

КЛАССИФИКАЦИЯ ОБЪЕКТОВ НА МНОГОСПЕКТРАЛЬНЫХ / ГИПЕРСПЕКТРАЛЬНЫХ АЭРОКОСМИЧЕСКИХ ИЗОБРАЖЕНИЯХ НА ОСНОВЕ ТЕОРИИ СВИДЕТЕЛЬСТВ ДЕМПСТЕРА-ШЕЙФЕРА

*Военно-дипломатическая академия, Киев, Украина

Анотація. Запропоновано алгоритм класифікації об'єктів на багатоспектральних / гіперспектральних аерокосмічних зображеннях на основі теорії свідчень Демпстера-Шейфера. Алгоритм дозволяє виявляти не тільки окремі класи, але й їх об'єднання, тобто враховує "змішані" пікселі, наявність яких притаманна зображенням середнього просторового розрізнення.

Ключові слова: класифікація об'єктів, багатоспектральне / гіперспектральне аерокосмічне зображення, теорія свідчень Демпстера-Шейфера.

Аннотация. Предложен алгоритм классификации объектов на многоспектральных / гиперспектральных аэрокосмических изображениях на основе теории свидетельств Демпстера-Шейфера. С помощью предложенного алгоритма можно обнаруживать не только отдельные классы, но и их объединения, то есть учитывать "смешанные" пиксели, наличие которых присуще изображениям среднего пространственного разрешения.

Ключевые слова: классификация объектов, многоспектральное / гиперспектральное аэрокосмическое изображение, теория свидетельств Демпстера-Шейфера.

Abstract. An algorithm for objects classification on multispectral / hyperspectral images based on the Dempster-Shafer theory of evidence is represented. The algorithm allows detecting not only separate classes but also their composition, i.e. takes into account the "mixed" pixels, which is inherent in the presence of medium spatial resolution images.

Keywords: objects classification, multispectral / hyperspectral aerospace images, the Dempster-Shafer theory of evidence.

1. Вступление

Последние несколько десятилетий все возрастающая часть природоресурсных, сельскохозяйственных, научных и других важных и актуальных для человечества задач решается с помощью материалов дистанционного аэрокосмического зондирования Земли. Базовой и наиболее сложной операцией при работе с такими материалами является их дешифрирование с целью последующей классификации объектов.

К настоящему времени разработано достаточно много различных методов для автоматизации дешифрирования аэрокосмических изображений, при этом они, в основном, базируются на использовании вероятностного подхода. В данной статье рассматривается подход к классификации объектов на многоспектральных / гиперспектральных аэрокосмических изображениях, в основе которого лежит теория свидетельств Демпстера-Шейфера (ТСДШ). Кратко приводятся положения ТСДШ, на которых базируется новый алгоритмический подход к решению поставленной задачи. Валидация разработанного алгоритма проведена с использованием реального космического гиперспектрального изображения.

2. Постановка задачи

Как известно, в основе классификации объектов на аэрокосмических изображениях лежит наличие разницы в их оптико-спектральных свойствах – спектральных сигнатурах [1]. Чем больше отличаются по этим свойствам объекты между собой, а также от подстилающей поверхности (фона), тем проще их обнаружение и точнее результат классификации. Однако подобная ситуация встречается на практике далеко не всегда. Очень часто природные и

искусственные объекты, которые принадлежат к разным классам, имеют близкие спектральные сигнатуры [2]. Чтобы различить между собой такие разноклассовые объекты, необходимо иметь детальную информацию об их спектральных сигнатурах, которую обеспечивает многоспектральная и, особенно, гиперспектральная съемка.

Любое многоспектральное или гиперспектральное изображение, которое получается при дистанционном аэрокосмическом зондировании, состоит из определенного количества зональных изображений, каждое из которых формируется оптическим излучением в достаточно ограниченном спектральном интервале [3]. Для многоспектральных изображений ширина такого интервала может составлять от нескольких десятков до нескольких сотен нанометров, для гиперспектральных изображений – от единиц до десятков нанометров.

Очевидно, что (при заданном рабочем спектральном диапазоне бортового оптического сенсора) чем “уже” интервал, в котором формируется зональное изображение, тем больше будет общее количество зональных изображений в составе многоспектрального / гиперспектрального изображения и тем более детальную информацию об объекте можно потенциально получить. Но здесь существуют две проблемы. Первая – “сужение” спектрального интервала уменьшает величину полезного сигнала от объекта, а это может существенно усложнить его обнаружение и классификацию. Вторая проблема – объекты разных классов могут на зональном изображении, в силу “узости” спектрального интервала, иметь близкий или даже одинаковый уровень полезного сигнала, который не даст возможности их отличить и классифицировать на этом изображении.

Последнюю проблему можно проиллюстрировать следующим примером. Допустим, что есть два зональных изображения одной сцены, которая содержит объекты трех классов: C_1 , C_2 и C_3 (рис. 1).

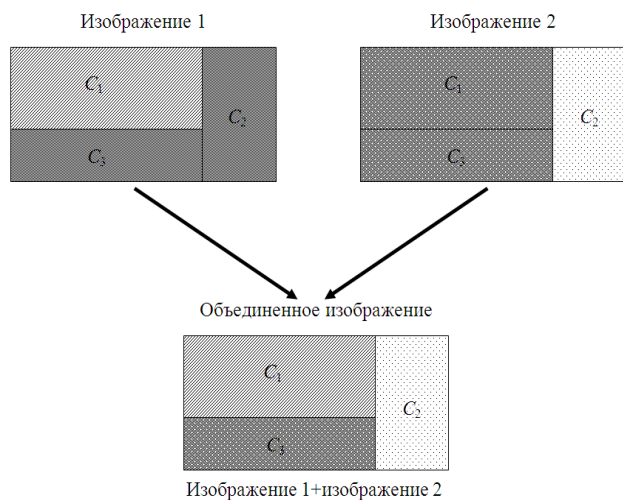


Рис. 1. Отображение разных классов на зональных изображениях

Первое зональное изображение позволяет отличить класс C_1 от C_2 и C_3 , но не C_2 от C_3 , а второе зональное изображение позволяет отличить класс C_2 от C_1 и C_3 , но не C_1 от C_3 . В результате объекты класса C_3 не будут обнаружены и классифицированы на них, хотя понятно, что вместе эти два зональных изображения содержат информацию, которая может помочь в решении задачи обнаружения и классификации объектов всех трех классов. Отметим, что о такой возможности впервые было упомянуто в работе [4].

Тогда задача может быть сформулирована таким образом: используя информацию, которая содержится в первичных зональных изображениях многоспектрального или гиперспектрального аэрокосмического изображения, сформировать вторичное (объединенное) изображение (рис. 1), которое позволит классифицировать все присутствующие на сцене объекты.

Целью данной статьи является разработка алгоритма классификации объектов на многоспектральных / гиперспектральных аэрокосмических изображениях, в основу которого положена теория свидетельств Демпстера-Шейфера.

3. Анализ возможных путей решения задачи

Каждое зональное изображение можно рассматривать как отдельный независимый источник данных о сцене и тогда поставленную выше задачу можно сформулировать как задачу разработки алгоритма классификации данных, который будет обеспечивать надежное получение информации обо всех классах объектов, присутствующих на сцене.

Теоретико-методические модели подобного алгоритма были предложены в [5, 6]. Модель Ли (Lee) [5] базируется на теории вероятности и использует байесовский подход. Преимуществом такого подхода является его вычислительная простота, однако классификация по Байесу нуждается в информации об априорных и условных вероятностях, что на практике встречается редко. Выход из подобного положения в байесовском подходе есть, и он заключается в том, что всем классам или событиям назначают одинаковую вероятность. Но при таком предположении нивелируется грань между случайностью и незнанием, то есть отсутствием информации.

Модель Бенедиктссона (Benediktsson) [6] базируется на теории свидетельств Демпстера-Шейфера (Dempster-Shafer), которая позволяет обрабатывать и классифицировать данные в условиях частичного незнания, а также обеспечивает простой механизм комбинирования данных с помощью так называемого комбинационного правила Демпстера. Определенным недостатком методов ТСДШ является их вычислительная сложность, но возможности современных компьютеров обычно позволяют преодолеть эту проблему. Поэтому, благодаря отмеченным преимуществам, методы обработки данных, основанные на ТСДШ, находят все большее распространение в задачах классификации данных, принятия решений, оценивания рисков и тому подобное. В нашем исследовании при разработке алгоритма классификации многоспектральных и гиперспектральных аэрокосмических изображений мы также будем опираться на ТСДШ. Поэтому сжато рассмотрим основные положения теории свидетельств.

4. Основные положения теории свидетельств Демпстера-Шейфера

Пусть существует некоторый объект, о котором известно, что он принадлежит к одному из K классов, но априори неизвестно, к какому именно. Такая ситуация может быть описана некоторым множеством базовых гипотез $\{A_k\}$, каждая из которых имеет свою меру истинности, то есть возможность (вероятность) отнесения объекта к соответствующему k -му классу, ($k = 1, 2, \dots, K$). Базовые гипотезы являются взаимоисключающими и взаимодополняющими, то есть реально лишь одна отдельная гипотеза оказывается верной.

В теории свидетельств допускается, что право на существование имеют не только базовые гипотезы, но могут рассматриваться и так называемые сложные гипотезы, которые не ограничивают возможную классовую принадлежность объекта лишь одним классом, но и не исключают, что объект может принадлежать к одному из нескольких избранных классов [7]. Сложные гипотезы могут формироваться путем разных логических операций с базовыми гипотезами, в частности, с помощью логических операций включения, пересечения и объединения гипотез.

Все гипотезы вместе образуют множество θ с кардинальным числом 2^N (учитывается пустое множество \emptyset и непосредственно само множество θ), которое в ТСДШ называют основой анализа (frame of discernment).

Подобно тому, как в теории вероятностей каждой гипотезе может быть присвоена своя вероятность, в ТСДШ каждому элементу множества θ присваивается соответствующая функция массы (mass function), область значений которой лежит в интервале от 0 до 1.

При отображении $m: 2^N \rightarrow [0, 1]$ действуют такие правила:

- функция массы пустого множества \emptyset равняется нулю: $m(\emptyset) = 0$;
- сумма масс для каждого подмножества $A \subseteq \Theta$ равняется единице: $\sum_{A \subseteq \Theta} m(A) = 1$.

На содержательном уровне функцию массы m можно рассматривать как меру доверия к связанной с ней гипотезе, поэтому $m(A)$ называют также базовой массой доверия (basic belief mass) гипотезы, а любую гипотезу, для которой $m(A) > 0$, – фокальным элементом (focal set). Способы определения функции массы m рассмотрены, в частности, в [8–10].

Используя понятие базовой массы доверия, в ТСДШ вводятся понятия доверия (Belief) и правдоподобия (Plausibility), которые для любой сложной гипотезы $X \subseteq \Theta$ определяются такими выражениями:

$$Bel(X) = \sum_{A_i | A_i \subseteq X} m(A_i), \quad (1)$$

$$Pls(X) = \sum_{A_i | A_i \cap X \neq \emptyset} m(A_i). \quad (2)$$

Функция доверия $Bel(X)$ определяет суммарный уровень уверенности, который приписывается гипотезе $X \subseteq \Theta$. Функция правдоподобия $Pls(X)$ определяет уровень расширения, до которого гипотеза X еще может считаться правдоподобной.

Для любой гипотезы X всегда имеет место $Bel(X) \leq Pls(X)$. Значения $Bel(X)$ и $Pls(X)$ определяют нижнюю и верхнюю границы интервала, в котором лежит точная оценка достоверности гипотезы X . Этот интервал $[Bel(X), Pls(X)]$ называют “интервалом доверия” для данной гипотезы [7], а его ширина определяет погрешность оценки.

Также имеет место соотношение

$$Pls(X) = 1 - Bel(\bar{X}),$$

где \bar{X} – гипотеза, противоположная X .

Графически соотношение между доверием (Belief) и правдоподобием (Plausibility) проиллюстрировано на рис. 2. Здесь через LB и UB обозначены соответственно нижняя и верхняя границы для величины доверия к гипотезе X . Ширина интервала $Pls(X) - Bel(\bar{X})$ отображает уровень неопределенности оценки достоверности гипотезы X : если уровень знаний относительно гипотезы растет, то граница LB смещается в сторону UB, и ширина этого интервала становится меньше.




Рис. 2. Соотношение между доверием и правдоподобием гипотезы X

Как было указано выше, одним из важных свойств ТСДШ есть наличие простой процедуры для объединения (комбинирования) информации от разных источников. Пусть, как и раньше, имеем основу анализа в виде множества θ с кардинальным числом 2^N , а также P источников. Каждый p -ый источник ($1 \leq p \leq P$) имеет соответствующую функцию массы m_p и генерирует собственную гипотезу (свидетельство) B_p .

Если имеется ряд гипотез (свидетельств) от источников с разными функциями массы m_p , то следующий шаг – их объединение с целью получения обобщенного свидетельства с новой, согласованной, функцией массы m_D . Такое объединение в ТСДШ осуществляется с помощью комбинационного правила Демпстера [11]:

$$m_D(X) = \frac{1}{1-K} \sum_{\substack{B_1 \cap \dots \cap B_P = X \\ \forall (X \neq \emptyset) \in 2^N}} \prod_{1 \leq p \leq P} m_p(B_p), \quad (3)$$

где K – коэффициент конфликтности,

$$K = \sum_{\substack{B_1 \cap \dots \cap B_P = \emptyset \\ \forall (X \neq \emptyset) \in 2^N}} \prod_{1 \leq p \leq P} m_p(B_p).$$

Область возможных значений коэффициента K лежит в интервале $[0;1]$, при этом нулевое значение коэффициента K говорит об отсутствии конфликта в гипотезах (свидетельствах) разных источников, а чем более источники противоречат друг другу, тем ближе к единице приближается величина K .

При вычислениях по правилу Демпстера (3) считается, что $m_D(\emptyset) = 0$. Более детальную информацию о ТСДШ и ее базовых положениях можно найти в монографии [7].

5. Алгоритмический подход на основе теории свидетельств Демпстера-Шейфера



Рис. 3. Снимок, полученный аппаратурой Нурегіон спутника EO-1. Изображение представлено в системе RGB (R=28 канал ($\lambda=635$ нм), G=19 канал ($\lambda=547$ нм), B=10 канал ($\lambda=458$ нм))

Рассмотрим, каким образом, имея зональные изображения из состава многоспектрального или гиперспектрального аэрокосмического изображения некоторой сцены и базируясь на ТСДШ, можно классифицировать все объекты, которые присутствуют в сцене. Для этого воспользуемся гиперспектральным снимком, который был получен аппаратурой Нурегіон спутника EO-1 (рис. 3). С целью упрощения объема вычислений ограничимся фрагментами двух зональных изображений из состава этого снимка, одно из которых сформировано в спектральном канале на длине волны $\lambda=419$ нм, а второе – на длине волны $\lambda=2371$ нм. Этот фрагмент очерчен на рис. 3 контурной красной линией, а также представлен в увеличенном виде.

Первым шагом алгоритма, который предлагается, является определение классов объектов на сцене, при этом отдельно рас-

смачивается и классифицируется каждый пиксель. Поскольку наши сведения о признаках объектов сцены являются очень ограниченными, то выбираем алгоритм неконтролируемой попиксельной классификации ISODATA. Суть данного алгоритма заключается в том, что сначала произвольно определяется W векторов в качестве разных стартовых точек. Далее выполняется кластеризация по правилу минимума евклидова расстояния от избранных центров [12]. После этого рассчитывается вектор средних значений μ_w для w -го класса и определяется сумма квадратов погрешности ϵ . Следующим этапом является проведение повторной классификации по правилу минимума евклидова расстояния от векторов средних значений μ_w . При этом может измениться количество кластеров и тогда, соответственно, изменяются значения μ_w и ϵ . Процедура продолжается до тех пор, пока величина суммы квадратов погрешности не перестанет заметно уменьшаться.

Результат применения алгоритма ISODATA приведен на рис. 4. Из него видно, что на каждом зональном изображении обнаружены объекты лишь двух классов, хотя реально на выбранной сцене присутствуют объекты трех классов: C_1 , C_2 и C_3 . На первом изображении ($\lambda=2371$ нм) класс 1 отвечает гипотезе $C_2 \cup C_3$, а класс 2 – гипотезе C_1 . На втором изображении ($\lambda=419$ нм) класс 1 отвечает гипотезе C_2 , а класс 2 – гипотезе $C_1 \cup C_3$.

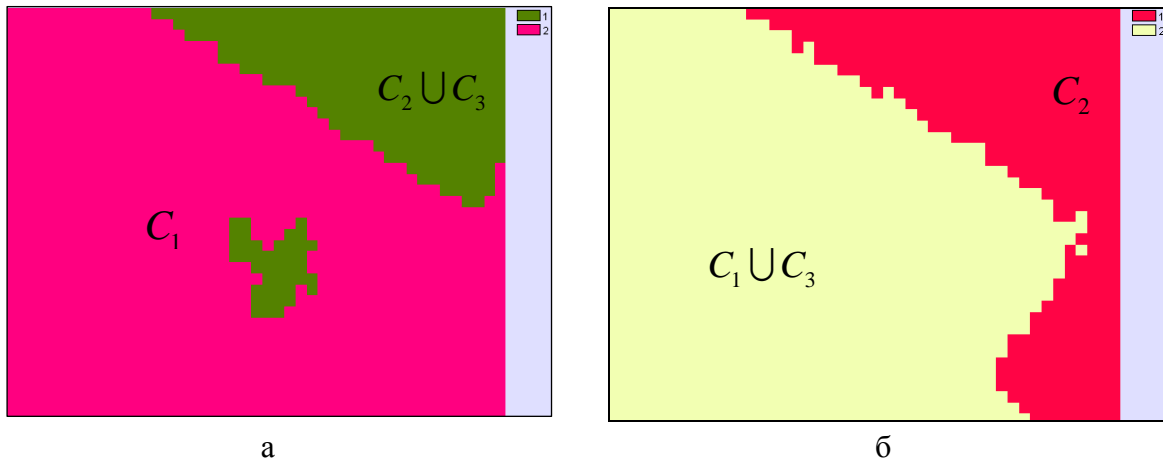


Рис. 4. Результат проведения неконтролируемой классификации: а – для первого изображения ($\lambda=2371$ нм), где класс 1 отвечает гипотезе $C_2 \cup C_3$, а 2 – C_1 ; б – для второго изображения ($\lambda=419$ нм), где класс 1 отвечает гипотезе C_2 , а 2 – $C_1 \cup C_3$

В ситуации реального присутствия на сцене объектов трех классов (рис. 3) целесообразно рассматривать такие гипотезы: нулевая ($m(\emptyset)=0$); простые гипотезы $C_i; i=1,2,3$; сложные гипотезы $C_1 \cup C_2$; $C_1 \cup C_3$; $C_2 \cup C_3$ и $\Theta = C_1 \cup C_2 \cup C_3$.

Теперь необходимо определить функции массы для этих гипотез. Если неопределенность между двумя классами отсутствует (предусматривается, что они известны), то функция массы их объединения является нулевой. И наоборот, когда два класса C_i и C_j не различаются на изображениях, целесообразно представить их объединение $C_i \cup C_j$ ненулевой массой. Для определения функций массы C_i и C_j могут использоваться два основных подхода:

- массы двух классов стремятся к нулевому значению: $m(C_i)=m(C_j)=0$ и $m(C_i \cup C_j) \neq 0$;

– массы двух классов, а также их объединения, не являются нулевыми:
 $m(C_i) = m(C_j) = m(C_i \cup C_j) \neq 0$.

Предположим, что неопределенность принадлежности пиксельного объекта C_i или C_j класса – полная и масса произвольно распределена между C_i , C_j и частью неопределенности, которая представлена $m(C_i \cup C_j)$. Таким образом, второй подход является промежуточным между моделью полной неопределенности про C_i или C_j относительно $C_i \cup C_j$ и байесовским подходом, где неопределенность считается нулевой ($m(C_i) = m(C_j) \neq 0, m(C_i \cup C_j) = 0$). В данной работе будет рассмотрен второй подход определения массы, поскольку экспериментальные результаты показывают, что в случае первого подхода конечное число классов составляет значительную величину, а это усложняет интерпретацию результатов [4].

Если обозначить $\{A_1, \dots, A_t\}$ и $\{B_1, \dots, B_h\}$ два соответствующих набора классов, где t – количество классов для первого изображения, а h – количество классов для второго изображения, тогда для каждого пикселя x_s ненулевая функция массы может быть определена величиной апостериорной вероятности следующим образом:

для простых гипотез: $H = A_i \cap B_j$ при условии, что $A_i \cap B_j \neq \emptyset$

$$\begin{cases} m_1(H) = m_1(A_i) = P(A_i/x_s), \\ m_2(H) = m_2(B_j) = P(B_j/x_s), \end{cases}$$

для сложных гипотез:

$H = A_i \cap (B_1 \cup \dots \cup B_j \cup \dots \cup B_h)$ при условии, что $A_i \cap B_j \neq \emptyset, j \in [1, h]$

$$\begin{cases} m_1(H) = m_1(A_i) = P(A_i/x_s), \\ m_2(H) = 0, \end{cases}$$

$H = (A_1 \cup \dots \cup A_i \cup \dots \cup A_t) \cap B_j$ при условии, что $A_i \cap B_j \neq \emptyset, i \in [1, t]$

$$\begin{cases} m_1(H) = 0, \\ m_2(H) = m_2(B_j) = P(B_j/x_s), \end{cases}$$

где $P(A_i/x_s)$ и $P(B_j/x_s)$ – апостериорные вероятности классов для первого и второго изображений.

В свою очередь, величина апостериорной вероятности, например, для $P(B_j/x_s)$, может быть определена по теореме Байеса, как в [12]:

$$P(B_j/x_s) = \frac{P(B_j)P(x_s/B_j)}{\sum_{j=1}^h P(B_j)P(x_s/B_j)},$$

где $P(B_j)$ – априорная вероятность класса B_j , $P(x_s/B_j)$ – условная вероятность принадлежности пикселей x_s к классу B_j для второго изображения.

Если допустить, что распределение яркости объектов на многоспектральном / гиперспектральном изображении подчинено закону нормального распределения, тогда условная вероятность $P(x_s/B_j)$ может быть определена как

$$P(x_s/B_j) = \frac{1}{\sqrt{(2\pi)^K}} \cdot \frac{1}{\sqrt{|\mathbf{V}_j|}} \cdot \exp\left(-\frac{1}{2}(x_s - \boldsymbol{\mu}_j)^T \mathbf{V}_j^{-1}(x_s - \boldsymbol{\mu}_j)\right), \quad (4)$$

где \mathbf{V}_j – ковариационная матрица размером $K \times K$ для j -го класса объектов.

Из выражения (4) видно, что величина условной вероятности принадлежности пикселей x_s к классу B_j зависит от ковариационной матрицы \mathbf{V}_j и вектора средних значений $\boldsymbol{\mu}_j$. В свою очередь, ковариационная матрица \mathbf{V}_j и вектор средних значений $\boldsymbol{\mu}_j$ определяются на основе сформированных классов C_1 , C_2 , $C_1 \cup C_3$ и $C_2 \cup C_3$ (являются их характеристиками), которые были получены путем применения алгоритма неконтролируемой классификации ISODATA.

Результаты расчета функции массы по теореме Байеса в программной среде IDRISI Selva [13] для определенных классов каждого изображения приведены на рис. 5 и 6.

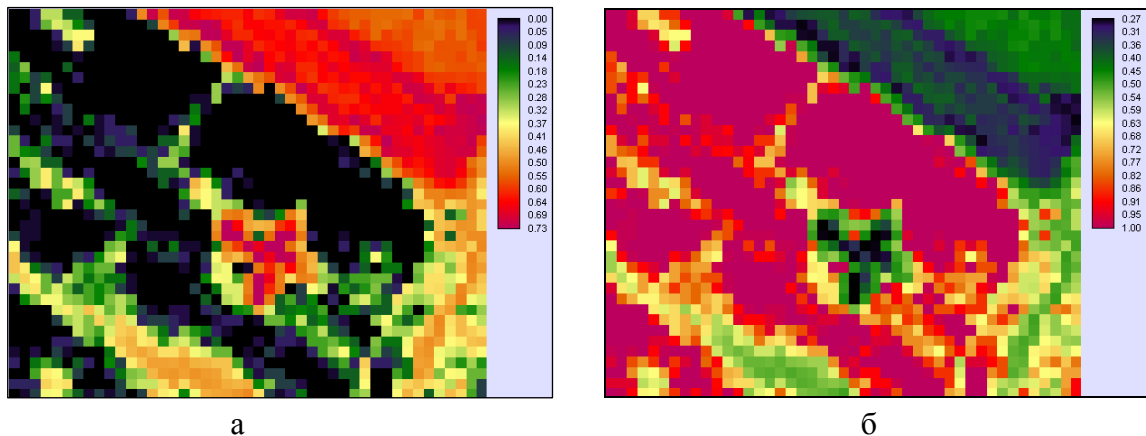


Рис. 5. Распределение величины апостериорной вероятности по полю изображения для первого изображения ($\lambda=2371$ нм): а – для класса $C_2 \cup C_3$; б – для класса C_1

Во время расчета функции массы по полю изображения значение величины априорной вероятности для каждого из классов выбиралось как равновероятное.




Рис. 6. Распределение величины апостериорной вероятности по полю изображения для второго изображения ($\lambda=419$ нм): а – для класса $C_1 \cup C_3$; б – для класса C_2

Результат объединения данных на основе комбинационного правила Демпстера приведен на рис. 7 и 8.




Рис. 7. Результат объединения данных на основе правила Демпстера: а – распределение функции доверия по полю изображения для класса C_2 ; б – распределение функции правдоподобия по полю изображения для класса C_2

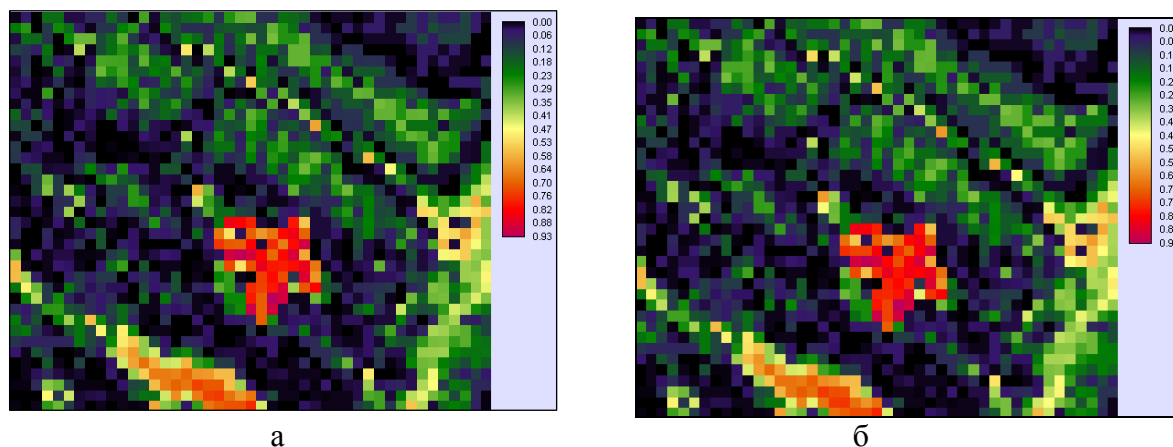


Рис. 8. Результат объединения данных на основе комбинационного правила Демпстера: а – распределение функции доверия по полю изображения для класса C_3 ; б – распределение функции правдоподобия по полю изображения для класса C_3

Следующим этапом алгоритма является принятие решения относительно определения наиболее адекватных гипотез. В качестве критерия воспользуемся правилом максимального правдоподобия [12]:

$$\max\{Pls(A_{j\text{complex}})\},$$

где $A_{j\text{complex}}$ – j -ая гипотеза после объединения данных на основе комбинационного правила Демпстера.

Результат сегментации объединенного изображения по выбранному правилу приведен для класса C_3 на рис. 9. Из полученного результата видно, что класс, который не удалось выделить на отдельном изображении, с достаточно высокой точностью ($Pls \in [0.7, 0.94]$) обнаруживается на объединенном изображении.




Рис. 9. Результат сегментации объединенного изображения по правилу максимального правдоподобия для класса C_3

Таким образом, алгоритмическая процедура классификации объектов на многоспектральных / гиперспектральных аэрокосмических изображениях, в основу которой положена ТСДШ, может быть представлена структурно-логической схемой, приведенной на рис. 10.

Процедура состоит из трех следующих этапов:

1. Предварительный этап. Проводится предварительная обработка входных изображений (геометрическая, радиометрическая, атмосферная коррекция, геореференцирование и неконтролируемая классификация данных). Формируются классы, с помощью которых могут быть описаны объекты.

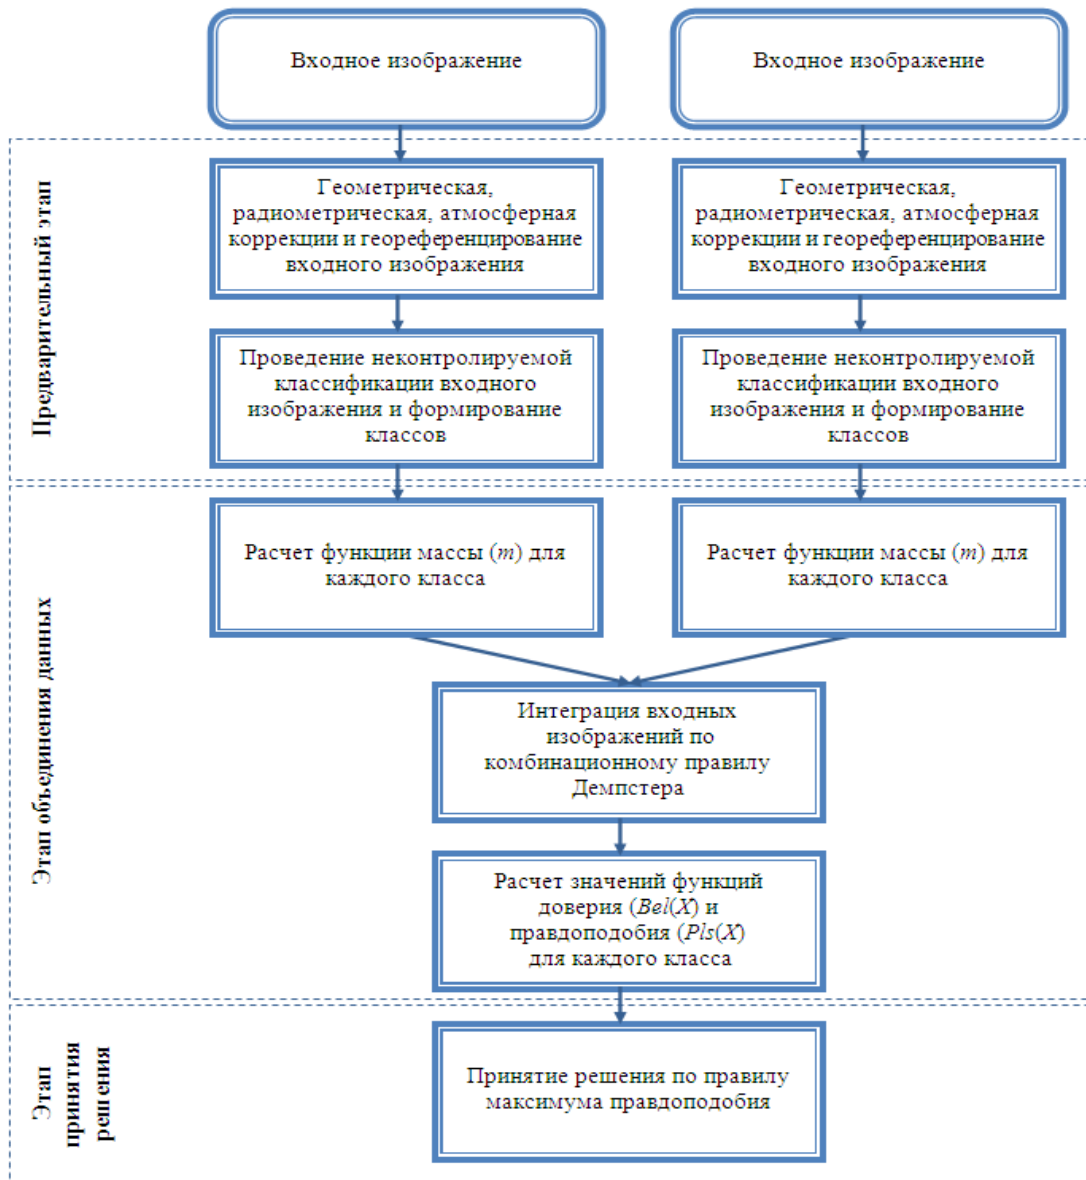


Рис. 10. Структурно-логическая схема алгоритма классификации объектов на основе ТСДШ

2. Этап объединения данных. Определяется величина функции массы для каждого класса входных изображений на основе байесовской классификации и проводится объединение данных в соответствии с комбинационным правилом Демпстера. При проведении байесовской классификации величина априорной вероятности классов может выбираться произвольно или с учетом предыдущих исследований, которые могут быть представлены в виде отдельных изображений для каждого класса, численного значения или их совместной комбинации. Также рассчитываются значения функций доверия и правдоподобия для каждой гипотезы.

3. Этап принятия решения. Решение принимается на основе критерия максимума правдоподобия.

Необходимо отметить, что правило принятия решения может быть изменено в зависимости от типа задачи, которая решается, а также от вида гипотез, которые рассматриваются в процессе исследования.

6. Выводы

Предложен и обоснован новый алгоритм обработки многоспектральных / гиперспектральных аэрокосмических изображений, позволяющий классифицировать практически все объекты, которые присутствуют на сцене. В основу алгоритма положена теория свидетельств Демпстера-Шейфера, позволяющая решить задачу выявления объектов не только отдельных классов, но также их объединений, то есть учитывать “смешанные” пиксели, наличие которых присуще изображениям среднего пространственного разрешения, в частности, многоспектральным изображениям, которые формирует оптико-электронная аппаратура, устанавливаемая на борту отечественных спутников дистанционного зондирования Земли серии “Сич”.

На материалах гиперспектральной космической съемки показано, что при анализе сцены с объектами двух классов, которые не различаются на одном изображении, применение методов ТСДШ дает возможность не делать выбор между этими двумя классами, а рассчитать значение функции массы их объединения, определить величину функции доверия и правдоподобия, а также, на основе принятого правила принятия решения отнести каждый пиксельный объект к соответствующему классу.

Последующие исследования должны быть направлены на усовершенствование предложенного алгоритма с целью повышения точности классификации объектов на изображениях разной физической природы.

СПИСОК ЛИТЕРАТУРЫ

1. Tso B. Classification Methods for Remote Sensed Data / B. Tso, P.M. Mather. – London: Tailor and Francis. 2001. – 332 p.
2. Багатоспектральні методи дистанційного зондування Землі в задачах природокористування / За ред. В.І. Лялька, М.О. Попова. – К.: Наукова думка, 2006. – 360 с.
3. Borengasser M. Hyperspectral Remote Sensing / M. Borengasser, W.S. Hungate, R. Watkins. – London: CRC Press, 2008. – 119 p.
4. Le Hegarat-Masclé S. Application of Dempster-Shafer Evidence Theory to Unsupervised Classification in Multisource Remote Sensing / S. Le Hegarat-Masclé, I. Bloch, D. Vidal-Madjar // IEEE Transactions on Geoscience and Remote Sensing. – 1997. – Vol. 35, N 4. – P. 1018 – 1031.
5. Lee T. Probabilistic and evidential approaches for multisource data analysis / T. Lee, J.A. Richards, J.H. Swain // IEEE Transactions on Geoscience and Remote Sensing. – 1987. – Vol. 25. – P. 283 – 293.
6. Benediktsson J.A. Neural network approaches versus statistical methods in classification of multisource remote sensing data // J.A. Benediktsson, P.H. Swain, O.K. Esroy // IEEE Transactions on Geoscience and Remote Sensing. – 1990. – Vol. 28. – P. 540 – 552.
7. Shafer G. A Mathematical Theory of Evidence / Shafer G. – Princeton: Princeton University Press, 1976. – 297 p.

8. Smets P. Belief functions: the disjunctive rule of combination and the generalized Bayesian theorem / P. Smets // *Int. Journal of Approximate Reasoning*. – 1993. – Vol. 9. – P. 1 – 35.
9. Smets P. The application of the matrix calculus to belief functions / P. Smets // *Int. Journal of Approximate Reasoning*. – 2002. – Vol. 31. – P. 1 – 30.
10. Jiang W. A New Method to Determine BPA in Evidence Theory / W. Jiang, Y. Deng, J. Peng // *Journal of Computers*. – 2011. – Vol. 6, N 6. – P. 1162 – 1167.
11. Dempster A.P. A generalization of Bayesian inference / A.P. Dempster // *Journal of the Royal Statistical Society*. – 1968. – Vol. 30. – P. 205 – 247.
12. Кашкин В.Б. Дистанционное зондирование Земли из космоса. Цифровая обработка изображений: учебн. пособ. / В.Б. Кашкин, А.И. Сухинин. – М.: Логос, 2001. – 264 с.
13. Eastman J.R. IDRISI Selva Manual / Eastman J.R. – Worcester, Massachusetts: Clark University, 2012. – 322 p.

Стаття надійшла до редакції 28.11.2013