

Сегментация гиперспектральных изображений с использованием снижения размерности и классических методов сегментации

Е.В. Мясников^а

^а Самарский национальный исследовательский университет имени академика С.П. Королева, 443086, Московское шоссе, 34, Самара, Россия

Аннотация

Благодаря природе гиперспектральных изображений, неуправляемая сегментация таких изображений представляется достаточно сложной задачей. В настоящей работе для решения этой задачи используется следующая трехэтапная процедура. На первом этапе снижается размерность гиперспектральных изображений. Затем применяется один из классических методов сегментации (сегментация через кластеризацию, наращивание областей или преобразование водораздела). На последнем этапе для повышения качества сегментации используется процедура слияния областей, основанная на очередях с приоритетами. Для нахождения параметров алгоритмов и сравнения методов сегментации используются меры качества сегментации (global consistency error и rand index) и хорошо известные гиперспектральные изображения.

Ключевые слова: гиперспектральное изображение; сегментация; кластеризация; преобразование водораздела; наращивание областей; слияние областей; мера качества сегментации; global consistency error; rand index

1. Введение

Гиперспектральное изображение представляет собой трехмерный массив, имеющий две пространственные размерности и одну спектральную размерность. Каждый отсчет гиперспектрального изображения является вектором, содержащим сотни компонент, соответствующих длинам волн в широком диапазоне. По сравнению с полутонными и мультиспектральными изображениями использование гиперспектральных изображений предоставляет новые возможности, позволяя извлекать информацию о материалах (компонентах), представленных на изображении. Благодаря этим уникальным свойствам гиперспектральные изображения используются в сельском хозяйстве, медицине, химии и многих других областях.

Однако высокая размерность гиперспектральных изображений часто делает невозможным прямое применение традиционных подходов к анализу таких изображений. По этой причине в последние годы анализ гиперспектральных изображений является достаточно интенсивно исследуемой областью. В настоящей работе мы рассматриваем задачу сегментации гиперспектральных изображений, представляющую собой одну из важнейших задач анализа изображений.

Сегментация изображений представляет собой процесс разбиения изображения на связанные области с однородными свойствами. В области анализа изображений методы сегментации обычно разделяются на три класса [1]: методы, основанные на признаках, методы, основанные на выделении областей, а также методы, основанные на выделении границ.

В методах, основанных на признаках, все отсчеты изображения разделяются на подмножества на основе непосредственно значений отсчетов изображения или производных от этих значений признаков. Таким образом, можно сказать, что первый класс методов работает в спектральном или производном от него пространстве. К этому классу относятся, например, методы, основанные на кластеризации [2, 3]. Методы, основанные на выделении областей, и методы, основанные на выделении границ, работают в пространственной области. В методах, основанных на выделении областей, для определения областей на изображении используется некоторый критерий однородности. Этот класс включает методы, основанные на росте областей и преобразовании водораздела [4, 5]. В методах, основанных на выделении границ, используются свойства разрывности для определения границ, разделяющих изображение на области. Методы, относящиеся к последнему классу, используются с гиперспектральными изображениями достаточно редко в связи с неоднозначностью определения границ на гиперспектральных изображениях.

В последнее время появляется все большее число работ, в которых для построения сложных методов классификации с повышенной точностью используются как методы неуправляемой сегментации, так и методы управляемой классификации [5, 6].

Необходимо отметить, что иногда в литературе методы сегментации также разделяются на два класса: неуправляемые и управляемые методы. Однако мы будем рассматривать управляемую сегментацию, как задачу классификации.

Несмотря на то, что все большее число работ посвящается разработке новых методов сегментации и улучшению методов классификации, ощущается недостаток работ, содержащих оценку хорошо известных классических методов сегментации для гиперспектральных изображений. Более того, в существующих работах по неуправляемой сегментации часто не вводят никаких численных мер для оценки и сравнения методов и ограничиваются качественными оценками. В настоящей работе для частичного устранения указанного пробела используется достаточно очевидный подход, заключающийся в снижении размерности гиперспектральных изображений и оценке трех классических методов сегментации, а именно методов, основанных на кластеризации, процедуре наращивания областей и преобразовании водораздела.

Работа организована следующим образом. В разделе 2 вводится общая схема сегментации, используемая в настоящей работе. Отдельные компоненты представленной схемы, включая используемые методы сегментации и оценку качества сегментации, кратко описываются в разделе 3. Раздел 4 содержит результаты экспериментов и их обсуждение. Работа завершается заключением.

2. Общая схема сегментации

В настоящем исследовании используется общая схема сегментации, изображенная на рис. 1.



Рис. 1. Общая схема сегментации. Альтернативные методы показаны штрих-пунктирными линиями, необязательный элемент показан пунктирными линиями.

В соответствии с приведенной выше схемой выполняется четыре последовательных этапа. На первом этапе спектральная размерность исходного изображения снижается с использованием метода главных компонент, который является наиболее известным и широко используемым линейным методом снижения размерности. На втором этапе изображение сегментируется с использованием одного из классических методов сегментации. На этом этапе каждый метод сегментации принимает на вход множество возможных параметров и создает множество сегментированных изображений. Это позволяет в дальнейшем оценить субоптимальные параметры каждого метода сегментации. На третьем этапе опционально выполняется необязательная процедура слияния областей. Предполагается, что эта процедура может повысить качество сегментации для пересегментированных изображений путем слияния смежных областей со схожими характеристиками. В любом случае на последнем этапе производится автоматическая оценка качества всех сегментированных изображений. Для выполнения этого этапа процедуре оценки предоставляются изображения с истинной сегментацией.

3. Методы

3.1. Снижение размерности

Для снижения размерности гиперспектральных данных используются как линейные, так и нелинейные методы снижения размерности. Наиболее часто используются линейные методы, включая метод главных компонент (PCA) [7], анализ независимых компонент (ICA) [8] и метод *projection pursuit*. Нелинейные методы снижения размерности (нелинейное отображение [9, 10], метод *Isomap* [11], метод *locally linear embedding* [12], метод *laplacian eigenmaps* [13]) используются реже в связи с высокой вычислительной сложностью таких методов.

В настоящей работе применяется метод главных компонент (PCA), как наиболее часто используемый в таких случаях. Этот метод осуществляет поиск линейной проекции в подпространство меньшей размерности, максимизирующей разброс данных. Метод PCA часто рассматривается, как линейный метод снижения размерности данных, минимизирующий потерю информации. В настоящей работе метод PCA используется для отображения гиперспектральных данных в пространства низкой размерности с использованием размерности выходного пространства, варьирующейся от 2 до 10.

3.2. Сегментация на основе кластеризации

Метод сегментации, основанный на методе кластеризации, достаточно прост и состоит из двух шагов. Вначале осуществляется кластеризация отсчетов изображения в редуцированном пространстве. На этом этапе алгоритм кластеризации разбивает множество отсчетов изображения на некоторое количество подмножеств в соответствии со свойствами отсчетов. На втором этапе с использованием процедуры разметки изображения выделяются связанные области изображения, содержащие отсчеты, относящиеся к соответствующим кластерам.

Существует большое количество алгоритмов кластеризации относящихся к следующим классам [3]: иерархическая кластеризация, кластеризация на основе плотности, спектральная кластеризация и т.д. Несмотря на то, что было предложено большое количество алгоритмов кластеризации, известный алгоритм K-внутригрупповых средних (k-

means) [14] остается наиболее часто упоминаемым подходом. В настоящей работе этот алгоритм используется с евклидовой мерой расстояния. Для инициализации центров кластеров использовался алгоритм k-means++ [15]. Было показано, что алгоритм k-means++ позволяет достичь более быстрой сходимости к лучшим локальным минимумам, чем базовый алгоритм.

Для получения удовлетворительного решения количество кластеров варьировалось от 10 до 100. Для каждого заданного количества кластеров инициализация и запуск процедуры кластеризации осуществлялись по пять раз для выбора наилучшей из выполненных инициализаций.

3.3. Сегментация на основе наращивания областей

Главная идея метода, основанного на наращивании областей, заключается в выращивании областей, начиная с выбранного множества начальных точек, называемых семенами. Этот метод состоит из двух этапов. На первом этапе с использованием некоторого алгоритма выбираются семена. На втором этапе из выбранных семян происходит выращивание областей. На этом этапе для проверки того, принадлежат ли соседние пиксели выращиваемой области, используется некоторый критерий однородности.

Выбор начальных точек (семян) является важным вопросом в рамках рассматриваемого подхода. В настоящей работе в качестве семян выбираются локальные минимумы абсолютного значения градиента изображения. Кроме того используется простой критерий однородности, основанный на евклидовом расстоянии между проверяемыми отсчетами и соответствующими семенами. Таким образом, метод сегментации, основанный на наращивании областей, имеет один настраиваемый параметр (пороговое значение для наращивания областей), используемый в критерии однородности.

3.4. Сегментация с использованием преобразования водораздела

В сегментации, основанной на преобразовании водораздела [16], полутоновое изображение рассматривается как топографический рельеф. Источники воды помещаются в каждый локальный минимум (отсчет с локально минимальным значением на карте высот). То есть источники воды находятся в нижних точках областей, называемых водосборными бассейнами. Затем водосборные бассейны наполняются водой из источников, а в качестве границ выбираются те отсчеты изображения, в которых встречаются воды из различных источников.

Для сегментации изображения с использованием преобразования водораздела вначале выполняется поиск локальных минимумов градиента изображения. Затем для получения границ областей применяется преобразование водораздела. Далее по границам между областями с использованием процедуры разметки изображения выполняется извлечение связанных областей, находящихся внутри границ. На заключительном шаге выполняется классификация граничных отсчетов к одной из смежных областей с использованием правила ближайшего соседа.

3.5. Процедура слияния областей

К сожалению, каждый из рассматриваемых подходов к сегментации может порождать пересегментированные изображения по следующим причинам:

- используется чрезмерно большое количество кластеров в первом подходе,
- найдено чрезмерно большое количество локальных минимумов градиентного изображения во втором и третьем подходе.

Для решения проблемы пересегментации используется необязательный этап слияния областей (в соответствии с рис. 1). Основная идея процедуры слияния состоит в слиянии смежных областей со схожими характеристиками, начиная с наиболее схожих по характеристикам областей. Краткое описание предложенной процедуры слияния приведено ниже.

На первом шаге формируется список смежных областей, содержащий информацию обо всех парах смежных областей без повторов. На втором шаге выполняется оценка схожести областей для всех пар в списке. После этого все найденные пары помещаются в очередь с приоритетами так, что пары с наиболее схожими областями получают в очереди наибольший приоритет. На последнем шаге, пары, имеющие наибольший приоритет, последовательно исключаются из очереди с приоритетами, при этом выполняется слияние соответствующих областей изображения, и производится обновление информации в очереди. Критерий остановки процедуры может быть основан на количестве областей или на пороговом значении для слияния. В настоящей работе использовался последний вариант на основе настраиваемого порогового значения.

3.6. Оценка качества сегментации

Исследователями было разработано достаточно большое количество мер оценки качества сегментации. Эти меры могут быть разделены на несколько классов [17]: меры оценки качества, основанные на областях (принимающие во внимание характеристики сегментированных областей), методы оценки качества, основанные на границах (принимающие во внимание характеристики границ сегментированных областей), меры, основанные на теории информации, непараметрические меры. Первый класс включает так называемое направленное расстояние Хэмминга (directional Hamming distance) [18], которое является ассиметричной метой, нормализованное расстояние Хэмминга

(normalized Hamming distance) [18], локальную / глобальную ошибки согласованности (local / global consistency errors) [21] и т.д. Второй класс включает меры точности и полноты (precision and recall) [19], экскаваторное расстояние (earth movers distance) [20] и др. Примером меры третьего класса является variation of information [24]. Четвертый класс включает меру Rand index [22], ее модификации и некоторые другие меры.

Анализ литературы показал, что, несмотря на большое количество разработанных мер оценки, ощущается недостаток статей, посвященных сравнительному анализу таких мер [23]. Этот факт усложняет обоснованный выбор какой-то определенной меры качества сегментации. Учитывая, что исследование мер качества сегментации не является целью настоящей работы, предлагается использовать ошибку согласованности [21] и меру Rand index [22], так как они являются одними из наиболее часто используемых мер. Глобальная ошибка согласованности имеет вид [21]:

$$GCE(S_1, S_2) = \frac{1}{n} \min \left\{ \sum_i \varepsilon_i(S_1, S_2), \sum_i \varepsilon_i(S_2, S_1) \right\}$$

Здесь S_1 и S_2 – два сравниваемых результата сегментации,

$$\varepsilon_i(S_1, S_2) = \frac{|R_{1i} \setminus R_{2i}|}{|R_{1i}|}$$

является мерой ошибки для i -го отсчета, R_{1i} – область, содержащая i -ый отсчет на сегментации S_1 , R_{2i} – область, содержащая i -ый отсчет на сегментации S_2 .

В качестве альтернативного подхода для оценки качества сегментации использовался Rand Index (RI) [22]:

$$RI(S_1, S_2) = \frac{1}{\binom{N}{2}} \sum_{\substack{i,j \\ i \neq j}} (I(l_i^1 = l_j^1 \wedge l_i^2 = l_j^2) + I(l_i^1 \neq l_j^1 \wedge l_i^2 \neq l_j^2))$$

Здесь $I()$ является функцией тождества, l_i^k – метка (идентификатор) сегмента, к которому относится i -ый отсчет на k -ой сегментации. Делитель представляет собой количество всех возможных пар из N отсчетов без повторов.

4. Результаты и обсуждение

В настоящем разделе описываются результаты экспериментальных исследований в соответствии с общей схемой, описанной во втором разделе.

При проведении экспериментов использовались открытые и хорошо известные сцены дистанционного зондирования [25]. Ниже приводятся результаты исследований для сцены Indian Pines, 145 x 145 отсчетов, 224 спектральных диапазона, полученной с использованием сенсора AVIRIS. Использовались 200 спектральных диапазонов, отобранных путем исключения диапазонов с высоким уровнем шумов и водопоглощения. Эта гиперспектральная сцена предоставляется с маской истинной сегментации, которая использовалась для оценки качества сегментации (рис. 2).

Результаты экспериментов приведены ниже. Необходимо отметить, что меньшие значения меры GCE предпочтительнее, чем большие значения. Напротив, для меры RI лучшими являются более высокие значения.




Рис. 2. Гиперспектральное изображение Indian Pines Test Site 3: истинная классификация (а) и гиперспектральное изображение, представленное в ложных цветах с использованием метода нелинейного отображения (б).

Результаты оценки качества для метода кластеризации k-means показаны на рис. 3. Как видно из приведенных графиков, обе меры монотонно убывают с ростом количества кластеров (рис. 3а). Это означает, что мера GCE с ростом количества кластеров улучшается, в то время как мера RI принимает худшие значения. В такой ситуации выходом является оптимизация одной из мер при ограничении на потери другой меры. На рис. 3б показано, что видимой зависимости качества сегментации от размерности редуцированного пространства для фиксированного количества кластеров не наблюдается.

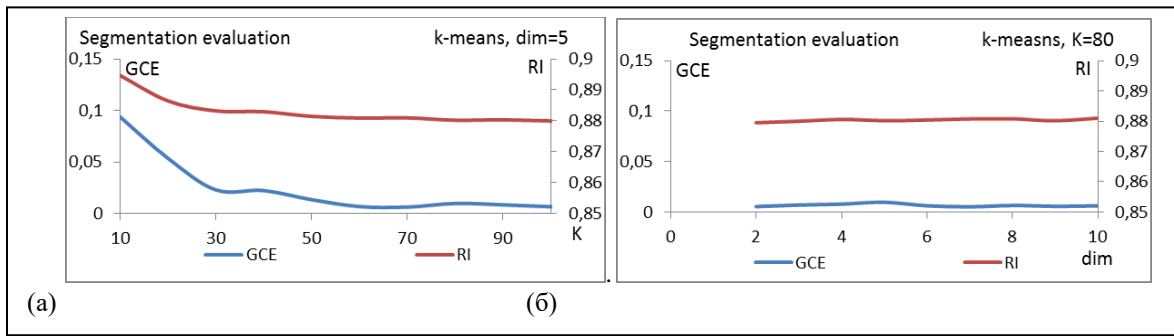


Рис. 3. Оценка сегментации для алгоритма кластеризации k-means. Зависимость меры качества: от количества кластеров для фиксированной размерности (а); от размерности для фиксированного количества кластеров (б).




Рис. 4. Оценка сегментации для алгоритма наращивания областей. Зависимость мер качества: от порогового значения, используемого при росте областей, для фиксированной размерности (а); от размерности для фиксированного порогового значения, используемого при росте областей (б).

Результаты экспериментальных исследований алгоритмов, основанных на наращивании областей и преобразовании водораздела, показаны на рис. 4 и 5 соответственно. Как видно из рис. 4а и 5а, выбор пороговых значений позволяет достаточно точно настроить качество сегментации. Как в случае с методом сегментации на основе наращивания областей, так и в случае с использованием преобразования водораздела, оба показателя ведут себя противоположным образом. При этом в случае преобразования водораздела показатели достигают своих наилучших значений примерно при одних и тех же значениях параметра.

Как видно из рис. 4б и 5б, размерность редуцированного пространства практически не имеет значения.

В следующих ниже таблицах сведены наилучшие значения мер качества. В этих таблицах оптимизирована одна мера качества и ограничены потери другой меры. В таблице 1 снижение меры RI ограничено величинами 0.88 (менее строгий случай), и 0.885 (более строгий случай), и произведен поиск наилучших (меньших) значений меры GCE. В таблице 2 рост меры GCE ограничен значениями 0.2 (менее строгий случай) и 0.15 (более строгий случай), и произведен поиск наилучших (больших) значений меры RI.

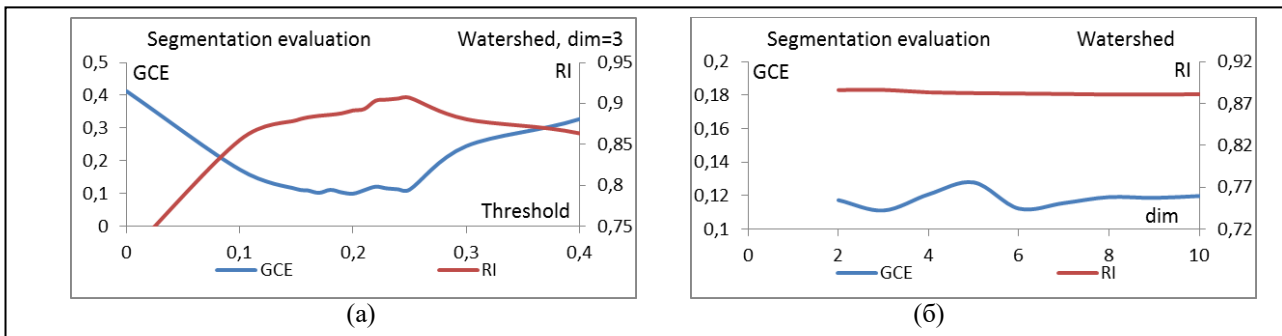
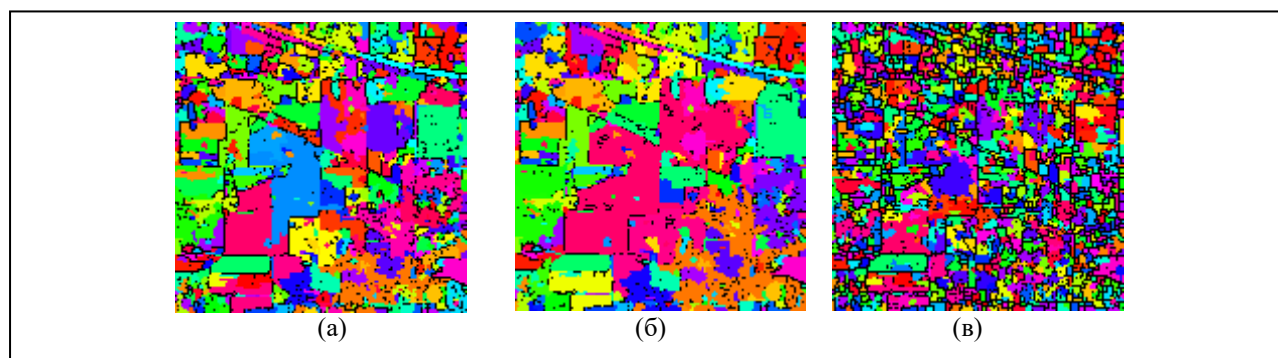


Рис. 5. Оценка сегментации для алгоритма, основанного на преобразовании водораздела. Зависимость мер качества: от порогового значения при фиксированной размерности (а); от размерности при фиксированном пороговом значении (б).

Результаты экспериментов показали, что наилучшие значения меры GCE были получены с использованием метода сегментации на основе алгоритма K-внутригрупповых средних. Наилучшие значения меры RI получены с использованием методов наращивания областей.

Результаты аналогичных исследований для сцены Salinas [25], 217x512 отсчетов, 224 спектральных диапазона (как и в предыдущем случае, использовались 200 спектральных диапазонов), полученной с использованием сенсора AVIRIS, приведены в таблице 3. Здесь в левой части таблицы производился поиск наилучших (меньших) значений меры GCE при ограничении на RI, а в правой части таблицы производился поиск наилучших (больших) значений меры RI при ограничении на GCE. Как видно из приведенной таблицы, эксперименты подтвердили описанные результаты.



Некоторые примеры выполненной сегментации показаны на рис. 6.

Рис. 6. Примеры сегментации (сегменты показаны случайными цветами): (а) преобразование водораздела ($GCE=0,111$; $RI=0,891$), (б) недосегментированное изображение ($GCE=0,215$; $RI=0,887$), (в) пересегментированное изображение ($GCE=0,203$; $RI=0,846$).

Таблица 1. Сравнение методов для изображения Indian Pines Test Site 3: лучшие значения GCE

Размерность	RI>0,88			RI>0,885		
	k-means	Наращивание областей	Преобразование водораздела	k-means	Наращивание областей	Преобразование водораздела
2	0,007	0,142	0,113	0,052	0,141	0,117
3	0,004	0,139	0,099	0,053	0,139	0,099
4	0,006	0,128	0,117	0,053	0,127	0,117
5	0,006	0,139	0,125	0,053	0,138	0,125
6	0,006	0,134	0,106	0,053	0,134	0,161
7	0,005	0,132	0,111	0,039	0,131	0,164
8	0,007	0,133	0,1129	0,052	0,132	0,148
9	0,006	0,137	0,115	0,036	0,137	0,170
10	0,005	0,135	0,119	0,054	0,135	0,133
Среднее значение	0,006	0,135	0,113	0,049	0,135	0,137

Таблица 2. Сравнение методов для изображения Indian Pines Test Site 3: лучшие значения RI

Размерность	GCE<0,2			GCE<0,15		
	k-means	Наращивание областей	Преобразование водораздела	k-means	Наращивание областей	Преобразование водораздела
2	0,893	0,897	0,891	0,893	0,888	0,886
3	0,893	0,895	0,907	0,893	0,887	0,907
4	0,888	0,904	0,895	0,888	0,904	0,886
5	0,894	0,901	0,888	0,894	0,897	0,885
6	0,889	0,903	0,889	0,889	0,903	0,884
7	0,888	0,902	0,888	0,888	0,902	0,883
8	0,886	0,902	0,889	0,886	0,902	0,889
9	0,886	0,901	0,887	0,886	0,901	0,882
10	0,894	0,901	0,888	0,894	0,901	0,888
Среднее значение	0,890	0,901	0,891	0,890	0,898	0,888

5. Заключение

В настоящей работе произведена оценка нескольких классических методов сегментации изображений для решения задачи сегментации гиперспектральных изображений дистанционного зондирования Земли. Оцениваемые методы включали сегментацию на основе кластеризации с использованием алгоритма K-внутригрупповых средних, метод наращивания областей, а также метод, основанный на преобразовании водораздела. Для выполнения оценки снижалась размерность гиперспектральных данных, выполнялась сегментация, а затем производилась оценка качества сегментированных изображений. Экспериментальные исследования показали, что наилучшие значения меры GCE были получены с использованием метода на основе кластеризации. Наилучшие значения меры RI были получены с использованием метода наращивания областей.

Таблица 3. Сравнение методов для изображения Salinas: лучшие значения GCE и RI

Размерность	GCE при RI>0,885			RI при GCE<0,15		
	k-means	Наращивание областей	Преобразование водораздела	k-means	Наращивание областей	Преобразование водораздела
2	0,0007	0,0682	0,0016	0,9280	0,9816	0,9224
3	0,0014	0,0696	0,0013	0,9297	0,9822	0,9256
4	0,0009	0,0615	0,0013	0,9301	0,9822	0,9275
5	0,0010	0,0643	0,0013	0,9380	0,9821	0,9257
6	0,0009	0,0636	0,0013	0,9336	0,9821	0,9273
7	0,0009	0,0635	0,0013	0,9281	0,9821	0,9274
8	0,0013	0,0652	0,0013	0,9312	0,9821	0,9263
9	0,0006	0,0653	0,0013	0,9385	0,9821	0,9246
10	0,0014	0,0654	0,0013	0,9423	0,9821	0,9246
Среднее значение	0,0011	0,0652	0,0014	0,9333	0,9821	0,9257

Благодарности

Работа была поддержана Российским фондом фундаментальных исследований, проект № 16-37-00202_мол_а.

Литература

- [1] Fu, K.S. A survey on image segmentation / K.S. Fu, J.K. Mui // Pattern Recognition. – 1981. – Vol. 13(1). – P. 2–16.
- [2] Berthier, M. Binary codes k-modes clustering for HSI segmentation / M. Berthier, S. El Asmar, C. Frélicot // 2016 IEEE 12th Image, Video, and Multidimensional Signal Processing Workshop (IVMSP). - 2016. - P. 1-5.
- [3] Cariou, C. Unsupervised nearest neighbors clustering with application to hyperspectral images / C. Cariou, K. Chehdi // IEEE J. of Select. Topics in Signal Processing. - 2015. – Vol. 9(6). – P. 1105–1116.
- [4] Noyel, G. Morphological segmentation of hyperspectral images / G. Noyel, J. Angulo, D. Jeulin // Image Anal. Stereol. – Vol. 26. – P. 101-109.
- [5] Tarabalka, Y. Segmentation and classification of hyperspectral images using watershed transformation / Y. Tarabalka, J. Chanussot, J.A. Benediktsson // Pattern recognition. – Vol. 43(7). – 2010. – P. 2367–2379.
- [6] Goretta, N. An iterative hyperspectral image segmentation method using a cross analysis of spectral and spatial information / N. Goretta, G. Rabatel, C. Fiorio, C. Lelong, J.M.Roger // Chemometrics and Intelligent Laboratory systems. – 2012. – Vol. 117(1). - P. 213–223.
- [7] Richards, J. A. Remote Sensing Digital Image Analysis: An Introduction / J. A. Richards, X. Jia, D. E. Ricken, W. Gessner. - Springer-Verlag New York, Inc. – 1999.
- [8] Wang, J. Independent component analysis-based dimensionality reduction with applications in hyperspectral image analysis / J. Wang, C.-I. Chang // IEEE Trans. Geosci. Remote Sens. – Vol. 44 (6). - 2006. – P. 1586-1600.
- [9] Myasnikov, E.V. Nonlinear mapping methods with adjustable computational complexity for hyperspectral image analysis / E.V. Myasnikov // Proc. SPIE 9875. – 2015. – P. 987508.
- [10] Myasnikov, E. Evaluation of Stochastic Gradient Descent Methods for Nonlinear Mapping of Hyperspectral Data / E. Myasnikov // Lec. Notes Comput. Sci. – 2016. – Vol. 9730. - P. 276-283.
- [11] Sun, W. UL-Isomap based nonlinear dimensionality reduction for hyperspectral imagery classification / W. Sun et al. // ISPRS J. Photogramm. Remote Sens. – 2014. – Vol. 89. – P. 25-36.
- [12] Kim, D.H. Hyperspectral image processing using locally linear embedding / D.H. Kim, L.H. Finkel // First International IEEE EMBS Conference on Neural Engineering. – 2003. - P. 316–319.
- [13] Doster, T. Building Robust Neighborhoods for Manifold Learning-Based Image Classification and Anomaly Detection / T. Doster, C.C. Olson // Proc. SPIE 9840. – 2016. – P. 984015.
- [14] Lloyd, S.P. Least Squares Quantization in PCM / S.P. Lloyd // IEEE Transactions on Information Theory. – 1982. - Vol. 28. – P. 129–137.
- [15] David, A. K-means++: The Advantages of Careful Seeding / A. David, S. Vassilvitskii // SODA '07: Proceedings of the Eighteenth Annual ACM-SIAM Symposium on Discrete Algorithms. – 2007. - P. 1027–1035.
- [16] Beucher, S. Use of watersheds in contour detection / S.Beucher, C.Lantuejoul // International Workshop Image Processing, Real-Time Edge and Motion Detection / Estimation. - 1979.
- [17] Unnikrishnan, R. A Measure for Objective Evaluation of Image Segmentation Algorithms / R. Unnikrishnan, C. Pantofaru, M. Hebert // 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05) – Workshops. – 2005. - P. 34–34.
- [18] Huang, Q. Quantitative methods of evaluating image segmentation / Q. Huang, B. Dom // Proc. of IEEE International Conference on Image Processing. – 1995. - Vol. III. - P. 53–56.
- [19] Martin, D. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics / D. Martin, C. Fowlkes, D. Tal, J. Malik // Proc. of IEEE International Conference on Computer Vision. – 2001. - Vol. II. - P. 416–423.
- [20] Monteiro, F. Performance evaluation of image segmentation / F. Monteiro, A. Campilho // Proc. of International Conference on Image Analysis and Recognition, LNCS. - Vol. 4141. – 2006. - P. 248–259.
- [21] Martin, D. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics / D. Martin, C. Fowlkes, D. Tal, J. Malik // Proceedings of IEEE International Conference on Computer Vision. – 2001. - P. 416–423.
- [22] Rand, W.M. Objective criteria for the evaluation of clustering methods / W. M. Rand // Journal of the American Statistical Association. – 1971. – Vol. 66 (336). - P. 846–850.
- [23] Monteiro, F.C. Distance Measures for Image Segmentation Evaluation / F.C. Monteiro, A.C. Campilho // Numerical Analysis and Applied Mathematics ICNAAM 2012, AIP Conf. Proc. – 1479. - 2012. – P. 794-797.
- [24] Meila, M. Comparing clusterings by the variation of information / M. Meila // Conference on Learning Theory. – 2003.
- [25] [Electronic resource]. — Access mode: http://www.ehu.es/ccwintco/index.php?title=Hyperspectral_Remote_Sensing_Scenes (01.12.2016)