ОБНАРУЖЕНИЕ АНОМАЛИЙ НА ГИПЕРСПЕКТРАЛЬНЫХ ИЗОБРАЖЕНИЯХ

Денисова А.Ю., Мясников В.В.

Институт систем обработки изображений РАН, Самарский государственный аэрокосмический университет имени академика С.П. Королёва (национальный исследовательский университет)

Аннотация

В статье предлагается несколько новых алгоритмов обнаружения аномалий на гиперспектральных изображениях, использующих различные способы определения факта «аномальности». Производится сравнение предлагаемых алгоритмов с широко используемым RXD-алгоритмом и его модификациями, на ряде примеров продемонстрированы преимущества предложенных решений.

<u>Ключевые слова</u>: гиперспектральные изображения, обнаружение аномалий, спектральное рассогласование, RX-детектор аномалий.

Введение

Одной из распространённых задач обработки цифровых гиперспектральных изображений является обнаружение аномалий. Существуют совершенно различные определения понятия «аномалия», используемые в различных прикладных задачах и зависящие от специфики данных [1]. Применительно к задачам анализа гиперспектральных изображений под *аномалией* обычно понимают пространственную область небольшого размера, спектральное описание которой имеет существенное отличие от её окрестности [2–4].

Один из первых алгоритмов обнаружения аномалий, который был предложен для обработки гиперспектральных изображений в работе [5], - это RX-алгоритм (RX detector), получивший широкое распространение и названный в честь его авторов - I.S. Reed and X.Yu. Величина «аномальности», вычисляемая в RXD-алгоритме, представляет собой расстояние Махалонобиса до среднего значения спектральных сигнатур на изображении. Таким образом, в качестве аномалии выступают наиболее удалённые от среднего значения сигнатуры с учётом корреляционных зависимостей между спектральными каналами. Этот первый алгоритм демонстрировал хорошие результаты для изображений с «простым» фоном, представимым единственной сигнатурой, но для более сложных задач оказался неэффективным. Данный факт, а также возможность разного формализованного определения данного выше понятия «аномалия» привели к появлению большого числа как модификаций предложенного RXалгоритма, так и совершенно новых решений. Некоторые возможные классификации таких решений по различным критериям с достаточно полными списками соответствующих публикаций представлены, например, в монографиях [3-4] и обзорных работах [6-10]. А примерами работ с модификацией известного RX-алгоритма и разработками новых алгоритмов являются работы соответственно [11] и [12-15].

Следуя классификации, данной в работах [7–8], алгоритмы обнаружения аномалий можно подразделить на подгруппы по используемым в них подходам:

– алгоритмы, использующие переход к сокращённому описанию (Subspace Methods), для которого обычно используется метод главных компонент, или метод сингулярного разложения. Отличительная особенность этого класса методов – глобальное преобразование, применяемое для всех отсчётов гиперспектрального изображения;

 – локальные алгоритмы, отличительной особенностью которых является использование отсчётов локальной окрестности для оценки «фона»;

 – алгоритмы, использующие предварительную сегментацию и позволяющие осуществить предварительное разделение изображения на «фоновые» области. Внутри последних и производится обнаружение аномалий.

Указанные выше подходы используются в конкретных алгоритмах и отдельно, и совместно. При этом сами алгоритмы на заключительном этапе могут и использовать алгоритм RXD, и не использовать. Этот факт, а также постоянное появление новых алгоритмов, которые не попадают в обозначенную классификационную схему (например, алгоритмы на основе графов [12] или «топологические» алгоритмы [15]), говорит в целом о достаточной условности такой классификации.

Предлагаемые в настоящей работе новые алгоритмы отличаются своими подходами к определению величины «аномальности», базируясь на различных математических моделях изображения и/или используя различные аспекты этого понятия. Так, первый из алгоритмов – алгоритм пространственно-спектрального рассогласования – предполагает, что изображение описывается моделью стационарного случайного поля и использует в качестве величины «аномальности» некоторой области величину пространственноспектрального рассогласования его с окрестностью.

Второй алгоритм – алгоритм адаптивного спектрального рассогласования – под величиной «аномальности» понимает величину, пропорциональную величине ошибки, возникающей при представлении отсчётов анализируемого фрагмента через отсчёты его окрестности. Данный алгоритм разрабатывается в двух вариантах – без использования и с использованием нормирования гиперспектральных отсчётов.

Учитывая то, что величина «аномальности» в обоих алгоритмах определяется как величина спектрального рассогласования, ниже они объединены в одну группу – группу *алгоритмов спектрального рассогласования*. Следуя данной выше классификации, оба эти алгоритма можно отнести к группе локальных алгоритмов.

Третий, заключительный, алгоритм - вероятностный алгоритм обнаружения аномалий - использует квантование сигнатур изображения и вычисление хеш-значений квантованных векторов для построения гистограммы частот появления гиперспектральных отсчётов. Вероятность сигнатуры квантованного изображения определяет величину «аномальности» точки изображения: наименее вероятные точки рассматриваются в качестве аномалий. Таким образом, в последнем алгоритме к аномалиям относятся уникальные спектральные сигнатуры на изображении, что наиболее точно соответствует данному в начале работы классическому понятию «аномалии». Возвращаясь к данной выше классификации, следует отметить, что, хотя этот алгоритм является глобальным, он в общем случае не требует перехода к сокращённому описанию. Данный факт позволяет говорить о новом решении, не попадающем в принятую классификацию большинства существующих алгоритмов.

Все разрабатываемые в работе алгоритмы сравниваются с широко используемым RXD-алгоритмом (с глобальной и локальной версией), показано преимущество предложенных алгоритмов на ряде примеров обнаружения аномалий.

Алгоритмы спектрального рассогласования

Алгоритмы спектрального рассогласования используют общую схему расчёта величины «аномальности», с вычислениями в «скользящем окне» [16]. Для этого выбираются два окна обработки, первое из которых - «внутреннее» - интерпретируется как область потенциальной аномалии, а второе - «внешнее» - как окрестность этой потенциальной аномалии (отсчёты «внутреннего» окна не попадают во множество отсчётов «внешнего»). Указанная пара окон занимает последовательно все возможные положения в плоскости изображения (например, в режиме построчно-постолбцовой развёртки), и для каждого их расположения (n_1, n_2) , соответствующего текущему положению их центрального отсчёта, рассчитывается величина «аномальности». Величина «аномальности» для области (внутреннего окна) может быть получена путём агрегации значений «аномальности» окна. Заметим, что указанная агрегация может быть выполнена различными способами (сумма попиксельных значений, их минимум, их максимум, их медиана и т.п.).

Для удобства введём следующие обозначения отсчётов «внутреннего» и «внешнего» окна (см. рис. 1):

 $-I(n_1,n_2)$ — множество индексов отсчётов «внутреннего» (малого) окна (области потенциальной аномалии), способ введения упорядочивания отсчётов не имеет значения;

 $-J(n_1,n_2)$ — множество индексов отсчётов «внешнего» (большого) окна (окрестность области потенциальной аномалии), способ введения упорядочивания отсчётов не имеет значения.

Обозначим также \overline{v}_i , $i \in I(n_1, n_2)$ – значения гиперспектральных отсчётов из множества $I(n_1, n_2)$, а \overline{v}_j , $j \in J(n_1, n_2)$ – гиперспектральных отсчётов из множества $J(n_1, n_2)$.



Рис.1. Иллюстрация к определению множеств отсчётов внутри окна обработки

Величину спектрального рассогласования $\varepsilon^2(n_1,n_2)$ гиперспектрального изображения в позиции (n_1,n_2) можно определить как ошибку представления гиперспектральных отсчётов из множества $I(n_1,n_2)$ через отсчёты множества $J(n_1,n_2)$:

$$\varepsilon_i^2(n_1, n_2) = \left\| \overline{v}_i - \sum_{j \in J(n_1, n_2)} \alpha_{ij}(n_1, n_2) \overline{v}_j \right\|^2, \qquad (1)$$

где $\|...\|$ – некоторая норма (в работе используется L_2), а $\alpha_{ij}(n_1,n_2)$ – неизвестные коэффициенты представления. В зависимости от способа определения/задания этих коэффициентов можно рассмотреть две ситуации, приводящие к двум принципиально различным алгоритмам.

В первой ситуации коэффициенты полагаются постоянными на всём изображении (но неизвестными и зависящими от изображения), то есть считаем, что выполняется условие:

$$\alpha_{ij}(n_1, n_2) \equiv \alpha_{ij}, i \in I(n_1, n_2), j \in J(n_1, n_2)$$

Такое определение коэффициентов соответствует рассмотрению изображения как случайного стационарного поля, для которого наибольшие ошибки (1) возникают в местах существенного нарушения «стационарности».

Во второй ситуации выражение (1) используется напрямую. В этом случае речь идёт о возможности представления конкретного отсчёта «внутреннего» окна через отсчёты окна «внешнего»: в тех случаях, когда такое представление сделать с малой величиной рассогласования не удаётся, соответствующий отсчёт (или область) интерпретируется как аномалия.

Ниже рассмотрены оба алгоритма и указаны способы расчёта указанных коэффициентов.

<u>Алгоритм пространственно-спектрального</u> <u>рассогласования</u>

Для алгоритма пространственно-спектрального рассогласования коэффициенты $\alpha_{ij}(n_1,n_2)$ рассматриваются как постоянные для изображения величины α_{ij} . Определение этих коэффициентов производится из условия минимума суммарного среднеквадратического отклонения:

$$\varepsilon^2 = \sum_{(n_1,n_2)} \varepsilon^2 \left(n_1, n_2 \right),$$

где

$$\varepsilon^{2}(n_{1},n_{2}) = \frac{1}{2} \sum_{i \in I(n_{1},n_{2})} \varepsilon_{i}^{2}(n_{1},n_{2}) =$$

$$= \frac{1}{2} \sum_{i \in I(n_{1},n_{2})} \left(\overline{v}_{i} - \sum_{j \in J(n_{1},n_{2})} \alpha_{ij} \overline{v}_{j}\right)^{2}.$$
(2)

Коэффициенты могут быть получены из следующей системы линейных алгебраических уравнений:

$$\sum_{(n_1,n_2)} \overline{v}_t^T(n_1,n_2) \overline{v}_k(n_1,n_2) =$$

=
$$\sum_{j=0}^{J-1} \alpha_{kj} \sum_{(n_1,n_2)} \overline{v}_t^T(n_1,n_2) \overline{v}_j(n_1,n_2),$$

где $\overline{v}_k(n_1,n_2) \in I(n_1,n_2)$ и k=0..I-1, $\overline{v}_t(n_1,n_2) \in J(n_1,n_2)$ и t=0..J-1.

При рассчитанных коэффициентах α_{ij} величину «аномальности» для области, как было указано выше, можно определить следующим способом:

$$\varepsilon^{2}(n_{1}, n_{2}) = \underset{i \in I(n_{1}, n_{2})}{\operatorname{Aggregate}} \left(\overline{v}_{i} - \sum_{j \in J(n_{1}, n_{2})} \alpha_{ij} \overline{v}_{j}\right)^{2}$$

где в качестве функции Aggregate могут выступать любые отображения вида Aggregate : $\mathbf{R}^{|l|} \to \mathbf{R}$. Примерами таких функций являются: полусумма значений, приводящая к величине рассогласования (2), минимум, максимум, медиана и др.

<u>Алгоритм адаптивного</u> спектрального рассогласования

Для алгоритма адаптивного спектрального рассогласования коэффициенты $\alpha_{ij}(n_1,n_2)$ полагаются различными для каждого возможного положения окон (n_1,n_2) . Способ нахождения этих коэффициентов заключается в использовании ортогонального проецирования конкретного вектора $\overline{v_i}$ внутреннего окна на линейную оболочку (линейное замыкание) векторов внешнего окна [17] и получении его проекции $\hat{v_i}$. В результате ошибка (1) будет иметь вид:

$$\varepsilon_{i}^{2}\left(n_{1},n_{2}\right) = \left\|\overline{v}_{i}\right\|^{2} - \left\|\widehat{v}_{i}\left(n_{1},n_{2}\right)\right\|^{2}, \quad i \in I\left(n_{1},n_{2}\right), \quad (3)$$

где $\hat{\overline{v}}_i(n_1, n_2) = P_{\perp}^{(n_1, n_2)} \overline{v}_i$ – проекция вектора-отсчёта \overline{v}_i из области $I(n_1, n_2)$ на множество векторов области $\{\overline{v}_j\}_{j \in J(n_1, n_2)}$.

Оператор проектирования (проектор) $P_{\perp}^{(n_1,n_2)}$ получается из условия наименьшей среднеквадратичной ошибки представления вектора-отсчёта \overline{v}_i отсчётами из $J(n_1,n_2)$ [17]:

$$P_{\perp}^{(n_1,n_2)} = V(V^T V)^{-1} V^T,$$

где $V = \left[\overline{v_0} \ \overline{v_1} ... \overline{v_j} ... \overline{v_{J-1}}\right]$ – матрица, состоящая из векторов «внешней» области $\overline{v_j} \in J(n_1, n_2)$ (для упрощения формальной записи последующих выражений факт зависимости этой матрицы от положения окна

обработки (n_1,n_2) в обозначении матрицы опускаем). Причём $\overline{\alpha} = (V^T V)^{-1} V^T$. Поскольку отсчёты $J(n_1,n_2)$ могут быть линейно зависимы между собой, при вычислении проектора можно использовать либо предварительный отбор подмножества линейно независимых векторов, либо регуляризацию. Регуляризованный проектор, использованный в работе, имеет вид:

$$\hat{P}_{\perp}^{(n_1,n_2)} = V \left(V^T V + \beta I \right)^{-1} V^T$$

где $\beta > 0$ – параметр регуляризации, *I* – единичная матрица.

Полная величина спектрального рассогласования для заданного отсчёта задаётся выражением:

$$\varepsilon^{2}(n_{1},n_{2}) = Aggregate\left(\varepsilon_{i}^{2}(n_{1},n_{2})\right),$$
$$\underset{i \in I(n_{1},n_{2})}{i \in I(n_{1},n_{2})}$$

где в качестве функции Aggregate могут, как и выше, выступать различные отображения.

Дополнительная модификация алгоритма адаптивного спектрального рассогласования заключается в предварительной нормировке всех гиперспектральных отсчётов изображения так, чтобы выполнялось условие

$$\left\|\overline{v_{i}}\left(n_{1},n_{2}\right)\right\|=1$$

В этом случае величина ошибки (3) может быть представлена в виде

$$\varepsilon_{i}^{2}(n_{1},n_{2}) = 1 - \cos^{2}\left(\overline{v_{i}},\hat{v}_{i}(n_{1},n_{2})\right) =$$

$$= \sin^{2}\left(\overline{v_{i}},\hat{v}_{i}(n_{1},n_{2})\right), \quad i \in I(n_{1},n_{2}),$$
(4)

где синус (или косинус) вычисляется для угла, образованного исходным вектором и его проекцией на подпространство, формируемое векторами «внешнего» окна (их линейного замыкания). Очевидно, данная величина однозначно (и монотонно) зависит от указанного угла.

Вероятностный алгоритм обнаружения аномалий

Пусть $\overline{v}(n_1, n_2)$ – отсчёт-вектор гиперспектрального изображения, содержащий информацию о спектральной сигнатуре соответствующего отсчёта изображения. Заметим, что в качестве компонент \overline{v} могут выступать как исходные значения гиперспектрального вектора, так и коэффициенты разложения такого гиперспектрального вектора по предварительно найденным спектральным сигнатурам, а также собственно ошибка такого представления. Пусть далее число компонент вектора – n.

Введём величину K – число уровней квантования каждого компонента вектора \overline{v} . Тогда каждый вектор \overline{v} на изображении даёт квантованный вектор

$$\overline{q} = (q_0 \quad q_1 \quad \dots \quad q_{n-1})^T$$
, где $q_j \in \{0, \dots, K-1\}$.

Тогда в общем случае таблица возможных квантованных значений вектора \overline{q} имеет размер K^n . Набор вероятностей $P(\overline{q})$ для каждой возможной ячейки со значениями $(q_0 \ q_1 \ \dots \ q_{n-1})^T$ образует вероятностное распределение функции яркости гиперспектрального изображения. Поскольку K^n может быть очень большим (число каналов обычных гиперспектральных изображений исчисляется сотнями), то при большом числе анализируемых каналов из-за ограниченности размеров таблицы предлагается использовать хеширование [18], т.е. расчёт для каждого значения $(q_0 q_1 \dots q_{n-1})^T$ некоторого целочисленного представления. Тогда вероятностное распределение (или, на практике, гистограмма, эмпирическое распределение) считается для хеш-значения отсчётов гиперспектрального изображения. В настоящей работе в качестве функции хеширования используется следующая:

$$f\left(\overline{q}\right) = \sum_{i=0}^{n-1} q_i K^i \mod N$$

где N – некоторое большое число, определяемое исходя из доступных размеров хеш-таблицы, mod – операция деления по модулю. Хеширование позволяет организовать простой механизм адресации уникальных значений квантованного отсчёта при расчёте гистограммы.

Пусть $I(n_1,n_2)$ – множество отсчётов внутри окна обработки, $\{\overline{q}_i\}_{i \in I(n_1,n_2)}$ – множество их квантованных представлений. Результатом для конкретного положения окна является величина:

$$P(n_1, n_2) = 1 - \min_{i \in I(n_1, n_2)} P(\overline{q}_i).$$
⁽⁵⁾

В выражении (5), аналогично предшествующим двум алгоритмам, помимо минимума могут быть использованы другие агрегирующие функции: максимум вероятности в окне, медиана и др.

Экспериментальное исследование алгоритмов спектрального рассогласования

Для исследований алгоритмов спектрального рассогласования использовались синтезированные тестовые гиперспектральные изображения размером 256×256 со 100 каналами, которым соответствовали длины волн от 0,8 до 2,5 мкм с шагом 0,017. Изображения формировались как линейная комбинация четырёх «фоновых» сигнатур (ACTINOLITE AM3000, ILLITE IL101, SEPIOLITE SEP3101, BUDDINGTONITE NHB2301) «аномальных» (HEMATITE_FE2602, И двух SIDERITE_COS2002), взятых из библиотеки IGCP-264 Library - CSES Beckman Spectrometer [10]. Коэффициенты смешивания сигнатур и фона и аномалии задавались как стационарные случайные поля с биэкспоненциальными корреляционными функциями. Исследование производилось для трёх синтезированных изображений (PIC-1, PIC-2 и PIC-3) с коэффициентами корреляции р соответственно 0,999, 0,98 и 0,45. Сумма коэффициентов сигнатур в каждом отсчёте была равна единице, коэффициенты неотрицательны [2-4]. Набор аномалий, встроенных в изображение, включал в себя площадки размерами 7×7, 5×5 и 3×3. Примеры тестовых изображений с внедрёнными аномалиями приведены на рис. 2.

Первые два изображения использовались для сравнения результатов работы с известными модификациями RXD-алгоритма (глобальная и локальная, снижение размерности не производилось). Первое изображение соответствовало простой ситуации с практически неизменным фоновым полем (аналог одной сигнатуры), в то время как второе – с изменяемым (сложным) фоном.





Для сравнения алгоритмов был проведён следующий эксперимент. В каждый канал тестового изображения добавлялся некоррелированный аддитивный шум с нормальным законом распределения и нулевым средним. Зашумлённые изображения обрабатывались независимо RXD-алгоритмом (двумя указанными выше модификациями) и предложенным алгоритмом пространственно-спектрального рассогласования с параметрами окон 3×3 и 5×5. Результат обработки представлен на рис. 3 и 4 для отношений сигнал/шум 1000, 100 и 10 соответственно.

	100 P 152 00 -	8 8 8
	н •	0 ° ·
а) отн	ошение сигнал/шум	ı 1000
		88:
		0
	x e .	0 • ·
:: = *	ж	o • •
б) от	юшение сигнал/шул	и 100
50 6 4	8 f (88:
¢ •	a * *	0 • •
s‡ ∉ ◆	H . F	
₽ ₽	н	

в) отношение сигнал/шум 10

Рис. 3. Результаты для тестового изображения PIC-1 с различным отношением сигнал/шум. Слева направо: метод спектрального рассогласования; RXD-алгоритм (глобальный);RXD-алгоритм (локальный, окно 5×5)

Более тёмные отсчёты соответствуют большим значениям величины рассогласования и, как следствие, «аномальности».

Чтобы избежать неустойчивости в работе RXDалгоритма с изображением PIC-1, выполнялось преобразование исходного изображения методом главных компонент перед его применением. На рис. 3 представлены результаты RXD-алгоритма и его модификации для первых двух главных компонент изображения PIC-1. Метод спектрального рассогласования применения метода главных компонент не требует. Из представленных на рис. 4 результатов видно, что метод пространственно-спектрального рассогласования обладает высокой помехоустойчивостью и обнаруживает аномалии существенно лучше, чем любая из модификаций RXD-алгоритма в случае со сложным фоном (изображение PIC-2).



в) отношение сигнал/шум 10 Рис. 4. Результаты для тестового изображения PIC-2 с различным отношением сигнал/шум. Слева направо: метод спектрального рассогласования; RXD-алгоритм (глобальный); RXD-алгоритм (локальный, окно 5×5)

Влияние на результат выбора размеров «внутреннего» и «внешнего» окна хорошо видно в эксперименте с изображением РІС-3. На рис. 5 показан результат обработки методом пространственноспектрального рассогласования в случае с размерами 3×3 и 5×5 , 5×5 и 7×7 , 7×7 и 9×9 соответственно. Как видно, аномалии большего размера лучше обнаруживаются с большим размером окна.



Рис.5. Результаты обработки изображения PIC-3 алгоритмом пространственно-спектрального рассогласования с параметрами размеров внутренней и внешней областей соответственно: а) 3×3 и 5×5; б) 5×5 и 7×7, в) 7×7 и 9×9

Пример работы алгоритма адаптивного спектрального рассогласования для изображения PIC-1 с соотношением сигнал/шум 100 в каждом канале представлен на рис. 6. В качестве параметра регуляризации использовалось значение $0,01\lambda_{\max}$, где λ_{\max} – максимальное собственное значение матрицы $V_{(n_1,n_2)}^T V_{(n_1,n_2)}$.

Как видно, алгоритм адаптивного спектрального рассогласования также даёт результаты существенно лучше RXD-алгоритма, при этом (в отличие от алго-

ритма пространственно-спектрального рассогласования) он не предполагает использования никакой модели изображения. К его недостаткам по сравнению с алгоритмом пространственно-спектрального рассогласования можно отнести: неустойчивость (в общем случае) оператора проектирования, необходимость его регуляризации и большие вычислительные затраты. Это накладывает определённые сложности на практическое применение этого алгоритма.



Рис. 6. Результат работы адаптивного метода обнаружения аномалий

На рис. 8 приведён пример применения алгоритмов спектрального согласования и модификаций RXDалгоритмов к реальному гиперспектральному изображению Moffett Field гиперспектрометра AVIRIS, представленному на рис. 7.

Для алгоритмов спектрального рассогласования размеры внутреннего окна составляли 3×3 отсчёта, размеры внешнего окна – 5×5 отсчётов. Локальный алгоритм RXD использовался с окном размером 5×5. Из очевидных недостатков алгоритмов RXD следует отметить их значительно меньшую помехоустойчивость, особенно локальной версии алгоритма. Результаты алгоритма пространственно-спектрального рассогласования выглядят визуально предпочтительнее, однако здесь следует отметить значительную сложность в интерпретации и оценке полученного результата.

Экспериментальное исследование алгоритма вероятностного обнаружения аномалий

При использовании алгоритма вероятностного обнаружения аномалий для обработки гиперспектральных изображений предпочтительно использовать в качестве входных данных изображения, полученные в результате одного из преобразований понижения размерности. Например, могжет быть использован метод главных компонент или метод независимых компонент [20], часто применяемые для работы с гиперспектральными изображениями. Понижение размерности часто необходимо, поскольку в противном случае число возможных значений квантованного вектора оказывается слишком велико и практически все значения отсчётов оказываются уникальными. Число компонент представления оказывается в этом алгоритме дополнительным независимым параметром, который также следует подбирать для каждой конкретной задачи.

Для исследования алгоритма вероятностного обнаружения аномалий использовались:





- изображения коэффициентов, полученные методом главных компонент [20], для обработки гиперспектральных изображений,

- мультиспектральные изображения, изначально содержащие небольшое число спектральных компонент.

На рис. 9 и 10 приведены соответственно тестовый фрагмент трёхканального снимка UK DMC и результат работы алгоритма при K = 4. Количество уровней квантования выбиралось небольшим, рекомендуемые значения – три или четыре уровня. Для сравнения на рис. 11 и рис. 12 приведены результаты работы RXD-алгоритма (глобального и локального соответственно). На основе визуальной оценки полученных изображений результаты предложенного алгоритма выглядят предпочтительнее.



Рис.8. Результаты применения алгоритмов обнаружения аномалий к изображению Moffett Field гиперспектрометра AVIRIS: а) алгоритм пространственно-спектрального рассогласования; б) адаптивный алгоритм спектрального рассогласования; в) RXD-алгоритм (глобальный); г) RXD-алгоритм (локальный, окно 5×5)

Другой пример обработки реального – гиперспектрального – изображения представлен на рис. 13.

На рис. 14 представлен пример с синтезированным гиперспектральным изображением, демонстрирующий очевидное преимущество предложенного алгоритма. На синтезированном изображении размером 512×512 с 340 каналами были синтезированы две области, сигнатуры областей значительно отличались друг от друга.



К областям в каждом канале добавляется аддитивный шум с нулевым средним и отношением сигнал/шум 1000. Для задания «аномалии» выбиралась новая сигнатура, которая была «близка» (в спектральном пространстве) к полусумме сигнатур исходных областей. Эта сигнатура использовалась для задания отсчётов «границы» между областями, формируя область «аномальности» для данного изображения. Результаты обнаружения такой области различными алгоритмами приведены на рис. 14*6-г*: большим значениям «аномальности» соответствуют более тёмные отсчёты изображения-результата.

Из этих результатов очевидна абсолютно корректная (ожидаемая) работа алгоритма вероятностного обнаружения аномалий, полностью некорректная работа глобального RXD-алгоритма (в качестве аномалии указана область изображения, расположенная в верхней правой части изображения и занимающая практически половину изображения) и близкая к неудовлетворительной работа локального RXD-алгоритма.

Выводы

В статье предложен ряд новых алгоритмов обнаружения аномалий на гиперспектральных изображениях: алгоритмы спектрального рассогласования (пространственно-спектральный и адаптивный спектральный с модификацией) и алгоритм вероятностного обнаружения аномалий.



Puc.13. Результаты применения алгоритмов обнаружения аномалий к изображению Moffett Field гиперспектрометра AVIRIS: а) алгоритм вероятностного обнаружения аномалий; б) RXD-алгоритм (глобальный)



Рис.14. а) Входное изображение, б) RXD-алгоритм (глобальный), в) RXD-алгоритм (локальный), г) алгоритм вероятностного обнаружения аномалий с числом уровней квантования K=4

Алгоритмы используют различные способы определения факта «аномальности», базируясь на различных математических моделях изображения и/или используя различные аспекты понятия «аномальности». Выполняется сравнение предложенных алгоритмов с широко используемыми вариантами RXD-алгоритма (глобальным и локальным), показано убедительное превосходство предложенных решений по сравнению с указанными существующими. Проведён сравнительный анализ достоинств и недостатков предложенных алгоритмов. В частности, показано, что алгоритм пространственно-спектрального рассогласования устойчив к шуму и позволяет уверенно обнаружить аномалии на изображениях, удовлетворяющих модели стационарного случайного поля, даже при сильных искажениях. Алгоритм адаптивного спектрального рассогласования такой модели не использует, но является более вычислительно затратным и требует подбора параметра регуляризации. Оба алгоритма спектрального рассогласования на рассмотренных примерах оказались эффективнее, чем известный RXD-алгоритм.

Алгоритм вероятностного обнаружения аномалий использует принципиально новый метод поиска аномалий, заключающийся в «снижении» избыточности гиперспектрального представления отсчёта путём переквантования его спектральных коэффициентов. Указанная операция, которая может применяться и к исходному представлению гиперспектрального изображения, и к его представлению с сокращённой размерностью (например, с использованием главных компонент), позволяет дальнейший поиск «аномальных» отсчётов свести к простейшему анализу одномерной гистограммы, построенной для значений хэш-функции квантованного гиперспектрального отсчёта анализируемого изображения. Данный факт позволяет говорить о принципиально новом решении, не попадающем в принятую классификацию большинства существующих алгоритмов обнаружения аномалий. Сравнение результатов работы этого алгоритма с известными также показало его эффективность и значительное преимущество на одной из типовых для гиперспектральных изображений задач.

Благодарности

Работа выполнена при частичной финансовой поддержке:

- грантов РФФИ, проекты № 13-07-12103-офи-м, 13-01-12080-офи-м, 12-07-00021-а, и 13-07-97006-р_поволжье а;

- программы фундаментальных исследований Президиума РАН «Фундаментальные проблемы информатики и информационных технологий», проект 2.12;

- Министерства образования и науки Российской Федерации (в рамках постановления Правительства Российской Федерации от 09.04.2010 г. № 218: договор № 02.ГЗ6.31.0001 от 12.02.2013).

Литература

- Chandola, V. Anomaly detection: A survey / V. Chandola, A. Banerjee, V. Kumar // ACM Computing Surveys (CSUR). – 2009. – V. 41(3). – 72 p.
- Chang, C.I. Anomaly detection and classification for hyperspectral imagery / C.I. Chang, C. Shao-Shan // IEEE Transactions on Geoscience and Remote Sensing. – 2002. – V. 40(6). – P. 1314-1325.
- 3. **Chang, C.I.** Hyperspectral Data Processing: Algorithm Design and Analysis. John Wiley & Sons, 2013. 1164 p.
- 4. **Chang, C.I.** Hyperspectral data exploitation: theory and applications. Wiley-Interscience, 2007. 456 p.
- 5. **Reed, I.S.** Adaptive multiple-band CFAR detection of an optical pattern with unknown spectral distribution / I.S. Reed,

X. Yu // IEEE Transactions on Acoustics, Speech, and Signal Processing. – V. 38(10). – 1990. – P. 1760-1770.

- Matteoli, S. A tutorial overview of anomaly detection in hyperspectral images / S. Matteoli, M. Diani, G. Corsini // Aerospace and Electronic Systems Magazine, IEEE. – 2010. – V. 25(7). – P. 5-28.
- Borghys, D. Hyperspectral anomaly detection: A comparative evaluation of methods / D. Borghys, V. Achard, S.R. Rotman, N. Gorelik, C. Perneel, E. Schweicher // General Assembly and Scientific Symposium, 2011 XXXth URSI. – IEEE, 2011. – P. 1-4.
- Borghys, D. Hyperspectral Anomaly Detection: Comparative Evaluation in Scenes with Diverse Complexity / D. Borghys, I. Kasen, V. Achard, C. Pernee // Journal of Electrical and Computer Engineering. – 2012. – V. 2012. – 16 p. – Article ID 162106.
- Bachega, L.R. Evaluating and improving local hyperspectral anomaly detectors / L.R. Bachega, J. Theiler, C.A. Bouman // Applied Imagery Pattern Recognition Workshop (AIPR), 2011 IEEE. IEEE, 2011. P. 1-8.
- Soofbaf, S.R. Anomaly detection algorithms for hyperspectral imager / S.R. Soofbaf, H. Fahimnejad, M.J. Valadan Zoej, B. Mojaradi // Proceedings, Remote Sensing and Image Processing, Presented at the Map of the World Forum. 2007. P. 1-8.
- Schaum, A.P. Hyperspectral anomaly detection beyond RX // Proceedings of the SPIE Algorithms and Technologies for Multispectral, Hyperspectral and Ultraspectral Imagery XII. – 2007. – V. 6565.
- Messinger, D.W. A graph theoretic approach to anomaly detection in hyperspectral imagery/ D.W. Messinger, J. Albano // Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS), 2011 3rd Workshop on. – IEEE, 2011. – P. 1-4.
- Banerjee, A. A support vector method for anomaly detection in hyperspectral imagery / A. Banerjee, P. Burlina, C. Diehl // Geoscience and Remote Sensing, IEEE Transactions on. – 2006. – V. 44(8). – P. 2282-2291.
- 14. Gu, Y. A selective KPCA algorithm based on high-order statistics for anomaly detection in hyperspectral imagery / Y. Gu, Y. Liu, Y. Zhang // Geoscience and Remote Sensing Letters. –2008. – V. 5(1). – P. 43-47.
- Basener, D. Anomaly detection using topology / B. Basener, E. Ientilucci, D.W. Messinger // Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XIII, SPIE, 2007. – V. 6565.
- 16. Методы компьютерной обработки изображений / М.В. Гашников, Н.И. Глумов, Н.Ю. Ильясова, В.В. Мясников, С.Б. Попов, В.В. Сергеев, В.А. Сойфер, А.Г. Храмов, А.В. Чернов, В.М. Чернов, М.А. Чичева, В.А. Фурсов. – Под ред. В.А. Сойфера. – 2-е изд., испр. – М.: Физматлит, 2003. – 784 с.
- Кострикин, А.И. Линейная алгебра и геометрия. / А.И. Кострикин, Ю.И. Манин. – Изд. 4-е, стер. – Сер.: Классическая учебная литература по математике. – СПб., 2008.
- Биркгоф, Г. Современная прикладная алгебра / Г. Биркгоф, Т. Барти. – М.: Мир, 1976. – 400 с.
- Clark, R.N. The U. S. Geological Survey, Digital Spectral Library: Version 1: 0.2 to 3.0 microns, U.S. Geological Survey Open File Report 93-592 / R.N. Clark, G.A. Swayze, A.J. Gallagher, T.V.V. King, W.M. Calvin. 1993. 1340 p.
- Rodarmel, C. Principal component analysis for hyperspectral image classification / C. Rodarmel, J. Shan // Surveying and Land Information Science. – 2002. – V. 62(2). – P. 115-122.

References

 Chandola, V. Anomaly detection: A survey / V. Chandola, A. Banerjee, V. Kumar // ACM Computing Surveys (CSUR). – 2009. – V. 41(3). – 72 p.

- Chang, C.I. Anomaly detection and classification for hyperspectral imagery / C.I. Chang, C.S hao-Shan // IEEE Transactions on Geoscience and Remote Sensing. – 2002. – V. 40(6). – P. 1314-1325.
- Chang, C.I. Hyperspectral Data Processing: Algorithm Design and Analysis / C.I. Chang. John Wiley & Sons, 2013. – 1164 p.
- Chang, C.I. Hyperspectral data exploitation: theory and applications / C.I. Chang. Wiley-Interscience, 2007. 456 p.
- Reed, I.S. Adaptive multiple-band CFAR detection of an optical pattern with unknown spectral distribution / I.S. Reed, X. Yu // IEEE Transactions on Acoustics, Speech, and Signal Processing. V. 38(10). 1990. P. 1760-1770.
- Matteoli, S. A tutorial overview of anomaly detection in hyperspectral images/ S. Matteoli, M. Diani, G. Corsini // Aerospace and Electronic Systems Magazine, IEEE. – 2010. – V. 25(7). – P. 5-28.
- Borghys, D. Hyperspectral anomaly detection: A comparative evaluation of methods / D. Borghys, V. Achard, S.R. Rotman, N. Gorelik, C. Perneel, E. Schweicher // General Assembly and Scientific Symposium, 2011 XXXth URSI. – 2011. – P. 1-4.
- Borghys, D. Hyperspectral Anomaly Detection: Comparative Evaluation in Scenes with Diverse Complexity / D. Borghys, I. Kasen, V. Achard, C. Pernee // Journal of Electrical and Computer Engineering. – 2012. – V. 2012. – 16 p. – Article ID 162106.
- Bachega, L.R., Evaluating and improving local hyperspectral anomaly detectors / L.R. Bachega, J. Theiler, C.A. Bouman // Applied Imagery Pattern Recognition Workshop (AIPR), 2011 IEEE. – 2011. – P. 1-8.
- Soofbaf, S.R. Anomaly detection algorithms for hyperspectral imagery / S.R. Soofbaf, H. Fahimnejad, M.J. Valadan Zoej, B. Mojaradi // Proceedings, Remote Sensing and Image Processing, Presented at the Map of the World Forum. 2007. P. 1-8.
- 11. Schaum, A.P. Hyperspectral anomaly detection beyond RX / A.P. Schaum // Proceedings of the SPIE Algorithms and

Technologies for Multispectral, Hyperspectral and Ultraspectral Imagery XII. – 2007. – V. 6565.

- Messinger, D.W. A graph theoretic approach to anomaly detection in hyperspectral imagery / D.W. Messinger, J. Albano // Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS), 2011 3rd Workshop on. – 2011. – P. 1-4.
- Banerjee, A. A support vector method for anomaly detection in hyperspectral imagery / A. Banerjee, P. Burlina, C. Diehl // Geoscience and Remote Sensing, IEEE Transactions on. – 2006. – V. 44(8). – P. 2282-2291.
- 14. Gu, Y. A selective KPCA algorithm based on high-order statistics for anomaly detection in hyperspectral imagery / Y. Gu, Y. Liu, Y. Zhang // Geoscience and Remote Sensing Letters. – 2008. – V. 5(1). – P. 43-47.
- Basener, D. Anomaly detection using topology / B. Basener, E. Ientilucci, D.W. Messinger // Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XIII. 2007. V. 6565.
- Computer Image Processing, Part II: Methods and algorithms / A.V. Chernov, V.M. Chernov, M.A. Chicheva, V.A. Fursov, M.V. Gashnikov, N.I. Glumov, N.Yu. Ilyasova, A.G. Khramov, A.O. Korepanov, A.V. Kupriyanov, E.V. Myasnikov, V.V. Myasnikov, S.B. Popov, V.V. Sergeyev. – Ed. by V.A. Soifer. – VDM Verlag, 2009. – 584 p.
- Kostrikin, A.I. Linear algebra and geometry / A.I. Kostrikin, Yu.I. Manin. – 4th Edition. – Petersburg, 2008. – (In Russian).
- Birkhoff, G. Modern applied algebra / G. Birkhoff, T. Bartee. – Moscow: "Mir" Publisher, 1976. – 400 p. – (In Russian).
- Clark, R.N. The U. S. Geological Survey, Digital Spectral Library: Version 1: 0.2 to 3.0 microns, U.S. Geological Survey Open File Report 93-592 / R.N. Clark, G.A. Swayze, A.J. Gallagher, T.V.V. King, W.M. Calvin. – 1993. – 1340 p.
- Rodarmel, C. Principal component analysis for hyperspectral image classification / C. Rodarmel, J. Shan // Surveying and Land Information Science. – 2002. – V. 62(2). – P. 115-122.

ANOMALY DETECTION FOR HYPERSPECTRAL IMAGINARY

A.Yu. Denisova, V.V. Myasnikov Image Processing Systems Institute, Russian Academy of Sciences, Samara State Aerospace University

Abstract

In this paper authors offered several algorithms for anomaly detection on hyperspectral images. Algorithms used different ideas to describe anomalies. A comparison between offered in article algorithms and RXD-detector was provided. An advances of proposed solutions were overviewed. <u>Key words:</u> hyperspectral images, anomaly detection, spectral mismatch, RX anomaly detector.

Сведения об авторах



Денисова Анна Юрьевна, 1988 года рождения. В 2011 году защитила диплом магистра прикладной математики и информатики в Самарском государственном аэрокосмическом университете (СГАУ) (национальный исследовательский университет). В настоящее время работает стажёром-исследователем в Институте систем обработки изображений РАН в ЛММОИ и обучается в аспирантуре СГАУ. Круг научных интересов включает обработку изображений, геоинформационные системы.

E-mail: <u>denisova_ay@geosamara.ru</u>.

Anna Yurievna Denisova (b. 1988). Graduated from Samara State Aerospace University in 2011 as Master of Mathematics and Computer Science. Now works at the Image Processing Systems Institute of the RAS and studies at Samara State Aerospace University. The area of research interest includes image processing and geoinformational systems.



Мясников Владислав Валерьевич, 1971 года рождения. В 1994 году окончил Самарский государственный аэрокосмический университет (СГАУ). В 1995 году поступил в аспирантуру СГАУ, в 1998 году защитил диссертацию на соискание степени кандидата технических наук, а в 2008 – диссертацию на соискание степени доктора физикоматематических наук. В настоящее время работает ведущим научным сотрудником в Федеральном государственном бюджетном учреждении науки Институте систем обработки изображений РАН и одновременно профессором кафедры геоинформатики и информационной безопасности СГАУ. Круг научных интересов включает цифровую обработку сигналов и изображений, компьютерное зрение, распознавание образов, искусственный интеллект и геоинформатику. Имеет более 100 публикаций, в том числе 40

статей и две монографии (в соавторстве). Член Российской ассоциации распознавания образов и анализа изображений.

Страница в интернете: <u>http://www.ipsi.smr.ru/staff/MyasVV.htm</u>. E-mail: <u>vmyas@smr.ru</u>.

Vladislav Valerievich Myasnikov (1971 b.), graduated (1994) from S.P. Korolyov Samara State Aerospace University (SSAU). He received his PhD in Technical Sciences (2002) and DrSc degree in Physics & Maths (2008). At present he is a leading researcher at the Image Processing Systems Institute of the Russian Academy of Sciences and holds a part-time position of Associate Professor at Geoinformatics and Information Security department at SSAU. The area of interests includes digital signals and image processing, geoinformatics, neural networks, computer vision, pattern recognition and artificial intelligence. He's list of publications contains about 100 scientific papers, including 40 articles and 2 monographs. He is a member of Russian Association of Pattern Recognition and Image Analysis.

Поступила в редакцию 29 марта 2014 г.