектов методом Watershed;
- проанализировать полученные данные.

Предварительная обработка макроизображений с помощью фильтров необходима, чтобы сделать последующую сегментацию более эффективной. Выбор фильтра(-ов) в значительной степени зависит от полученных изображений, но наиболее полезными являются нижеприведенные фильтры:

1. Деконволюция (*deconvolution*) – обеспечивает восстановление контрастности макроизображения, позволяя тем самым исправить систематическую ошибку потери контраста при его записи. Данный алгоритм используется для устранения эффектов размытия на исходном растре, вызванных сверткой (пятна, размытие, потеря контраста мелких объектов) из-за функции рассеяния точек изображения. Если этого не сделать, то результаты анализа интенсивности объектов на макроизображении могут быть некорректными.

Рассмотрим на примере макроизображения гранита, полученного путем сканирования образца. Одна из сторон записана с размытием, на ней трудно различить границы зерен биотита (Bi). Если разложить изображение на HSB-стек (*hue, saturation, brightness*) и произвести 10 итераций деконволюции, будет сформировано изображение для анализа без потерь качества (рис. 2).

2. Вычисть фон (*subtract background*) – удаляет гладкие непрерывные фоны и подходит для работы иммерсионным методом. К 8-битовому изображению может быть применен алгоритм, созданный С. Штернбергом. Локальное значение фона определяется для каждого пикселя путем усреднения по шару с радиусом R . Далее это значение вычитается из исходного изображения, что позволяет исключить изменения интенсивности фона. Радиус вращающегося шарика – это радиус кривизны параболоида. Как правило, он должен быть не менее радиуса самого большого объекта на изображении, не являющегося частью фона (рис. 3).

3. Размытие по Гауссу (*Gaussian blur*) – используется для устранения шумов на изображении [26] (рис. 4).
4. Выделение краев (*find edges*) – позволяет выделить резкие изменения интенсивности в активном изображении с помощью оператора Собеля.
5. Регулировка порога (*thresholding*) – обеспечивает простейшую сегментацию [25; 26] макро-изображения горной породы на маски минералов (рис. 5).




Рис. 2. Пример восстановления контрастности
Fig. 2. The deconvolution example

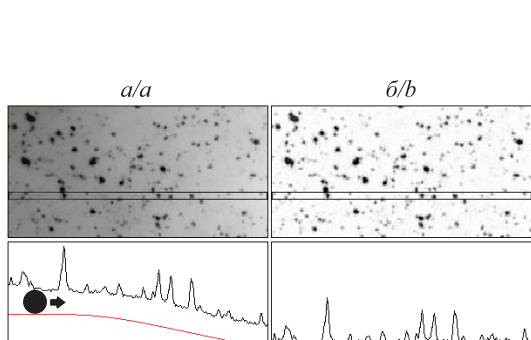


Рис. 3. Пример вычета фона:
a – исходное изображение;
b – результирующее изображение
Fig. 3. The subtract background example:
a – original image; *b* – result image




Рис. 4. Гауссово размытие по маске:
a – исходное изображение; *b* – результат
Fig. 4. The Gaussian blur example: *a* – original image; *b* – result




Рис. 5. Создание масок минералов гранита по классификационным изображениям:
a – биотит; *b* – калиевый полевой шпат; *c* – плагиоклаз; *d* – кварц
Fig. 5. Creating masks of granite minerals from classification images:
a – biotite; *b* – potassium feldspar; *c* – plagioclase; *d* – quartz

Результаты и их обсуждение

Для семейства гранитов с помощью плагина TWS созданы классы данных, каждому из которых соответствует порообразующий минерал: кварц (Q), калиевый полевой шпат (Fps), плагиоклаз (Pl) и биотит (Bi).

Для добавления объектов для каждого класса был использован инструмент ROI Manager. Посредством утилиты Multi Measure собрана статистика по объектам. Таким образом, была сформирована база данных для обучения классификатора (дерева решений). Стоит отметить, что для элементарных действий возможно написание макросов, позволяющих ускорить процесс обучения (зацикливание, измерения, управление данными и т. д.).

На тестовой выборке нескольких макроизображений производилось обучение классификатора. С помощью таких метрик, как точность (*precision*) и полнота (*recall*), оценивалось качество классификации, и при необходимости база данных дополнялась новыми ROI для класса с максимальной ошибкой. В результате по каждому макроизображению гранитов были получены классификационные изображения (рис. 6).

В эксперименте участвовал ансамбль решающих деревьев (*fast random forest*), состоящий из 200 деревьев решений. Процент ошибок варьировался от 3,531 до 6,308 %. Чаще всего алгоритм ошибался при резком переходе к гранитам с минимальным содержанием калиевого полевого шпата (Fps) (образцы 2, 5, 6). Однако эта погрешность исчезла после накопления критического количества данных.




Рис. 6. Исходные (слева) и результирующие (справа) изображения образцов гранитов: *a* – образец 1; *б* – образец 2; *в* – образец 3; *г* – образец 4; *д* – образец 5; *е* – образец 6; *ж* – образец 7. Идентифицированные классы по цвету: желтый – Q, красный – Fps, синий – Pl, зеленый – Bi

Fig. 6. Original (on the left) and result (on the right) images of granite samples: *a* – sample 1; *b* – sample 2; *c* – sample 3; *d* – sample 4; *e* – sample 5; *f* – sample 6; *g* – sample 7. Identified classes by color: yellow – Q, red – Fps, blue – Pl, green – Bi

На число ошибок также повлияла зашумленность некоторых макроизображений ввиду некорректного сканирования образцов (затемнение углов или сторон, низкое разрешение сканирования и т. д.).

После того как классификатор был натренирован на тестовой базе данных и показал качественные результаты на заданной выборке, дальнейшее обучение можно автоматизировать, написав макрос либо скрипт на загрузку новых макроизображений и применение классификации уже к ним с последующей передачей новых ROI в исходную базу данных.

Существуют разные методы определения количественного минералогического состава пород [27; 28], однако указанный подход имеет существенные преимущества. Кристаллические породы, содержащие калиевые полевые шпаты и плагиоклазы, плохо поддаются классификации из-за явлений изоморфной смесимости полевых шпатов и вариаций их структурной упорядоченности, в то время как параметры цветности этих минералов выступают надежным критерием для их классификации.

Для определения количественных характеристик минералов используются результирующие изображения классификации. При необходимости производится предварительная обработка, после чего применяется порог (*thresholding*) для создания масок и выполняется разделение перекрывающихся объектов (зерен) методом Watershed.

По минеральным маскам проводится количественный анализ: определяется процентное содержание и количество зерен. Данные, полученные по образцам изучаемых гранитов, представлены в таблице и на гистограммах рис. 7.

Результаты количественного анализа образцов семейства гранитов

Results of quantitative analysis of granite samples

Исследуемые образцы	Количество зерен				Содержание, %			
	Fps	Pl	Q	Bi	Fps	Pl	Q	Bi
Образец 1	677	1277	1386	723	45,554	14,424	31,680	7,155
Образец 2	302	438	447	247	9,068	43,629	32,141	15,152
Образец 3	1349	1704	1195	2608	34,647	42,513	15,995	7,289
Образец 4	144	1024	508	2356	37,164	26,931	25,044	9,301
Образец 5	1975	1540	3429	2910	3,078	47,071	45,607	2,392
Образец 6	676	522	579	513	17,388	42,840	18,860	19,818
Образец 7	963	827	270	835	33,676	25,163	26,213	13,934

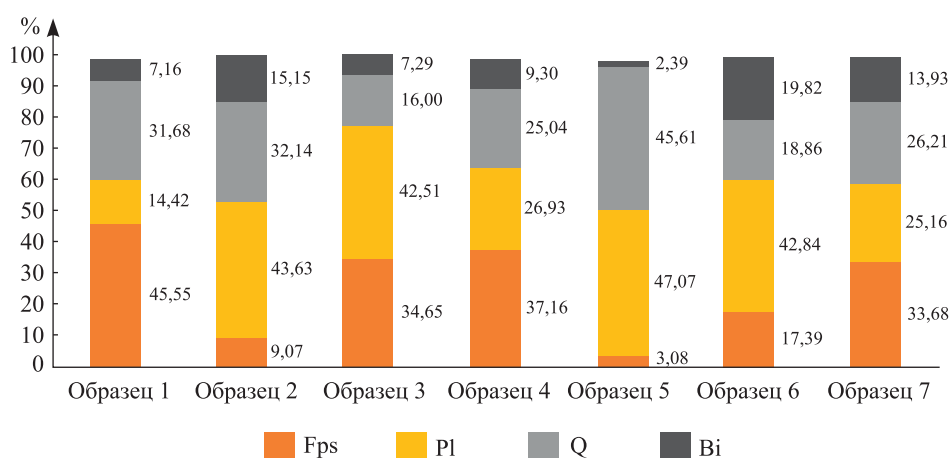


Рис. 7. Гистограмма минерального состава образцов гранитов

Fig. 7. Histogram of mineral composition of the granite samples

Интересен тот факт, что, используя количественные данные, представленные в таблице, можно сделать некоторые выводы и о структуре породы. Наиболее наглядный способ – построить гистограмму соотношения количества зерен минералов (рис. 8) и проанализировать ее вместе с гистограммой

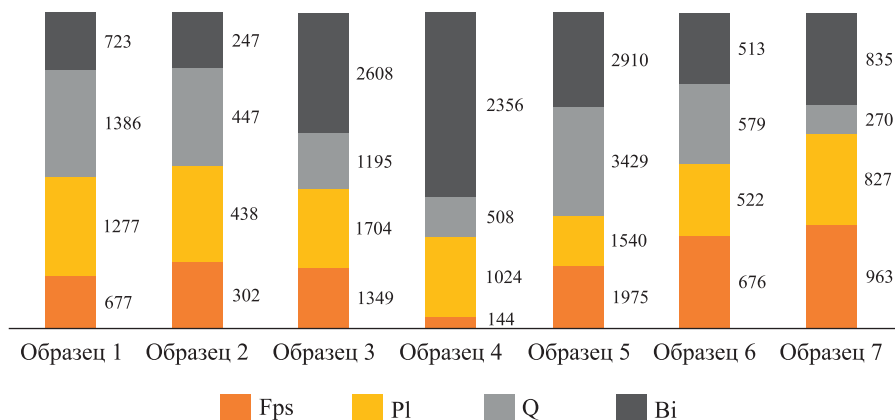


Рис. 8. Гистограмма соотношения количества зерен минералов
Fig. 8. Histogram of the ratio of the mineral grains number

минерального состава (см. рис. 7). Так, например, для образца 4 характерны крупные зерна калиевого полевого шпата (144 зерна составляют 37,164 % гранита), мелкие зерна биотита (2356 зерен занимают всего лишь 9,301 % породы) и содержащиеся в равных долях средние (относительно калиевого полевого шпата) зерна кварца и плагиоклаза. На основании этих данных можно определить крупнозернистую структуру рапакиви.

Подобный подход к классификации минералогического состава может быть применен не только к гранитоидам, но и к другим группам плутонических горных пород – монцитам, сиенитам, тоналитам и т. д. Этим определяется важное практическое значение обсуждаемого методического подхода.

Заключение

С помощью методов машинного обучения стало возможным классифицировать минералы горных пород на макро- и микроизображениях. Для семейства гранитов посредством плагина TWS были созданы классы по каждому из породообразующих минералов: кварц (Q), калиевый полевой шпат (Fps), плагиоклаз (Pl) и биотит (Bi).

Для этих классов подготовлены области интереса и сохранены в одну базу данных, по которой, собственно, и произведено обучение классификатора. По полученным классификационным изображениям созданы маски каждого минерала для последующего количественного анализа.

Одним из преимуществ классификации является тот факт, что ее качество планомерно растет по мере добавления новых данных: нетипичных примеров гранитов, образцов из различных месторождений. Как результат, ошибка идентификации минерала сводится к минимуму. Также было установлено, что чем больше классификатор тренируется, тем больше места ему необходимо для деревьев решений и для самой базы данных.

Стоит отметить, что этот метод, в отличие от других, подходит для определения калиевых полевых шпатов. Минерал отчетливо отличается по цветовым параметрам, что позволяет отделить его от таких силикатных минералов, как плагиоклазы и кварц.

Рассматриваемый метод характеризуется высокой эффективностью и повышенной точностью классификации зерен минералов на макроизображениях горных пород, определения качественных и количественных показателей, а также высокой скоростью данного процесса. Отдельные результаты этого методического подхода были представлены на Международной научной конференции «Современные проблемы геохимии, геологии и поисков месторождений полезных ископаемых», посвященной 110-летию со дня рождения академика К. И. Лукашова [29].

Библиографические ссылки

1. Kaestner A, Lehmann E, Stampanoni M. Imaging and image processing in porous media research. *Advances in Water Resources*. 2008;31(9):1174–1187. DOI: 10.1016/j.advwatres.2008.01.022.
2. Castro W, Oblitas J, De-la-Torre M, Cotrina C, Bazán K, Avila-George H. Using machine learning techniques and different color spaces for the classification of Cape gooseberry (*Physalis peruviana* L.) fruits according to ripeness level. *PeerJ Preprints*. 2019;7:e26691v2. DOI: 10.7287/peerj.preprints.26691v2.

3. Chermant J-L, Chermant L, Coster M, Dequiedt A-S, Redon C. Some fields of applications of automatic image analysis in civil engineering. *Cement and Concrete Composites*. 2001;23(2–3):157–169. DOI: 10.1016/S0958-9465(00)00059-7.
4. Egmont-Petersen M, de Ridder D, Handels H. Image processing with neural networks – a review. *Pattern Recognition*. 2002; 35(10):2279–2301. DOI: 10.1016/S0031-3203(01)00178-9.
5. Baykan NA, Yilmaz N, Kansun G. Case study in effects of color spaces for mineral identification. *Scientific Research and Essays*. 2010;5(11):1243–1253.
6. Fueten F, Mason J. An artificial neural net assisted approach to editing edges in petrographic images collected with the rotating polarizer stage. *Computers & Geosciences*. 2007;33(9):1176–1188. DOI: 10.1016/j.cageo.2006.12.007.
7. Gonçalves LB, Leta FR. An intelligent computer vision system to rock classification in oil and gas industry. *ABCM Symposium Series in Mechatronics*. 2009;4(Section I):21–30.
8. Baykan NA, Yilmaz N. Mineral identification using color spaces and artificial neural networks. *Computers & Geosciences*. 2010;36(1):91–97. DOI: 10.1016/j.cageo.2009.04.009.
9. Perez CA, Estévez PA, Vera PA, Castillo LE, Aravena CM, Schulz DA, Medina LE. Ore grade estimation by feature selection and voting using boundary detection in digital image analysis. *International Journal of Mineral Processing*. 2011;101(1–4):28–36. DOI: 10.1016/j.minpro.2011.07.008.
10. Василёнок ЕА, Самодуров ВП. Количественный анализ цифровых изображений горных пород. В: Лукашёв ОВ, Санько АФ, Зуй ВИ, Творочевич-Севрук ДЛ, редакторы. *Современные проблемы геохимии, геологии и поисков месторождений полезных ископаемых: материалы Международной научной конференции, посвященной 110-летию со дня рождения академика Константина Игнатьевича Лукашёва (1907–1987); 23–25 мая 2017 г.; Минск, Беларусь. Часть 2. Геохимия и минералогия. Экологическая геохимия и экологическая геология*. Минск: Право и экономика; 2017. с. 4–6.
11. Mitchell TM. *Machine learning*. [S. l.]: McGraw-Hill Science/Engineering/Math; 1997. 414 p.
12. Albar A, Osman MH, Abdullah MS, Ismail BN. Classification of intrusive igneous rocks using digital image processing: a binary approach. *Journal of Engineering Science*. 2013;9:11–19.
13. Dunlop H. *Automatic rock detection and classification in natural scenes, CMU-RI-TR-06-40*. Pittsburgh: Carnegie Mellon University, Robotics Institute; 2006. 66 p.
14. Mengko TR, Susilowati Y, Mengko R, Leksono BE. Digital image processing technique in rock forming minerals identification. In: *Proceedings of the 2000 IEEE Asia-Pacific conference on circuits and systems: electronic communication systems; 2000 December 4–6; Tianjin, China*. [S. l.]: IEEE; 2000. p. 441–444. DOI: 10.1109/APCCAS.2000.913531.
15. Launeau P, Cruden AR, Bouchez J-L. Mineral recognition in digital images of rocks: a new approach using multichannel classification. *The Canadian Mineralogist*. 1994;32:919–933.
16. Susilowati Y, Rahyubowato H, Mengko TR. Characteristic of interference color in rock forming mineral images. In: *Proceedings of the 2002 IEEE Asia-Pacific conference on circuits and systems; 2002 October 28–31; Denpasar, Bali, Indonesia. Volume 2*. [S. l.]: IEEE; 2003. p. 265–268. DOI: 10.1109/APCCAS.2002.1115223.
17. Davis J, Goadrich M. The relationship between precision-recall and ROC curves. In: *Proceedings of the 23rd International conference on machine learning; 2006 June 25–29; Pittsburgh, Pennsylvania, USA*. New York: ACM; 2006. p. 233–240. DOI: 10.1145/1143844.1143874.
18. Ferri C, Flach P, Hernández-Orallo J. Learning decision trees using the area under the ROC curve. In: Sammut C, Hoffmann A, editors. *Proceedings of the Nineteenth International conference on machine learning; 2002 July 8–12; Sydney, Australia*. [S. l.]: Morgan Kaufmann Publishers; 2002. p. 139–146.
19. Beggan C, Hamilton CW. New image processing software for analyzing object size-frequency distributions, geometry, orientation, and spatial distribution. *Computers & Geosciences*. 2010;36(4):539–549. DOI: 10.1016/j.cageo.2009.09.003.
20. Karakuş D, Onur AH, Deliormanlı AH, Konak G. Size and shape analysis of mineral particles using image processing technique. *Journal of Ore Dressing*. 2010;12(23):1–8.
21. Wu X, Kumar V, Quinlan JR, Ghosh J, Yang Q, Motoda H, et al. Top 10 algorithms in data mining. *Knowledge and Information Systems*. 2008;14(1):1–37. DOI: 10.1007/s10115-007-0114-2.
22. Жданов ВВ, Костин АЕ, Кухаренко ЕА, Ланда ЭА, Лукьянова ЛИ, Масайтис ВЛ и др., составители. *Петрографический кодекс России. Магматические, метаморфические, метасоматические, импактные образования: утвержден Министерством природных ресурсов Российской Федерации 15 ноября 2006 г.* Богатиков ОА, Петров ОВ, Шарпенко ЛН, редакторы. 2-е издание. Санкт-Петербург: ВСЕГЕИ; 2008. 204 с.
23. Breiman L. Random forests. *Machine Learning*. 2001;45(1):5–32. DOI: 10.1023/A:1010933404324.
24. Landini G, Randell DA, Fouad S, Galton A. Automatic thresholding from the gradients of region boundaries. *Journal of Microscopy*. 2017;265(2):185–195. DOI: 10.1111/jmi.12474.
25. Василёнок ЕА, Самодуров ВП. Определение индекса мафичности магматических пород по данным цифровой петрографии. В: Махнач АА, Астапенко ВН, Демидова СВ, Зуй ВИ, Кручек СА, Кутырло ВЭ и др., редакторы. *Проблемы геологии Беларуси и смежных территорий: материалы Международной научной конференции, посвященной 100-летию со дня рождения академика НАН Беларуси Александра Семеновича Махнач; 21–22 ноября 2018 г.; Минск, Беларусь*. Минск: СтроймедиаПроект; 2018. с. 285–288.
26. Pratt WK. *Digital image processing*. 3rd edition. New York: John Wiley & Sons; 2007. 738 p.
27. Baveye PC, Laba M, Otten W, Bouckaert L, Sterpaio PD, Goswami RR, et al. Observer-dependent variability of the thresholding step in the quantitative analysis of soil images and X-ray microtomography data. *Geoderma*. 2010;157(1–2):51–63. DOI: 10.1016/j.geoderma.2010.03.015.
28. Frančišković-Bilinski S, Bilinski H, Vdović N, Balagurunathan Y, Dougherty ER. Application of image-based granulometry to siliceous and calcareous estuarine and marine sediments. *Estuarine, Coastal and Shelf Science*. 2003;58(2):227–239. DOI: 10.1016/S0272-7714(03)00074-X.
29. Лукашёв ОВ. Международная научная конференция «Современные проблемы геохимии, геологии и поисков месторождений полезных ископаемых», посвященная 110-летию со дня рождения академика К. И. Лукашёва. *Журнал Белорусского государственного университета. География. Геология*. 2018;1:83–84.

References

1. Kaestner A, Lehmann E, Stampanoni M. Imaging and image processing in porous media research. *Advances in Water Resources*. 2008;31(9):1174–1187. DOI: 10.1016/j.advwatres.2008.01.022.
2. Castro W, Oblitas J, De-la-Torre M, Cotrina C, Bazán K, Avila-George H. Using machine learning techniques and different color spaces for the classification of Cape gooseberry (*Physalis peruviana* L.) fruits according to ripeness level. *PeerJ Preprints*. 2019;7:e26691v2. DOI: 10.7287/peerj.preprints.26691v2.
3. Chermant J-L, Chermant L, Coster M, Dequiedt A-S, Redon C. Some fields of applications of automatic image analysis in civil engineering. *Cement and Concrete Composites*. 2001;23(2–3):157–169. DOI: 10.1016/S0958-9465(00)00059-7.
4. Egmont-Petersen M, de Ridder D, Handels H. Image processing with neural networks – a review. *Pattern Recognition*. 2002;35(10):2279–2301. DOI: 10.1016/S0031-3203(01)00178-9.
5. Baykan NA, Yilmaz N, Kansun G. Case study in effects of color spaces for mineral identification. *Scientific Research and Essays*. 2010;5(11):1243–1253.
6. Fueten F, Mason J. An artificial neural net assisted approach to editing edges in petrographic images collected with the rotating polarizer stage. *Computers & Geosciences*. 2007;33(9):1176–1188. DOI: 10.1016/j.cageo.2006.12.007.
7. Gonçalves LB, Leta FR. An intelligent computer vision system to rock classification in oil and gas industry. *ABCMSymposium Series in Mechatronics*. 2009;4(Section I):21–30.
8. Baykan NA, Yilmaz N. Mineral identification using color spaces and artificial neural networks. *Computers & Geosciences*. 2010;36(1):91–97. DOI: 10.1016/j.cageo.2009.04.009.
9. Perez CA, Estévez PA, Vera PA, Castillo LE, Aravena CM, Schulz DA, Medina LE. Ore grade estimation by feature selection and voting using boundary detection in digital image analysis. *International Journal of Mineral Processing*. 2011;101(1–4):28–36. DOI: 10.1016/j.minpro.2011.07.008.
10. Vasilionak AA, Samodurov VP. [Mafic index of the igneous rocks definition by the digital petrography data]. In: Lukashev OV, San'ko AF, Zui VI, Tvoronovich-Sevruk DL, editors. *Sovremennye problemy geokhimii, geologii i poiskov mestorozhdenii poleznykh iskopayemykh: materialy Mezhdunarodnoi nauchnoi konferentsii, posvyashchennoi 110-letiyu so dnya rozhdeniya akademika Konstantina Ignat'evicha Lukasheva (1907–1987); 23–25 maya 2017 g.; Minsk, Belarus'. Chast' 2. Geokhimiya i mineralogiya. Ekologicheskaya geokhimiya i ekologicheskaya geologiya* [Modern problems of geochemistry, geology and the mineral deposits searching: proceedings of the International scientific conference, dedicated to the 110th anniversary of academician Konstantin Ignatievich Lukashev (1907–1987); 2017 May 23–25; Minsk, Belarus. Part 2. Geochemistry and mineralogy. Environmental geochemistry and environmental geology]. Minsk: Pravo i ekonomika; 2017. p. 4–6. Russian.
11. Mitchell TM. *Machine learning*. [S. l.]: McGraw-Hill Science/Engineering/Math; 1997. 414 p.
12. Albar A, Osman MH, Abdullah MS, Ismail BN. Classification of intrusive igneous rocks using digital image processing: a binary approach. *Journal of Engineering Science*. 2013;9:11–19.
13. Dunlop H. *Automatic rock detection and classification in natural scenes, CMU-RI-TR-06-40*. Pittsburgh: Carnegie Mellon University, Robotics Institute; 2006. 66 p.
14. Mengko TR, Susilowati Y, Mengko R, Leksono BE. Digital image processing technique in rock forming minerals identification. In: *Proceedings of the 2000 IEEE Asia-Pacific conference on circuits and systems: electronic communication systems; 2000 December 4–6; Tianjin, China*. [S. l.]: IEEE; 2000. p. 441–444. DOI: 10.1109/APCCAS.2000.913531.
15. Launeau P, Cruden AR, Bouchez J-L. Mineral recognition in digital images of rocks: a new approach using multichannel classification. *The Canadian Mineralogist*. 1994;32:919–933.
16. Susilowati Y, Rahyuwibowo H, Mengko TR. Characteristic of interference color in rock forming mineral images. In: *Proceedings of the 2002 IEEE Asia-Pacific conference on circuits and systems; 2002 October 28–31; Denpasar, Bali, Indonesia. Volume 2*. [S. l.]: IEEE; 2003. p. 265–268. DOI: 10.1109/APCCAS.2002.1115223.
17. Davis J, Goadrich M. The relationship between precision-recall and ROC curves. In: *Proceedings of the 23rd International conference on machine learning; 2006 June 25–29; Pittsburgh, Pennsylvania, USA*. New York: ACM; 2006. p. 233–240. DOI: 10.1145/1143844.1143874.
18. Ferri C, Flach P, Hernández-Orallo J. Learning decision trees using the area under the ROC curve. In: Sammut C, Hoffmann A, editors. *Proceedings of the Nineteenth International conference on machine learning; 2002 July 8–12; Sydney, Australia*. [S. l.]: Morgan Kaufmann Publishers; 2002. p. 139–146.
19. Beggan C, Hamilton CW. New image processing software for analyzing object size-frequency distributions, geometry, orientation, and spatial distribution. *Computers & Geosciences*. 2010;36(4):539–549. DOI: 10.1016/j.cageo.2009.09.003.
20. Karakuş D, Onur AH, Deliormanli AH, Konak G. Size and shape analysis of mineral particles using image processing technique. *Journal of Ore Dressing*. 2010;12(23):1–8.
21. Wu X, Kumar V, Quinlan JR, Ghosh J, Yang Q, Motoda H, et al. Top 10 algorithms in data mining. *Knowledge and Information Systems*. 2008;14(1):1–37. DOI: 10.1007/s10115-007-0114-2.
22. Zhdanov VV, Kostin AE, Kukhareno EA, Landa EA, Lukyanova LI, Masaitis VL, et al., compilers. *Petrographic code of Russia. Magmatic, metamorphic, metasomatic, impact rock-assemblages: approved by the Ministry of natural resources of the Russian Federation on 2006 November 15*. Bogatkov OA, Petrov OV, Sharpenok LN, editors. 2nd edition. Saint Petersburg: VSEGEI Press; 2008. 204 p. Russian.
23. Breiman L. Random forests. *Machine Learning*. 2001;45(1):5–32. DOI: 10.1023/A:1010933404324.
24. Landini G, Randell DA, Fouad S, Galton A. Automatic thresholding from the gradients of region boundaries. *Journal of Microscopy*. 2017;265(2):185–195. DOI: 10.1111/jmi.12474.
25. Vasilionak AA, Samodurov VP. Mafic index of the igneous rocks definition by the digital petrography data. In: Makhnach AA, Astapenko VN, Demidova SV, Zui VI, Kruchek SA, Kutyrla VE, et al., editors. *Problemy geologii Belarusi i smezhnykh territorii: materialy Mezhdunarodnoi nauchnoi konferentsii, posvyashchennoi 100-letiyu so dnya rozhdeniya akademika NAN Belarusi Aleksandra Semenovicha Makhnacha; 21–22 noyabrya 2018 g.; Minsk, Belarus'* [Problems of the geology of Belarus and adjacent territories: proceedings of the International scientific conference, dedicated to the 100th anniversary of the academician of the National Academy

of Sciences of Belarus Alexander Semenovich Makhnach; 2018 November 21–22; Minsk, Belarus]. Minsk: StroiMediaProekt; 2018. p. 285–288. Russian.

26. Pratt WK. *Digital image processing*. 3rd edition. New York: John Wiley & Sons; 2007. 738 p.

27. Baveye PC, Laba M, Otten W, Bouckaert L, Sterpaio PD, Goswami RR, et al. Observer-dependent variability of the thresholding step in the quantitative analysis of soil images and X-ray microtomography data. *Geoderma*. 2010;157(1–2):51–63. DOI: 10.1016/j.geoderma.2010.03.015.

28. Frančišković-Bilinski S, Bilinski H, Vdović N, Balagurunathan Y, Dougherty ER. Application of image-based granulometry to siliceous and calcareous estuarine and marine sediments. *Estuarine, Coastal and Shelf Science*. 2003;58(2):227–239. DOI: 10.1016/S0272-7714(03)00074-X.

29. Lukashov OV. International scientific conference «Contemporary problems of geochemistry, geology and prospecting for mineral resources» devoted to the 110th anniversary from academic K. I. Lukashov birth. *Journal of the Belarusian State University. Geography. Geology*. 2018;1:83–84. Russian.

Статья поступила в редколлегию 20.12.2019.

Received by editorial board 20.12.2019.