

УДК 004.932.2

ПОСТРОЕНИЕ ПРОФИЛЕЙ ТЕКСТУРНЫХ ПРИЗНАКОВ ПО ИЗОБРАЖЕНИЯМ ПОЛНОРАЗМЕРНОГО КЕРНА

© Д. О. Макиенко

*Национальный исследовательский ядерный университет «МИФИ»,
115409, Москва, Каширское шоссе, 31
E-mail: makienko-dasha@mail.ru*

Исследование изображений полноразмерного керна (образца породы, извлекаемой из скважины) востребовано в современной геофизике. Предметная область определяет специфику процессов обработки изображений керна и форму представления результатов. Обычным способом представления скважинных данных являются упорядоченные по глубине значения измерений. Образцы керна также упорядочены по глубине, а изображения образцов представляют собой набор отдельных фотографий или томографических сканов часто с отсутствием данных на некоторых глубинах. Типичное изображение одного фрагмента керна содержит метровый участок породы. При этом на практике часто требуется оценивать характеристики сантиметровых интервалов. В работе предложен подход к созданию ансамбля текстурных признаков изображений керна, представленных как упорядоченные по глубине профили, что позволяет использовать полученные результаты совместно с другими геолого-геофизическими данными.

Ключевые слова: текстура, литотип, полноразмерный керн, гистограмма, матрица совместной встречаемости.

DOI: 10.15372/AUT20230503

Введение. Цифровой анализ полноразмерного керна является востребованной задачей в современной геофизике. Извлечённые из скважины образцы керна несут важную информацию о строении горных пород. Состав исследований, которым подвергаются образцы керна, зависит от решаемой производственной задачи. Как правило, все извлечённые образцы керна фотографируются и привязываются к глубине, с которой производился отбор образцов. При исследовании участков изображений керна стараются учесть цветовые и текстурные характеристики изображения, важные для описания литологического типа, а также для прогнозирования фильтрационно-ёмкостных свойств породы. В ряде работ [1–11] по изображениям получают упорядоченные по глубине текстурные и цветовые признаки — профили, которые могут использоваться совместно с другими геолого-геофизическими данными, например с данными томографического сканирования и результатами лабораторных исследований образцов породы, каротажными данными.

Для построения профилей текстурных признаков коллекция фотографий керна анализируется в скользящем окне во всём интервале глубин. В каждой позиции окна производится анализ изображения и вычисляются текстурные характеристики. Вычисленные в текущей позиции значения сравниваются со значениями зафиксированного текстурного шаблона, что даёт возможность оценить степень сходства различных участков изображений керна и на этом основании строить профили текстурных признаков.

Породы различной зернистости могут содержать разнонаправленную слоистость, каверны, трещины или ходы разных размеров и формы, отдельные включения разнообразной формы. При этом не всегда удаётся задать параметры для обработки изображений, чтобы всё разнообразие текстурных элементов отражалось в текстурных профилях. Для того чтобы характеризовать как можно большее количество текстур пород, в работе строится




Рис. 1. Пример фотографий полноразмерного керна [12] и ансамбль текстурных профилей (1 — глубины, 2 — фотографии полноразмерного керна при дневном свете, 3 — ансамбль текстурных профилей)

ансамбль текстурных профилей. Ансамбль содержит профили, полученные для разных вариантов фильтрации изображений, двух способов получения текстурных характеристик и трёх мер сходства. Пример построения ансамбля профилей для фотографий полноразмерного керна, полученных из интернет-ресурса [12], показан на рис. 1.

Целью работы является построение ансамбля текстурных профилей, которые предназначены для использования совместно с другими типами геолого-геофизических данных для решения ряда задач, например для нахождения границ участков литотипов. Предлагается новый способ построения текстурных профилей для изображений пород путём оценивания меры сходства текстурных характеристик, вычисляемых в скользящем окне, с текстурными шаблонами.

Описание эксперимента. На современном этапе развития науки для классификации изображений успешно применяются свёрточные нейронные сети, в том числе и для классификации изображений керна [11, 13–15]. Однако для обучения свёрточной нейронной сети необходим размеченный набор данных. Подготовка набора данных с изображениями текстур пород является задачей, затратной по времени. Кроме того, сложно учесть множество текстур, встречающихся на изображениях пород, и обучить модель, применимую на различных месторождениях. Ввиду того что в работе не решается задача классификации, а предлагается подход для построения текстурных профилей, было отдано предпочтение традиционным способам описания текстур, для которых не требуется обучающий набор данных.

Среди подходов, позволяющих количественно охарактеризовать текстурные свойства различных областей изображения [16–18], были выбраны подходы, основанные на анализе одномерных и двумерных гистограмм интенсивностей [19]. Обычно операции с гистограм-

мами первого порядка требуют меньше ресурсов. В свою очередь, с помощью гистограмм второго порядка (матриц совместной встречаемости, co-occurrence matrices) можно исследовать пространственное распределение интенсивностей, меняя размер и конфигурацию двумерной сканирующей маски. В работе рассматриваются два вида гистограмм второго порядка: матрица совместной встречаемости (SM1) и матрица совместной встречаемости с усреднением значений (SM2).

Конфигурация двумерной сканирующей маски была зафиксирована. В соответствии с выбранной конфигурацией интенсивность текущего пикселя сравнивалась с интенсивностями пикселей справа и снизу от него. При построении гистограмм SM2 вычислялось среднее значение интенсивностей пикселей справа и снизу от текущего. Под размером маски понималось расстояние между текущим пикселем и пикселями, с которыми проводилось сравнение. Размер маски менялся в пределах от 1 до 10. Одним из параметров гистограмм первого и второго порядка является количество значений, на которые разбивается ряд возможных интенсивностей пикселей изображения. В данной работе одномерные гистограммы имеют размер 32 элемента, а размер гистограмм второго порядка составляет 32×32 .

В таблице перечислены сокращённые обозначения для типа гистограммы и используемой меры сходства. Одномерные гистограммы обозначаются H, два варианта двумерных гистограмм — SM1 и SM2. В качестве меры сходства текстур использовались меры сходства между гистограммами интенсивностей: метрики, основанные на корреляции и пересечении [20], а также расстояние землекопа (earth mover's distance). Вычисление расстояния землекопа между двумя гистограммами образно описывают как преобразование «горок земли» в виде первой гистограммы к виду второй гистограммы путём перемещения «земли» с наименьшими затратами (под затратами понимается произведение количества «земли» на переносимое расстояние). При вычислении расстояния землекопа для двумерных гистограмм решается линейная оптимизационная задача [21], что может быть затратным по времени. Поэтому расстояние землекопа применяется для сравнения только одномерных гистограмм и используется упрощённый вариант его вычисления [22].

Учитывая тот факт, что для фотографий ядра отсутствуют открытые размеченные наборы текстур, для оценки выбранной меры сходства изображений оказалось удобным воспользоваться готовым набором изображений Kylberg texture dataset [23] (рис. 2), некоторые классы которого схожи с изображениями горных пород. Выбранный набор содержит 28 классов текстур по 160 изображений размером 576×576 пикселей. При этом 160 изображений каждого класса содержат 4 группы, т. е. подкласса, по 40 изображений на группу. Всего $160 \times 28 = 4480$ картинок.

**Сокращённые обозначения для типов гистограмм и метрик,
используемых для сравнения изображений**

Обозначение	Тип гистограммы	Метрика
H_correlation	Одномерная гистограмма	Корреляция
H_intersection	Одномерная гистограмма	Пересечение
H_earth_mover	Одномерная гистограмма	Расстояние землекопа
SM1_correlation	Матрица совместной встречаемости	Корреляция
SM1_intersection	Матрица совместной встречаемости	Пересечение
SM2_correlation	Матрица совместной встречаемости с усреднением значений	Корреляция
SM2_intersection	Матрица совместной встречаемости с усреднением значений	Пересечение




Рис. 2. Примеры изображений для разных классов из тестового набора данных

Для того чтобы оценить «близость» классов текстур и сравнить результаты для различных параметров обработки, вычислялись следующие значения:

1. Среднее значение меры сходства между гистограммами для всех пар изображений класса l , которое обозначено c^l и названо «внутренним сходством класса l »:

$$c^l = \frac{1}{n^l(n^l - 1)/2} \sum_{i=1}^{n^l-1} \sum_{j=i+1}^{n^l} s(h_i^l, h_j^l) = \frac{2}{n^l(n^l - 1)} \sum_{i=1}^{n^l-1} \sum_{j=i+1}^{n^l} s(h_i^l, h_j^l),$$

где h_i^l, h_j^k — гистограммы i -го и j -того изображений класса l ; s — мера сходства между гистограммами; n^l — количество изображений в классе l ; $n^l(n^l - 1)/2$ — количество пар изображений в классе l . Чем меньше значение c^l , тем более близкими считаются изображения класса l .

2. Среднее значение меры сходства между гистограммами для всех пар изображений, где одно изображение принадлежит к классу l , а другое — к классу k , которое обозначено $c^{l,k}$ и названо «межклассовым сходством классов l и k »:

$$c^{l,k} = \frac{1}{n^l n^k} \sum_{i=1}^{n^l} \sum_{j=1}^{n^k} s(h_i^l, h_j^k). \quad (1)$$

Чем меньше значение $c^{l,k}$, тем более близкими считаются классы l и k .

3. Отношение среднего значения межклассового сходства класса l с другими классами к внутреннему сходству класса l , которое обозначено c_{rel}^l и названо «относительным сходством класса l »:

$$c_{rel}^l = \sum_{k \in L, k \neq l} \frac{c^{l,k}}{c^l(N - 1)},$$

где L — множество всех классов, N — количество классов.

4. Отношение межклассового сходства классов l и k к внутреннему сходству класса l , которое обозначено $c_{rel}^{l,k}$ и названо «межклассовым относительным сходством класса l с классом k »:

$$c_{rel}^{l,k} = \frac{c^{l,k}}{c^l}.$$

5. Отношение межклассового сходства класса l с ближайшим к нему другим классом к внутреннему сходству класса l , которое обозначено $c_{rel_min}^l$ и названо «минимальным относительным сходством класса l »:

$$c_{rel_min}^l = \frac{1}{c^l} \min_{k \in L, k \neq l} c^{l,k}.$$

Для разных параметров обработки могут быть получены различные значения отношения межклассового сходства к внутреннему сходству. Интересен вариант, в котором изображения одного класса будут близкими, а изображения разных классов не будут близкими. Этот случай соответствует максимизации межклассового сходства и минимизации внутреннего сходства. Для каждого класса выгоден такой вариант параметров обработки, при котором отношение межклассового сходства к внутреннему сходству максимально. В работе оцениваются относительное сходство и минимальное относительное сходство при различных параметрах обработки, а также при совместном использовании всех вариантов параметров обработки (ансамбля) для всех пар классов.

К изображениям из тестового набора применялась сглаживающая фильтрация с различными параметрами. Для каждого варианта фильтрации проводилась оценка сходства гистограмм интенсивностей по каждому изображению с гистограммой текстурного шаблона. В результате было сформировано 7 ансамблей текстурных признаков, где каждый ансамбль соответствует своей мере сходства из таблицы. Гистограммами-шаблонами могут быть, например, гистограммы, построенные по изображениям некоторых представителей классов текстур [16] или по всем изображениям.

Результаты. На рис. 3 показаны графики относительного сходства и минимального относительного сходства. Фильтры F0, ..., F47 соответствуют сглаживающей фильтрации с ядрами свёртки (0,0), ..., (47,47) с последующей обработкой градиентным фильтром с ядром свёртки (3,3). Совместное использование исходных изображений и отфильтрованных изображений с разной степенью сглаживания получалось за счёт усреднения их нормированных мер сходства и обозначено как ансамбль. В качестве подхода для получения текстурных характеристик на рис. 3 используется вариант SM1_correlation из таблицы. На рис. 3, *a* результаты соответствуют относительному сходству. На рис. 3, *b* показаны результаты минимального относительного сходства. Ансамбль показал большее минимальное относительное сходство, чем отдельные варианты обработки. На рис. 3 графики для ансамбля, исходного изображения и варианта с максимальным размером фильтра F47 выделены толстой линией.

Для относительного сходства c_{rel}^l можно выбрать ряд фильтров, которые по отдельности показывают значения больше, чем у ансамбля. Для минимального относительного сходства $c_{rel_min}^l$ предпочтительным является выбор ансамбля вместо отдельных фильтров. На рис. 4 изображены графики для классов с наименьшими и наибольшими значениями $c_{rel_min}^l$, а также графики средних значений для пяти классов с наименьшими значениями $c_{rel_min}^l$ и графики средних значений $c_{rel_min}^l$ по всем классам.

Для одномерных гистограмм варьируемым параметром является размер сглаживающего фильтра. Ансамбль был получен путём усреднения нормированных мер сходства, вычисленных для разных вариантов фильтрации. Для матриц совместной встречаемости

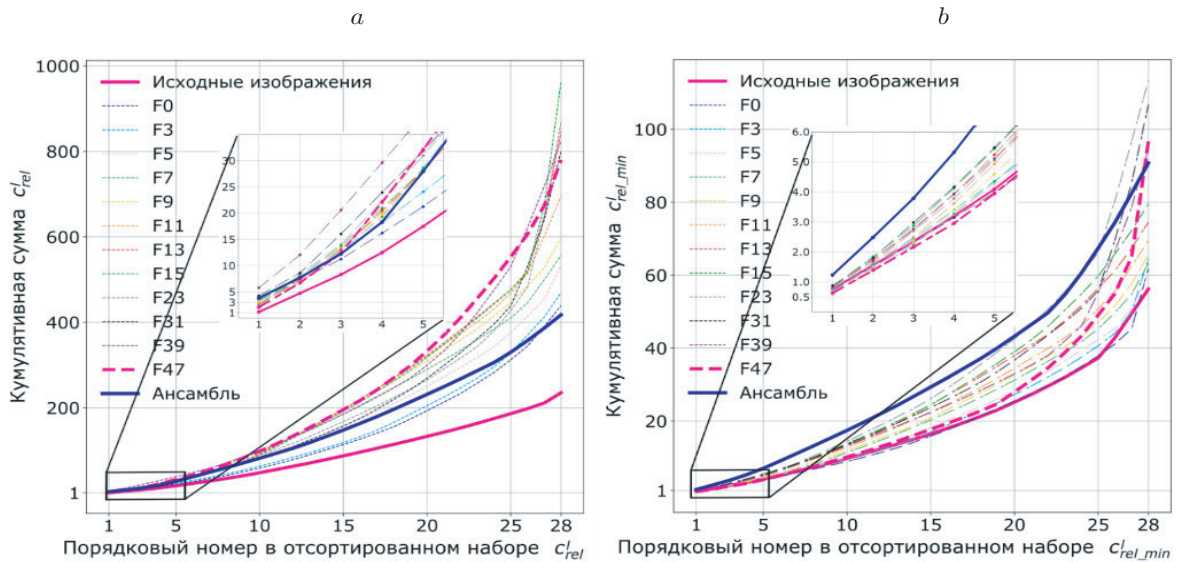


Рис. 3. Применение гистограмм второго порядка с размером маски 4 и расстояния, основанного на корреляции, для сравнения изображений из тестового набора данных: относительное сходство c^l_{rel} (a), минимальное относительное сходство $c^l_{rel,min}$ (b)

обозначим два варьируемых параметра — размер сглаживающего фильтра и размер сканирующей маски. При построении графика зависимости $c^l_{rel,min}$ от варианта фильтрации (см. рис. 4) были вычислены усреднённые нормированные меры сходства для разных размеров маски.

Графики на рис. 4 подтверждают предположение о том, что для выбранной схемы «сглаживающий фильтр — градиентный фильтр — сравнение гистограмм» выбор параметров обработки, позволяющих уверенно различать все 28 классов рассматриваемых текстур, практически не представляется возможным. Наряду с классами текстур, которые легко различаются при разных параметрах фильтрации, для некоторых текстурных классов ни один из рассмотренных вариантов не даёт оснований уверенно утверждать о различии этих классов посредством используемых метрик. В некоторых случаях ансамбль показал значения $c^l_{rel,min}$ больше, чем любой из составляющих ансамбль вариантов по отдельности.

На рис. 5 в столбце 1 изображена «синтетическая скважина», построенная из изображений тестового набора текстур. Каждый из 28 классов тестового набора данных содержит 4 группы. Из каждой группы было взято по одному изображению. Для получения «синтетической скважины» изображения были выстроены в столбец. Всего использовано $28 \times 4 = 112$ изображений. Названия классов приведены в столбце 2. Для разных сочетаний типа гистограммы и меры сходства, размеров масок и сглаживающих фильтров были построены профили текстурных признаков. На рис. 5 в столбцах 3–9 изображены усреднённые профили текстурных признаков, для получения которых вычислялось среднее значение признаков на каждой глубине. Для матриц совместной встречаемости вычислялось среднее значение признаков, построенных при разных размерах сглаживающих фильтров и масок. Для одномерных гистограмм усреднение проводилось только по размерам сглаживающих фильтров.

На ансамблях профилей текстурных кривых была выполнена кластеризация на 28 кластерах с помощью метода k -средних. Результаты кластеризации были оценены метрикой adjusted Rand index [24], которая для случайной кластеризации даёт 0 и для точного

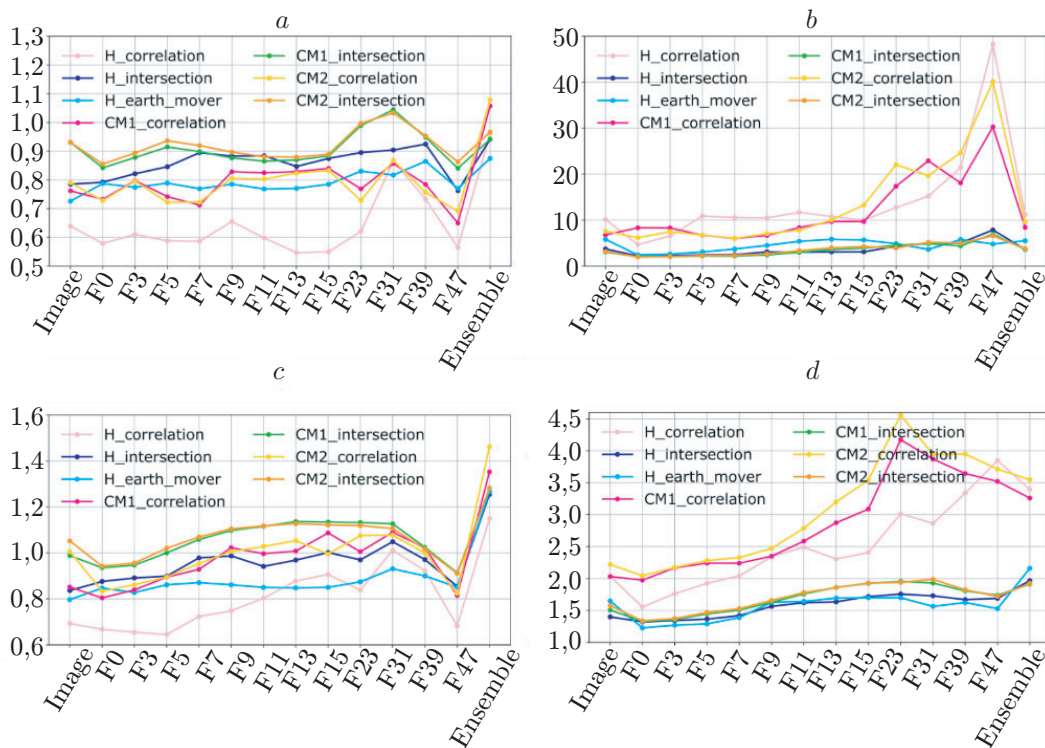


Рис. 4. Зависимость минимального относительного сходства классов $c^l_{rel.min}$ от размера сглаживающего фильтра: классы с наименьшим значением $c^l_{rel.min}$ (a); классы с наибольшим значением $c^l_{rel.min}$ (b); среднее значение для пяти классов с наименьшими значениями $c^l_{rel.min}$ (c); среднее значение $c^l_{rel.min}$ для всех классов (d)

совпадения — 1. Для визуального сравнения результатов использовались столбцы, содержащие полосы разной ширины и цвета для разных кластеров и одинаковой ширины и цвета для одного кластера. Пример такого отображения результатов кластеризации приведён на рис. 5 в столбце 10. Для демонстрации был выбран вариант кластеризации для объединённых ансамблей CM1_correlation и CM1_intersection. Использовались все признаки из ансамблей без усреднения. Результат кластеризации был обработан сглаживающим фильтром. Метрика adjusted Rand index получилась равной 0,83 по всем глубинам и 0,85 для случая исключения граничных участков между классами, в которых в скользящее окно попадают части изображений из разных классов.

На рис. 6 показан пример построения текстурных профилей по изображениям горных пород. Изображения взяты из интернет-ресурса со скважинными данными [12]. По всем признакам, составляющим ансамбли, выполнялась кластеризация методом k -средних. Для определения количества кластеров использовался силуэтный коэффициент [24]. Значения силуэтного коэффициента изменяются в интервале от -1 до 1 , и наибольшие значения коэффициента соответствуют предпочтительному числу кластеров. Для диапазона от 2 до 15 кластеров наибольшее значение силуэтного коэффициента получено для шести кластеров и равняется 0,54. На рис. 6 показаны усреднённые профили и результат кластеризации, обработанный сглаживающим фильтром.

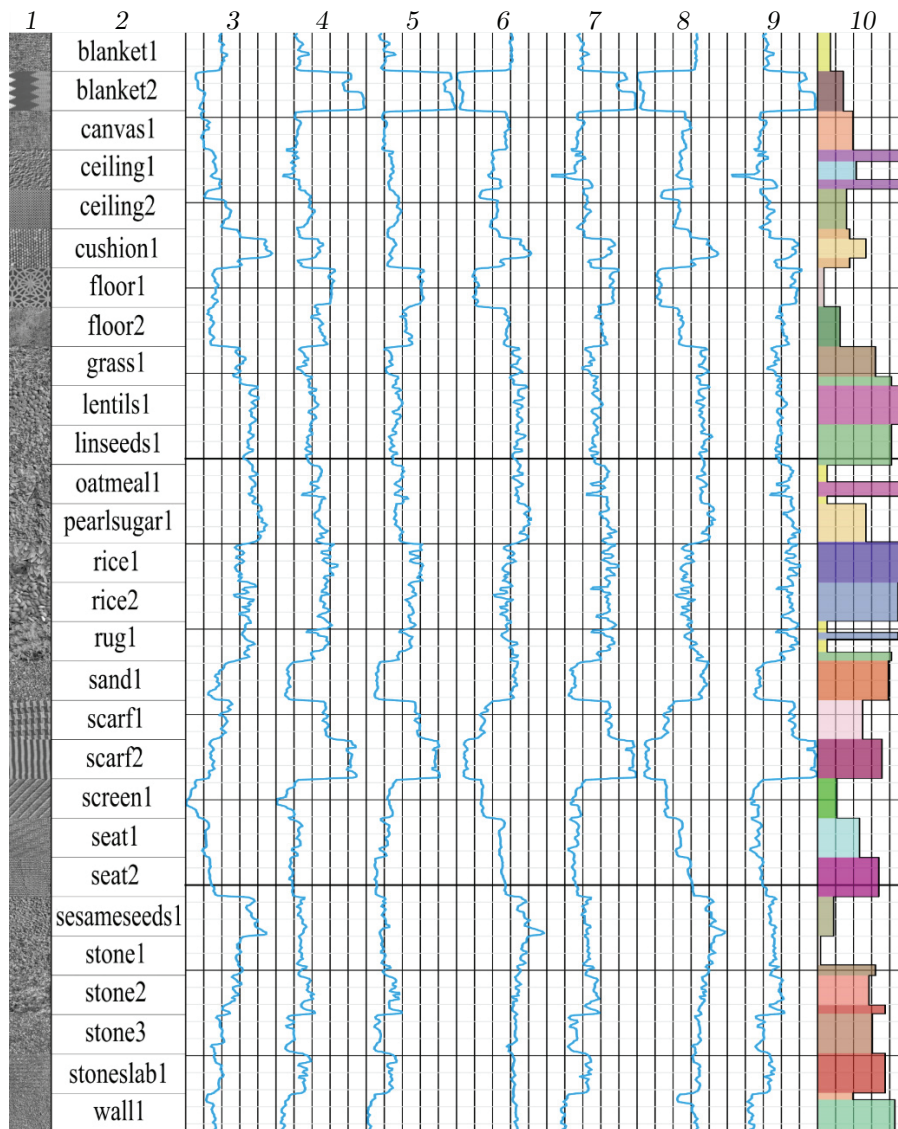


Рис. 5. Ансамбли профилей текстурных признаков для «синтетической скважины» из изображений тестового набора: 1 — схема «синтетической скважины», содержащей по 4 изображения из каждого класса текстур — по одному изображению из каждой группы (для упрощения просмотра на 4 изображения класса наложена одна из картинок); 2 — названия классов; 3–9 — усреднённые ансамбли профилей текстурных признаков: 3 — $H_{correlation}$; 4 — $H_{intersection}$; 5 — H_{earth_mover} ; 6 — $CM1_{correlation}$; 7 — $CM1_{intersection}$; 8 — $CM2_{correlation}$; 9 — $CM2_{intersection}$; 10 — результат кластеризации в объединённом пространстве признаков $CM1_{correlation}$ и $CM1_{intersection}$

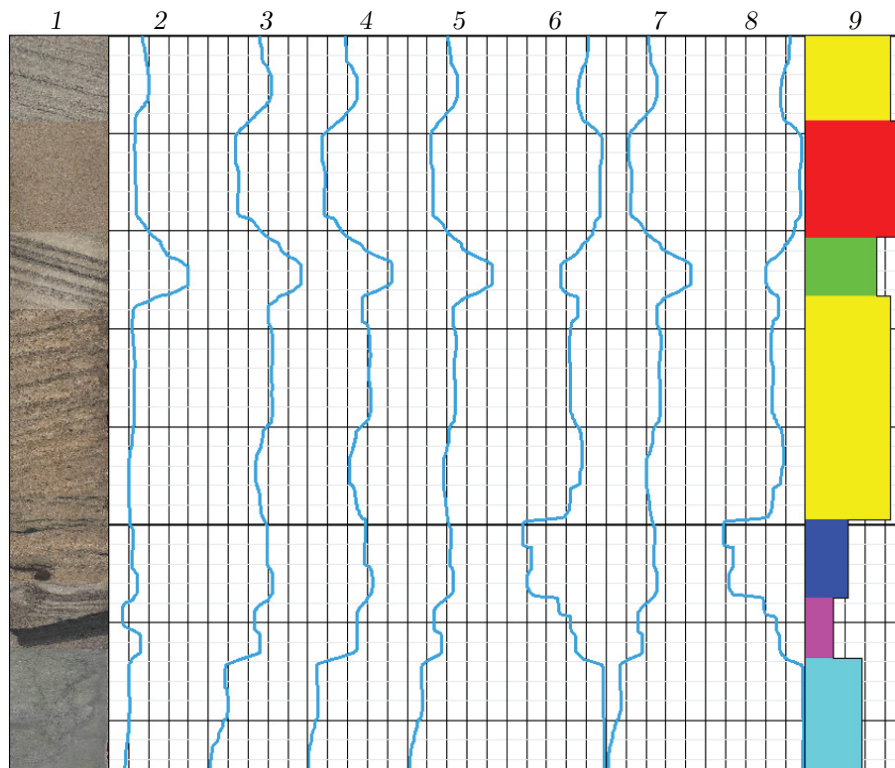


Рис. 6. Ансамбли профилей текстурных признаков для «синтетической скважины» из изображений горных пород (1 — изображения «синтетической скважины», 2–8 — усреднённые ансамбли профилей текстурных признаков: 2 — $H_correlation$, 3 — $H_intersection$, 4 — H_earth_mover , 5 — $CM1_correlation$, 6 — $CM1_intersection$, 7 — $CM2_correlation$, 8 — $CM2_intersection$, 9 — результат кластеризации в объединённом пространстве признаков)

Заключение. В представленной работе предложен подход для создания упорядоченных по глубине профилей текстурных признаков, получаемых из фотографий полноразмерного керна. Для получения каждого профиля использовались разнообразные параметры обработки и анализа изображений. При этом общая последовательность операций при построении каждого профиля не менялась: 1) применение сглаживающего фильтра, 2) применение градиентного фильтра, 3) построение $1D/2D$ -гистограммы интенсивностей, 4) получение метрики сходства с соответствующей гистограммой-шаблоном. Рассмотрено несколько метрик сходства гистограмм (см. таблицу), и для каждой из этих метрик были построены соответствующие текстурные признаки.

Визуально похожие, с точки зрения человека, текстурные примеры обычно порождают похожие текстурные признаки. Для разных классов изображений различны и параметры обработки, позволяющие подчёркивать различия между текстурами, и однозначно отдать предпочтение одному из вариантов обработки не получается. Показано, что использование ансамбля текстурных признаков на практике более целесообразно, особенно если рассматривать классы со схожими текстурами. Построены ансамбли профилей текстурных признаков для выстроенных в виде скважины изображений из набора *Kylberg texture dataset*, а также для изображений горных пород. В качестве примера использования профилей была проведена кластеризация текстур.

СПИСОК ЛИТЕРАТУРЫ

1. **Seleznev I. A., Abashkin V. V., Chertova A. A. et al.** Quantitative analysis of whole core images // Proc. of the 21st Conference on Oil and Gas Geological Exploration and Development «Geomodel 2019». Gelendzhik, Russia, 9-13 Sept., 2019. EAGE Geomodel. Eur. Assoc. Geosci. & Eng. P. 1–5.
2. **Abashkin V. V., Seleznev I. A., Chertova A. A. et al.** Quantitative analysis of whole core photos for continental oilfield of Western Siberia // Proc. of the SPE Russian Petroleum Technology Conference. Society of Petroleum Engineers. Moscow, Russia, 26-29 Oct., 2020. P. SPE-202017-MS.
3. **Abashkin V. V., Seleznev I. A., Chertova A. A. et al.** Digital analysis of the whole core photos // Proc. of the 1st EAGE Digitalization Conference and Exhibition. European Association of Geoscientists & Engineers. Vienna, Austria, 30 Nov. – 3 Dec., 2020. P. 1–5.
4. **Seleznev I. A., Chertova A. A., Abashkin V. V. et al.** Digital extraction of core properties from whole core photos // Proc. of the Int. Symposium of the Society of Core Analysts (SCA 2021). Virtual Conference. 13-16 September, 2021. Poster presentation.
5. **Seleznev I. A., Makienko D. O., Abashkin V. V. et al.** Variograms and co-occurrence matrices in problems of description of lithotypes and modeling of petrophysical properties of rocks from whole core images // Proc. of the 23th Conference on Oil and Gas Geological Exploration and Development «GeoModel 2021». Gelendzhik, Russia, 6 - 10 Sept., 2021. Geomodel. Eur. Assoc. Geosci. & Eng. P. 1–5.
6. **Perarnau A.** Use of core photo data in petrophysical analysis // Proc. of the SPWLA 52nd Annual Logging Symposium. Colorado, USA, 14–18 May, 2011. OnePetro, 2011. P. SPWLA-2011-Z.
7. **Gonzalez A., Heidari Z., Lopez O.** Automated rock classification using high-resolution CT-scan images and core photos in a siliciclastic formation used for CO₂ storage // Proc. of the SPE Annual Technical Conference and Exhibition. Houston, USA, 3-5 Oct., 2022. OnePetro, 2022. P. SPE-209979-MS.
8. **Chawshin K., Gonzales A., Berg C. F. et al.** Classifying lithofacies from textural features in whole core CT-scan images // SPE Reservoir Eval. & Eng. 2021. **24**, N 02. P. 341–357.
9. **Gonzalez A., Kanyan L., Heidari Z., Lopez O.** Integrated multi-physics workflow for automatic rock classification and formation evaluation using multi-scale image analysis and conventional well logs // Proc. of the SPWLA 60th Annual Logging Symposium. The Woodlands, USA, 15-19 June, 2019. OnePetro, 2019. P. SPWLA-2019-A.
10. **Chandra V., Tallec G., Gamba F., Vahrenkamp V.** A systematic machine learning approach to improve facies prediction using multiscale well log and image data // Proc. of the 83rd EAGE Annual Conference & Exhibition. EAGE Publications. Madrid, Spain, 6-9 June, 2022. **2022**, N 1. P. 1–5.
11. **Martin T., Meyer R., Jobe Z.** Centimeter-scale lithology and facies prediction in cored wells using machine learning // Frontiers in Earth Science. 2021. **9**. P. 659611.
12. **National** Offshore Petroleum Information Management System. URL: <https://nopims.dmp.wa.gov.au/Nopims> (дата обращения: 28.05.2023).
13. **Alzubaidi F., Mostaghimi P., Swietojanski P. et al.** Automated lithology classification from drill core images using convolutional neural networks // Journ. Petroleum Sci. and Eng. 2021. **197**. P. 107933.
14. **Houshmand N., GoodFellow S., Esmaili K., Calderyn J. C. O.** Rock type classification based on petrophysical, geochemical, and core imaging data using machine and deep learning techniques // Appl. Comput. and Geosci. 2022. **16**. P. 100104.

15. **Baraboshkin E. E., Ismailova L. S., Orlov D. M. et al.** Deep convolutions for in-depth automated rock typing // *Comput. & Geosci.* 2020. **135**. P. 104330.
16. **Liu X., Wang D. L.** Image and texture segmentation using local spectral histograms // *IEEE Trans. Image Process.* 2006. **15**, N 10. P. 3066–3077.
17. **Hung C. C., Song E., Lan Y.** *Image Texture Analysis*. Cham: Springer International Publishing, 2019. P. 264.
18. **Vil'kin A. M., Safonov I. V., Egorova M. A.** Algorithm for segmentation of documents based on texture features // *Pattern Recogn. and Image Anal.* 2013. **23**. P. 153–159.
19. **Макиенко Д. О., Болотный А. М.** Матрицы совместной встречаемости в задачах сравнения текстур // Сб. тез. XXVIII Междунар. науч. конференции студентов, аспирантов и молодых учёных «Ломоносов-2021». М.: МАКС Пресс, 2021. С. 63–66.
20. **Библиотека** обработки изображений OpenCV. URL: <http://opencv.org> (дата обращения: 28.05.2023).
21. **Rubner Y., Tomasi C., Guibas L. J.** A metric for distributions with applications to image databases // *Proc. of the Sixth Int. Conference on Computer Vision (IEEE Cat. No. 98CH36271)*. Bombay, India, 7 Jan., 1998. P. 59–66.
22. **Cha S. H., Srihari S. N.** On measuring the distance between histograms // *Pattern Recogn.* 2002. **35**, N 6. P. 1355–1370.
23. **Kylberg G.** *Kylberg Texture Dataset v. 1.0*. Uppsala, Sweden: Centre for Image Analysis, Swedish University of Agricultural Sciences and Uppsala University, 2011.
24. **Pedregosa F., Varoquaux G., Gramfort A. et al.** *Scikit-learn: Machine learning in Python* // *Journ. Machine Learning Research.* 2011. **12**. P. 2825–2830.

Поступила в редакцию 08.05.2023

После доработки 05.09.2023

Принята к публикации 25.09.2023
