

максимального выхода УВ достигают 414–439 °С, индекс продуктивности равен 0,03–0,53, коэффициент битуминозности варьирует в пределах 0,16–0,37. Данные подтверждаются наличием Ново-Коренёвского месторождения в задонском надгоризонте межсолевой толщи Червонослободско-Малодушинской ступени.

В результате проведённых работ была создана схема корреляции по линии скв. Людвиновская 1, Высокоборская 1, Ново-Коренёвская 4 и 6 с распределением нефтематеринских слоёв по разрезу. Нефтематеринские породы приурочены к глинистым, глинисто-карбонатным и карбонатным породам, кузьмичевских, тонежских, тремлянских, вишанских, туровских, дроздовских, петриковских отложений межсолевого комплекса нижнефаменской девонской толщи. По площади и в разрезе распределение $S_{орг}$ с большой долей вероятности связано с палеогеографией осадочного бассейна.

По данным пиролитических и битуминологических исследований определено, что нефтематеринские породы достигают зоны нефтяного окна, что подтверждается наличием многочисленных нефтепроявлений в породах и Ново-Коренёвского месторождения в межсолевых нижнефаменских девонских отложениях.

1. Методические рекомендации по применению пиролитического метода в органической геохимии / науч. ред. А. Э. Конторович СНИИГиМС. Новосибирск, 1985. 42 с.
2. Тиссо Б., Вельте Д. Образование и распространение нефти. М.: Мир, 1981. 501 с.

УДК 552.08

КОЛИЧЕСТВЕННЫЙ АНАЛИЗ ЦИФРОВЫХ ИЗОБРАЖЕНИЙ ГОРНЫХ ПОРОД

Е. А. Василёнок, В. П. Самодуров

Белорусский государственный университет, географический факультет, пр. Независимости 4,
220030 Минск, Республика Беларусь; manul1994@mail.ru, vladimir_samodurov@tut.by

Введение. Анализ и классификация изображений – задача, широко востребованная во многих областях геологии, в том числе и в петрографии. Нередко возникает потребность в исследовании изображений пород, шлифов, которые содержат минеральные зёрна разной формы, размера, ориентации и цветовых характеристик. *Целью работы* является применение анализа цифровых изображений магматических пород для разработки автоматизированной процедуры их идентификации. *Исходным материалом* служили цифровые фотографии полированного гранита – кислой плутонической породы нормального ряда.

Методический подход. Исходными параметрами для анализа и классификации могут быть информация о цвете, количественных характеристиках, структуре и текстуре пород. Существует множество методов для классификации минералов: комбинаторный метод или метод порогового градиента, метод выделения путём применения оператора Лапласа и фильтра Гаусса, метод, использующий оператор Собеля и т. д.

В процессе классификации каждый пиксель цифрового снимка относят к одному из классов минералов на основании некоторых статистических критериев: яркость/тон (распознавание цветовых образов), геометрическая форма, размер, структура и текстура (распознавание пространственных образов). Результаты классификации можно использовать для создания статистических отчётов о количественном составе образцов горных пород.

В данной статье приведено сравнение трёх отличных по алгоритмам и результатам методов анализа цифровых изображений пород на примере образца гранита: 1) выделение классов на изображении с помощью порога (Threshold); 2) использование алгоритмов нейронных сетей (Neural Net Classification); 3) классификация с обучением – способ минимального расстояния – Евклидова метрика (Minimum Distance Classification).

Выделение классов с помощью порога (Threshold) производилось на исходном изображении гранита (2 341 × 1 237 pix, формат bmp, цветовое пространство HSB) без применения фильтров. Был создан набор из трёх масок (рис. 1): Mc, Q и Pl, соответственно, четвёртым компонентом являлся Vi.




Рисунок 1 – Выделение Pl (белый цвет) на цифровом изображении гранита

Маска каждого минерала создана на основе пороговых значений следующих атрибутов: Hue (H) – цветовой тон; Saturation (S) – насыщенность; Brightness (B) – яркость. Bi определен по H [0 : 255], S [0 : 70], B [0 : 50]. Маска Mc создана по значениям H [0 : 255], S [20 : 62], B [0 : 255]. Для Q пороги H [0 : 255], S [0 : 255], B [0 : 170]. Для Pl – H [0 : 255], S [0 : 70], B [0 : 110].

Результаты количественного анализа изображения гранита данным методом представлены в табл. 1. Площадь, занимаемая каждым минералом, определена в процентах (S_{min}), а также в пикселах (Area).

Таблица – Результаты количественного анализа образца гранита различными методами

Threshold			Neural Net Classification			Minimum Distance Classification		
Mineral	Area, px	S_{min} , %	Mineral	Area, px	S_{min} , %	Mineral	Area, px	S_{min} , %
Bi	262 655	8,524	Bi	182 513	6,303	Bi	283 604	9,794
Pl	1 001 760	32,512	Pl	862 776	29,794	Pl	754 621	26,059
Q	952 951	30,928	Q	924 141	31,913	Q	1 013 421	34,996
Mc	863 833	28,036	Mc	926 387	31,991	Mc	844 171	29,151
Sum	3 081 199	–	Sum	2 895 817	–	Sum	2 895 817	–
Real	2 895 817							

Как видно из таблицы, для метода выделения классов с помощью порога, количество пикселей в сумме (Sum) даёт ложное число (не реальные (Real) 2 895 817 px, а 3 081 199 px). Это связано с перекрытием областей HSB при threshold.

Классификация с использованием нейронной сети (Neural Net Classification, NNC). Стандартный алгоритм обратного распространения был использован для нейронной сети при исследовании исходного изображения образца гранита без фильтров.

Алгоритм обратного распространения – это итеративный градиентный алгоритм, который используется с целью минимизации среднеквадратичного отклонения текущего выхода персептрона и желаемого выхода. Нейроны делятся на группы с общим входным сигналом – слою. На каждый нейрон первого слоя (скрытого слоя – Hidden Layer) подаются все элементы внешнего входного сигнала. Все выходы нейронов n-ого слоя подаются на каждый нейрон слоя n + 1. Нейроны выполняют взвешенное суммирование элементов входных сигналов. К сумме элементов входных сигналов, помноженных на соответствующие веса, прибавляется смещение нейрона. Над результатом суммирования выполняется нелинейное преобразование – функция активации. Значение функции активации и есть выход нейрона.

В качестве этой функции использовалась сигмоидальная функция (1): $f(x) = x/(x + \alpha)$, где α – параметр, влияющий на наклон сигмоидальной функции активации.

Классификация минералов выполняется с помощью обучения нейронной сети (training iteration) на базе созданных областей интереса (ROI – region of interest). Данная нейронная сеть требует число

итераций от 100 до 10 000, прежде чем веса связей нейронов стабилизируются достаточно, чтобы получить выходные данные. В нашем случае произведено 200 итераций (рис. 2).

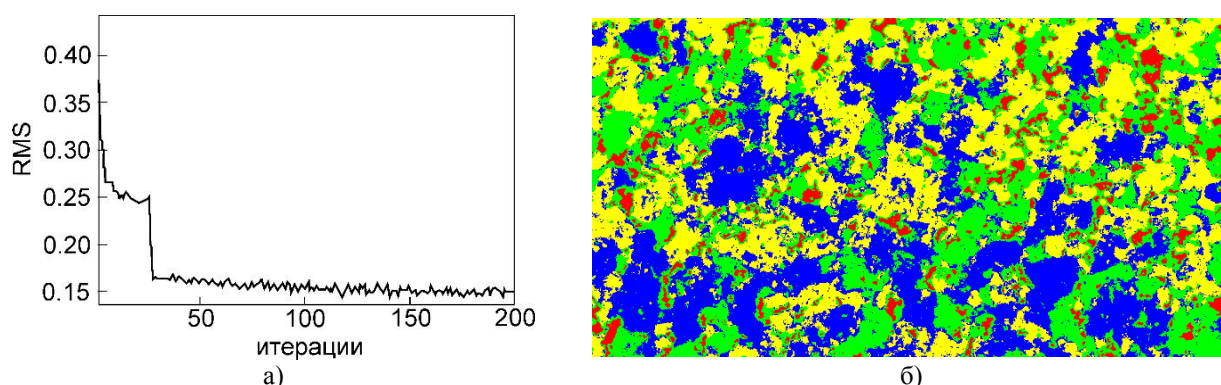


Рисунок 2 – Применение метода NNC к исходному изображению гранита
а) график зависимости среднеквадратичной ошибки (RMS) от числа итераций; б) выходные данные

Результаты Neural Net Classification (NNC) впечатляют: точность выделения минералов и определения площади, занимаемой каждым из них, высока (табл. 1).

Классификация с обучением – способ минимального расстояния (Minimum Distance Classification, MDS) при исследовании изображения образца гранита после применения Gaussian filter (рис. 3).




Рисунок 3 – Применение метода MDC к отфильтрованному изображению гранита

Данный метод основан на создании областей интереса (ROI) в качестве обучающей выборки классов. Выбор границы между классами опирается на значение стандартного отклонения или максимального расстояния (maximum distance). Однако, есть вероятность, что пиксели, не попадающие в диапазон, не будут классифицированы. Результаты MDC представлены в табл. 1.

Результаты. Выделение классов с помощью порога (Threshold) больше ориентировано на пользователя: решения о выделении тех или иных порогов выносит человек, тем самым произвольно создавая ошибку. Пороги, настроенные вручную, часто могут накладываться (табл. 1), либо не являться граничными.

Метод NNC показал хорошие результаты при минимальном воздействии человека. В данном случае, подсчёт и определение классов и их количественных характеристик производится сетью на базе выделенных областей (ROI). Таким образом, к положительным выводам стоит отнести: высокую точность, скорость и автоматизацию метода.

Метод MDC также является автоматизированным методом, использующим обучение по ROI. Однако, качество анализа заметно отстает от NNC.

Сравнение трёх методов анализа цифровых изображений пород на примере образца гранита позволяет выявить лучший метод – Neural Net Classification.

Выводы. Цифровой формат изображений горных пород предоставляет широкие возможности для развития методов автоматизированной цифровой петрографии. Проблема автоматизации в условиях возросшего количества данных и повышения требований к скорости качественного и количественного анализа состава горных пород остается актуальной в геологии и в настоящее время.