

МЕТОДЫ И СИСТЕМЫ АВТОМАТИЗАЦИИ.  
ОБРАБОТКА ДАННЫХ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ

УДК 528.85; 621.396

К.Т. Протасов

**ВЫДЕЛЕНИЕ ПОЛЕЙ ОБЛАЧНОСТИ НА КОСМИЧЕСКИХ СНИМКАХ  
АЛГОРИТМОМ СЕГМЕНТАЦИИ, ОСНОВАННОМ НН КЛАСИФИКАЦИИ  
И РАСПОЗНАВАНИИ ОБРАЗОВ**

Разработан комбинированный алгоритм сегментации многоспектральных космических снимков подстилающей поверхности Земли и облачности, основанный на четырехэтапной процедуре. На первом шаге производится пофрагментная локальная кластеризация видеоданных, на втором объединяются ближайшие из найденных классов с использованием расстояния Бхаттачария, на третьем шаге укрупненные классы служат материалом обучения алгоритма распознавания образов и осуществляется это обучение; наконец, на четвертом шаге производится сегментация всего изображения алгоритмом распознавания образов. Такой подход позволяет корректно решать задачу компромисса между громоздкостью исходных данных и необходимостью использовать адекватные модели распознаваемых образов, основанных, как в данном случае, на аппроксимациях Джонсона. Работа алгоритма иллюстрируется примером выделения облачных полей, зарегистрированных радиометром AVHRR спутника NOAA.

При решении задач природопользования и климато-экологического мониторинга природных комплексов основным источником оперативной информации являются многоканальные космические снимки подстилающей поверхности Земли и облачности. Учитывая тот факт, что в подавляющем большинстве случаев регистрация изображений проводится в условиях разорванной облачности, возникает задача автоматического выявления полей облачности с помощью алгоритмов сегментации видеоданных. Проблема идентификации полей облачности может иметь и самостоятельное значение при решении задач оценивания запаса влагосодержания облаков, определения микроструктурных параметров, типов облачности, прогнозирования гроз и т.п. Характерной особенностью этого класса задач является тот факт, что приходится анализировать поля больших размеров (например, для спутников серии NOAA поле видеоданных состоит из  $2048 \times 5000$  отсчетов для каждого из пяти спектральных диапазонов, регистрируемых прибором AVHRR), что затрудняет использование стандартных подходов.

Рассмотрим комбинированный алгоритм сегментации многоканальных спутниковых изображений, основанный на кластерном анализе локальных участков данных с последующим использованием алгоритмов распознавания образов.

Под сегментацией изображений понимают автоматическое разбиение изображений на содержательно интерпретируемые области. Эти области могут быть связаны с обнаруживаемыми, опознаваемыми объектами, которые различаются по своим яркостным, геометрическим и текстурным характеристикам. Поэтому сегментация изображений является начальным этапом

построения формального описания анализируемой сцены. Это формальное описание далее используется для обнаружения, идентификации и распознавания объектов или явлений.

Для построения простейших процедур сегментации часто используется концепция границ и концепция уровней постоянства интенсивностей, обзор результатов по этим алгоритмам подробно представлен в [1, 2]. В более сложных алгоритмах сегментации используется концепция разметки точек областей, основанная на введении понятия однородности. В этом случае сегментация связана с проблемой агрегирования данных, которая осуществляется алгоритмами кластерного анализа (автоматической классификации, таксономии) [3–6, 8].

В алгоритмах сегментации методы классификации используют следующим образом. Для каждой точки (пиксела) зафиксированного изображения определяется некоторый набор характеристик, названных признаками, в частном случае это могут быть оцифрованные значения регистрируемых полей яркостей всех спектральных диапазонов непосредственно. В пространстве этих признаков выделяют скопления (грозди) точек, называемые кластерами. Точки каждого кластера на исходном изображении образуют связные области, выделяемые алгоритмом сегментации. Успех решения задачи сегментации зависит от системы формируемых признаков и стратегии выделения ближайших в некотором смысле точек.

Условно можно выделить два подхода при формировании признаков. В первом подходе признаки характеризуют некоторый участок наблюдаемой регистрирующим прибором сцены земной поверхности

или облачности и отображают эту информацию (с учетом разрешающей способности прибора) в элемент (точку, пиксел) анализируемого изображения, при этом создается набор признаков для пиксела изображения. Таковыми могут быть яркостные характеристики элемента изображения, заданные набором спектральных диапазонов, или функциональные преобразования яркостных характеристик. В этом случае размерность признакового пространства определяется числом спектральных диапазонов регистрирующего прибора.

Во втором подходе признаки формируются некоторой окрестностью элемента изображения, при этом могут быть использованы статистики спектральных яркостей, средние значения яркостей на фрагменте изображения, ковариационные и текстурные характеристики оцифрованных полей. В этом случае набор признаков анализируемого пиксела зависит от ближайших соседних элементов выбранной окрестности.

При построении алгоритма сегментации изображений на основе кластерного анализа необходимо: а) сформировать подходящий набор признаков для элемента видеоданных, которым может быть пиксел или фрагмент; б) определить критерий агрегирования точек в пространстве признаков, задав меру «близости»; в) наметить стратегию обнаружения некоторого (искомого) количества кластеров, когда их число априорно не задано.

Несмотря на то, что проблемам синтеза алгоритмов автоматической классификации посвящено большое количество работ, например [3–6], до сих пор эта задача в должной степени не формализована и список существующих алгоритмов постоянно пополняется новыми. При построении алгоритмов классификации широко используются эвристические приемы, позволяющие учитывать разнообразие конкретных задач анализа видеоданных. Следует иметь в виду, что анализируемые космические снимки Земли, как правило, имеют размеры  $1024 \times 1024$  отсчетов и более, заданных набором спектральных диапазонов, количество которых постоянно увеличивается, появляются гиперспектральные видеоданные, включающие сотни диапазонов, поэтому задача кластерного анализа для таких объемов данных сложна и в вычислительном плане.

В качестве алгоритма кластеризации в простейших случаях используется процедура IZODATA (Isodata-Iterative Self-Organizing Data Analysis Techniques), представленная в пакетах ERDAS и ENVI, основанная на формализации эмпирического опыта, в которой точки изображения разбиваются на заданное число кластеров, минимизируя сумму среднеквадратических отклонений точек от центров кластеров и максимизируя разброс самих центров [4, 5]. При обработке изображений больших форматов кластеризацию проводят по блокам, а затем сшивают результаты локальных кластеризаций.

Однако наиболее обоснованным с теоретической точки зрения является подход к построению алгоритмов кластеризации, базирующийся на описании классов в признаковом пространстве смесью вероятностных распределений. Выделение отдельных кластеров в этом случае связано с решением задачи расщепления совместного распределения на составляющие условные одномодальные функции плотности, последние и являются моделями искомого классов. К сожалению, эта задача связана с поиском локальных экстремумов многомерной многоэкстремальной функции, которые, как правило, слабо выражены, и является чрезмерно громоздкой в вычислительном плане даже для небольших объемов данных [3–5].

Предлагаемый далее алгоритм автоматической классификации, сохраняя хорошие локальные свойства, способен работать с большими массивами видеоданных и представляет собой следующую четырехэтапную процедуру. На первом этапе производится кластерный анализ небольших фрагментов многоспектральных видеоданных, основанный на пороговом решающем правиле и полном переборе возможных вариантов. На втором этапе производится нормализация данных и объединение локальных классов всех фрагментов в более крупные блоки с использованием меры близости групп. На третьем этапе производится обучение алгоритма распознавания образов выявлять классы, полученные на втором шаге агрегирования данных. Наконец, на четвертом шаге с помощью решающего правила происходит распознавание всего изображения. Учитывая, что материалом обучения может служить небольшое количество фрагментов, статистически эквивалентных всему изображению, такой подход приводит к резкому снижению объема вычислений при сохранении точностных характеристик решающего правила.

Особенностью предлагаемого алгоритма является тот факт, что мерой близости или различимости выделяемых классов служат функционал риска либо оценки его границ снизу или сверху, а вероятностные модели классов восстанавливаются с помощью аппроксимаций Джонсона.

Предположим, что локальная кластеризация в рамках небольшого фрагмента изображения проводится одним из известных методов, который выбирается из соображений вычислительной простоты в компромиссе со строгостью обоснования, и сосредоточим свое внимание на втором и третьем этапах построения алгоритма.

Вначале более подробно рассмотрим вопросы построения алгоритма классификации с последующим распознаванием. Пусть результатом наблюдения является совокупность оцифрованных полей видеоданных, взятых в нескольких спектральных диапазонах, так что каждый пиксел изображения подстилающей поверхности Земли и облачности, зафиксированных системой регистрации, характеризуется случайным вектором  $\mathbf{X} = (X^1, \dots, X^n)^T$ , где  $T$  – знак

транспонирования,  $\mathbf{X} \in R^n$ , а  $R^n$  –  $n$ -мерное пространство наблюдений. Компоненты  $X^i$ ,  $i = 1, \dots, n$  вектора наблюдения  $\mathbf{X}$  характеризуют отражательные (радиояркие) свойства ландшафтов и облачности в каждом спектральном диапазоне соответственно. Будем предполагать, что в пространстве наблюдений совместное распределение компонент вектора  $\mathbf{X}$  может быть представлено в виде следующей функции плотности вероятностей:

$$f(\mathbf{x}) = \sum_{j=1}^Q P_j f_j(\mathbf{x}; \theta_j), \quad (1)$$

где  $Q$  – число классов;  $f(\mathbf{x}; \theta_j)$  – условная одномодальная параметрическая (с вектором параметров  $\theta_j \in R^m$ ,  $m$  – размерность пространства параметров) функция плотности класса  $j$ ;  $P_j$  – вес функции плотности  $f_j(\mathbf{x}; \theta_j)$  в смеси, имеющей смысл априорной вероятности появления класса  $j$ ;  $\sum_{j=1}^Q P_j = 1$ ;  $\theta_j$  – параметры функции плотности. Все перечисленные параметры неизвестны. Задача заключается в том, чтобы по имеющейся неклассифицированной выборке  $\mathbf{X}_1, \dots, \mathbf{X}_N$  объема  $N$  наблюдений восстановить все компоненты смеси (1)  $\{Q, P_j, f_j(\mathbf{x}; \theta_j), j = 1, \dots, Q\}$ .

Следует заметить, что задача восстановления компонент смеси (1) имеет решение лишь в случае ее идентифицируемости [3, 6]. Это трудно проверяемое на практике условие с геометрической точки зрения означает, что  $f(\mathbf{x})$  должна иметь «ярко выраженные» локальные моды, порождаемые кластерообразующими подвыборками смешанной выборки. Кроме того, поведение  $f(\mathbf{x})$  в окрестности моды должно позволять с достаточной для практики точностью восстанавливать параметрические функции  $f_j(\mathbf{x}; \theta_j)$ , которые и являются моделями искомого классов.

Рассмотрим вопрос выбора аппроксимирующих распределений для неизвестных моделей кластеров  $f_j(\mathbf{x}; \theta_j)$ , когда имеется выборка данных этого класса  $\mathbf{X}_1, \dots, \mathbf{X}_N$  с объемом  $N$ . Обратимся к подходу восстановления параметрических распределений, основанному на аппроксимациях Джонсона [7, 10]. При этом будем учитывать согласованность распределений отдельных признаков с истинными одномерными распределениями и, кроме того, в какой-то мере описывать статистические связи между компонентами наблюдаемого вектора. Процедуру восстановления параметрических функций плотности в этом случае можно представить в виде двух этапов.

На первом этапе для каждого признака подбирается соответствующее преобразование Джонсона, с достаточной надежностью согласованное с истинным неизвестным распределением. На втором этапе для описания статистических связей преобразованных компонент наблюдаемого вектора оцениваются коэффициенты корреляции между признаками. После этого совместное распределение компонент слу-

чайного вектора записывается следующим образом (опуская индекс класса):

$$f(\mathbf{x}; \theta_j) = \frac{\prod_{i=1}^n \delta^i \tau'_i(x^i; \varepsilon^i, \lambda^i)}{(2\pi)^{n/2} |R|^{n/2}} \exp \left\{ -\frac{1}{2} (\gamma + \delta \tau(\mathbf{x}; \varepsilon, \lambda))^T R^{-1} \times \right. \\ \left. \times (\gamma + \delta \tau(\mathbf{x}; \varepsilon, \lambda)) \right\}, \quad (2)$$

где вектор

$$\gamma + \delta \tau(\mathbf{x}; \varepsilon, \lambda) = \begin{bmatrix} \gamma^1 + \delta^1 \tau(x^1; \varepsilon^1, \lambda^1) \\ \vdots \\ \gamma^n + \delta^n \tau(x^n; \varepsilon^n, \lambda^n) \end{bmatrix};$$

$$R = (\tau_{ij}); \quad \tau_{ij} = \frac{1}{N} \sum_{k=1}^N [\gamma^i + \delta^i \tau(x_k^i; \varepsilon^i, \lambda^i)] [\gamma^j + \delta^j \tau(x_k^j; \varepsilon^j, \lambda^j)];$$

$\tau(x; \varepsilon, \lambda)$  – какое-либо из нормализующих преобразований Джонсона;

$$\theta = (\gamma^1, \dots, \gamma^n; \delta^1, \dots, \delta^n; \varepsilon^1, \dots, \varepsilon^n; \lambda^1, \dots, \lambda^n; (\tau_{ij})_{n \times n})^T, \text{ а}$$

$$\tau'_i(x; \varepsilon, \lambda) = \left| \frac{d\tau(x; \varepsilon, \lambda)}{dx} \right|.$$

Параметры  $\varepsilon$  и  $\lambda$  имеют смысл нижней границы и размаха выборки для каждой компоненты вектора наблюдений соответственно и могут быть определены из физических соображений либо оценены по выборке непосредственно. При известных параметрах  $\varepsilon$  и  $\lambda$  параметры  $\gamma$  и  $\delta$  несложно определить методом максимального правдоподобия [7, 10].

После того как вероятностные модели классов восстановлены Байесово, решающее правило относит вновь наблюдаемый вектор  $\mathbf{x}$  к одному из имеющихся классов [4–6]

$$u = \arg \max_{i=1, \dots, Q} P_i f_i(\mathbf{x}; \hat{\theta}_i), \quad (3)$$

где  $P_i$ ,  $i = 1, \dots, Q$  – априорные вероятности появления классов или их оценки;  $u$  – принимаемое решение (номер опознанного класса). Это решающее правило минимизирует вероятность неверно принимаемых решений (усредненную ошибку распознавания). Критерий минимума ошибок классификации является частным случаем критерия типа риска. Лишь эти критерии адекватны задачам распознавания и проверки гипотез.

Ввиду того что вероятности ошибки классификации оценить затруднительно [4], так как необходимо произвести интегрирование взвешенных функций плотности в многомерных признаковых пространствах, целесообразно использовать границы вероятности ошибок. Действительно, в случае двух классов ( $Q = 2$ ) средняя вероятность ошибочных решений  $\varepsilon$ , выраженная через вариационное расстояние Колмогорова, имеет вид [4]

$$\varepsilon = \frac{1}{2} \left[ 1 - \int_X |P_1 f(\mathbf{x}/1) - P_2 f(\mathbf{x}/2)| d\mathbf{x} \right], 0 \leq \varepsilon \leq 1/2, \quad (4)$$

где  $P_1 f(\mathbf{x}/1)$ ,  $P_2 f(\mathbf{x}/2)$  – условные функции плотности классов 1 и 2 соответственно, а  $X$  – область интегрирования. Оказывается, что

$$(1/2) - (1/2) (1 - 4\varepsilon_n^2)^{1/2} \leq \varepsilon \leq \varepsilon_n,$$

где  $\varepsilon_n = [P_1 P_2]^{1/2} \exp \{-\mu(1/2)\}$  и величину  $\mu(1/2) = -\ln \int_X [f(\mathbf{x}/1) - f(\mathbf{x}/2)]^{1/2} d\mathbf{x}$ , называемую рас-

стоянием Бхаттачария, можно использовать в качестве упрощенного критерия разделимости классов.

Теперь рассмотрим простой вариант распознавания образов или автоматической классификации с гауссовыми моделями описания классов. Для гауссовой модели расстояние Бхаттачария имеет вид [4]

$$\mu_v \left( \frac{1}{2} \right) = \frac{1}{8} (m_1 - m_2)^T \left( \frac{\Sigma_1 + \Sigma_2}{2} \right)^{-1} (m_1 - m_2) + \frac{1}{2} \ln \frac{\frac{1}{2} (\Sigma_1 + \Sigma_2)}{|\Sigma_1|^{1/2} |\Sigma_2|^{1/2}}, \quad (5)$$

где  $m_i$ ,  $\Sigma_i$  – математическое ожидание и корреляционная матрица  $i$ -го класса,  $i = 1, 2$ . Если  $\Sigma_1 \cong \Sigma_2$ , что верно при «близких» классах, то

$$\mu_v \left( \frac{1}{2} \right) = \frac{1}{8} (m_1 - m_2)^T S^{-1} (m_1 - m_2) + \frac{1}{2} \ln \frac{|\Sigma|}{|\Sigma|} \cong 0, \Sigma \cong \frac{1}{2} \quad (6)$$

и расстояние Бхаттачария может служить критерием объединения двух распределений, а точнее, двух выборочных ансамблей наблюдений (для которых  $\mu_v$  мало) в одну группу, образующую однородный класс.

Для распределений, построенных с использованием нормализующих преобразований Джонсона, также можно воспользоваться критерием разделимости классов (5) следующим образом. Вначале отметим, что граница Чернова и расстояние Бхаттачария [4] обладают свойством инвариантности относительно взаимно однозначных преобразований. Несложно показать, что для многомерных распределений Джонсона можно построить взаимно однозначное преобразование, которое переводит распределения (2) в нормальные функции плотности, а для этих распределений расстояние Бхаттачария подсчитано и имеет вид (5). Действительно, например, для нормализующего преобразования семейства  $S_L$  с общими границей  $\varepsilon$  и параметром  $\lambda$  определим нормализующее невырожденное преобразование (представленное для простоты для одной компоненты вектора)

$$\xi = \gamma + \delta \ln (x - \varepsilon) / \lambda \quad (7)$$

и обратное к нему

$$x = \varepsilon + \lambda \exp \{(\xi - \gamma) / \delta\}. \quad (8)$$

Подставляя  $\xi$  в выражение для функции плотности (2), получим в новом пространстве

$$f_j(\xi) = \frac{1}{(\sqrt{2\pi})^n |G_j|^{1/2}} \times \exp \left\{ -\frac{1}{2} \left( \xi - \left( \gamma - \frac{\delta}{\delta_j} \gamma^j \right) \right)^T G_j^{-1} \left( \xi - \left( \gamma - \frac{\delta}{\delta_j} \gamma^j \right) \right) \right\}, \quad (9)$$

где  $G_j = M \left( \xi - \left( \gamma - \frac{\delta}{\delta_j} \gamma^j \right) \right) \left( \xi - \left( \gamma - \frac{\delta}{\delta_j} \gamma^j \right) \right)^T, j = 0, \dots, Q;$

$M$  – оператор математического ожидания;  $\gamma$ ,  $\delta$  – параметры преобразующей функции, а  $\varepsilon$  и  $\lambda$  – те же, что и в (2), аналогично и для других типов распределений Джонсона.

Работа программы, реализующей алгоритм, начинается с выбора фрагментов материала обучения на поле анализируемого изображения. Эти фрагменты могут быть выбраны оператором из соображений, связанных с конкретной задачей сегментации, а именно: увеличивая представительность того или иного класса, можно повысить точность его описания и селекции. При необходимости расположение фрагментов на поле изображения можно поручить и случайному механизму, например задать равномерным.

Идея определения стратегии выбора фрагментов заключается в естественном требовании обеспечить материал обучения свойствами статистической однородности и репрезентативности, присущими всему ансамблю данных поля анализируемого изображения.

После того как выборка обучающих фрагментов сформирована, начинается этап выделения локальных кластеров в рамках каждого фрагмента. Так как размеры фрагментов невелики, то для поиска кластеров может быть использована любая процедура кластерного анализа, включая процедуры полного перебора расстояний между точками и выявления групп точек по методу ближайшего соседства.

В данном случае мы использовали метод выделения левой моды гистограмм расстояний [9], обеспечивающий среднестатистическую меру близости группы точек. Суть этого метода состоит в следующем. Для каждого вектора, компонентами которого являются значения спектральных яркостей, подсчитываются расстояния в метрике Евклида до всякого другого вектора анализируемого фрагмента и строится гистограмма распределения этих расстояний.

Далее среди всех гистограмм выбирается гистограмма, мода которой лежит левее всех мод других гистограмм, формируемых в рамках очередного фрагмента. Адаптивный порог отсекает группу точек, порождающих эту гистограмму. Эти точки формируют кластер и исключаются из дальнейшего рассмотрения, процесс повторяется до тех пор, пока не останется небольшое количество векторов, не

вошедших ни в один из классов. Это аномальные векторы, непригодные для обучения, и их отнесение к тому или иному классу происходит на этапе распознавания.

На втором шаге решается задача агрегирования результатов локальных кластеризаций, при этом мерой близости классов, в предварительно нормализованном с использованием преобразования (8) пространстве, служит расстояние Бхаттачария (6). Перебирая всевозможные пары классов всех фрагментов, объединяем ближайшие из них, в смысле минимума этого расстояния. В результате переходим к небольшому, заранее заданному оператором, числу классов.

На третьем этапе полученные классы служат обучающими выборками алгоритма распознавания образов. При этом оцениваются параметры решающего правила (3) с использованием (2). С помощью полученного решающего правила на четвертом этапе производится классификация всего изображения стандартным образом.

Для иллюстрации работы алгоритма были взяты 3 изображения, зафиксированные радиометром AVHRR спутника NOAA в 5 спектральных диапазонах (1 канал – 0,58–0,68 мкм, 2 канал – 0,725–1,1 мкм, 3 канал – 3,55–3,93 мкм, 4 канал – 10,3–11,3 мкм, 5 канал – 11,5–12,5 мкм) размером  $1024 \times 1024$  отсчета, с разрешением в подспутниковой точке  $1 \times 1 \text{ км}^2$  на пиксел.




Рис. 1. Изображение первого спектрального канала прибора AVHRR спутника NOAA-12 (а); выделенные поля облачности (б); снег в горах (в)




Рис. 2. Изображение первого спектрального канала прибора AVHRR спутника NOAA-14 (а); выделенные поля облачности (б); снег приподнятого плато (в)

Первое из этих изображений Западной Сибири и Горного Алтая, полученное спутником NOAA-12 14.5.97 в 9 ч 34 мин мест. времени с апогеем орбиты  $81^\circ 83'$ , свидетельствует о наличии облаков и снежного покрова в горах Алтая. Для обучения алгоритма сегментации было выбрано 18 фрагментов  $64 \times 64$  пиксела. Эти фрагменты равномерно располагались по полю исходного изображения  $1024 \times 1024$  отсчета. В результате работы программы было получено 233 класса, которые путем укрупнения были сведены к

50 классам. Затем алгоритмом распознавания образов было проанализировано все изображение. Некоторые результаты работы алгоритма приведены на рис. 1. На рис. 1,а представлено исходное изображение первого канала радиометра. Результат выделения класса «облака» представлен на рис. 1,б, а на рис. 1,в – класса «снег». Анализ рисунков показывает, что разделение классов в пятимерном пространстве признаков происходит достаточно надежно, в то время как в отдельных спектральных диапазонах они не различаются.

На втором изображении зафиксировано плато Путорана (среднегорное поднятие Средне-Сибирского плоскогорья с отметками 900–1701 м) спутником NOAA-14, 29.5.97 в 14 ч 13 мин мест. времени с апогеем орбиты  $28^{\circ} 00'$ , которое характеризуется наличием облаков и снежного покрова. Для обучения алгоритма сегментации было выбрано 25 фрагментов  $64 \times 64$  пиксела. Эти фрагменты равномерно располагались по полю всего анализируемого изображения. Было получено 223 класса, которые путем объединения

сведены к 50 классам. Затем проанализировано все изображение алгоритмом распознавания образов, некоторые результаты работы которого приведены на рис. 2. На рис. 2,а представлено исходное изображение первого канала радиометра. Результат выделения класса «облака» представлен на рис. 2,б, а на рис. 2,в – класс «снег» – снеговое покрытие плоских вершин хребтов. Достаточно четкое разделение этих классов было бы также невозможно по данным только отдельных спектральных каналов.




Рис. 3. Изображение первого спектрального канала прибора AVHRR спутника NOAA-12 (а); выделенные поля облачности (б); выделенные грозовые облака (в)

На третьем изображении Западной Сибири и Горного Алтая, полученном спутником NOAA-12 8.8.97 в 19 ч 37 мин мест. времени с апогеем орбиты  $76^{\circ} 00'$ , видны облачные поля, включая грозовые. Для обучения алгоритма сегментации было выбрано 25 фрагментов  $64 \times 64$  пиксела. Эти фрагменты равномерно располагались по полю изображения  $1024 \times 1024$  отсчета. В результате работы программы был получен 221 класс, который путем укрупнения был сведен к 50 классам. Затем было проанализировано все изображение алгоритмом распознавания образов, результаты работы которого приведены на рис. 3. На рис. 3,а показано исходное изображение первого канала радиометра. Результат выделения классов «облака» представлен на рис. 3,б, а на рис. 3,в выделен лишь класс «грозовые облака». Из рисунков следует, что разделение классов в пятимерном пространстве признаков происходит также достаточно надежно.

1. Бакут П.А., Колмогоров Г.С., Ворновицкий И.Э. Сегментация изображений методом пороговой обработки // Зарубежная радиоэлектроника. 1987. № 10. С. 6–24.

Институт оптики атмосферы СО РАН,  
Томск

2. Бакут П.А., Колмогоров Г.С. Сегментация изображений: методы выделения границ областей // Зарубежная радиоэлектроника. 1987. № 10. С. 25–46.
3. Айвазян С.А., Бухштабер В.М., Енюков И.С., Мешалкин Л.Д. Прикладная статистика: Классификация и снижение размерности. М.: Финансы и статистика, 1989. 607 с.
4. Фукунага К. Введение в статистическую теорию распознавания образов / Пер. с англ. М.: Наука, 1979. 368 с.
5. Ту Дж., Гонсалес Р. Принципы распознавания образов / Пер. с англ. М.: Мир, 1978. 408 с.
6. Цыпкин Я.З. Основы теории обучающихся систем. М.: Наука, 1970. 252 с.
7. Протасов К.Т. Параметризация вероятностных распределений для распознавания образов, основанная на нормализующих преобразованиях // Оптика атмосферы и океана. 1994. Т. 7. № 6. С. 840–847.
8. Протасов К.Т. Распознавание образов и классификация агрегированных наблюдений в условиях статистической неопределенности // Изв. вузов. Физика. 1995. Т. 38. № 9. С. 59–64.
9. Гряднев Ю.В., Протасов К.Т. Сегментация многомерных изображений алгоритмом кластеризации, основанным на двустороннем критерии неоднородности // Оптика атмосферы и океана. 1995. Т. 8. № 7. С. 1103–1111.
10. Хан Г., Шапиро С. Статистические модели в инженерных задачах. М.: Мир, 1969. 396 с.

Поступила в редакцию  
18 августа 1997 г.

***K.T. Protasov. Discrimination of Cloudy Fields on Space Photographs by Segmentation Algorithm Based on Classification and Recognition of Patterns.***

A combined algorithm is elaborated for segmentation of polyspectral space photographs of the Earth's underlying surface and cloudiness based on four-stage procedure. At the first stage the local fragment-to-fragment clustering of videodata is performed; at the second stage the nearest of the found classes are combined using the Bhattacharia's space. At the third stage the combined classes serve as a base for teaching algorithm of pattern recognition and the teaching itself is conducted; at last, the whole pattern is segmented using the pattern recognition algorithm. Such approach is a good compromise between a great body of initial data and a necessity to use adequate models of the patterns to be recognized, based, as here, on Johnson approximation. The algorithm operation is illustrated by an example of discrimination of a cloudy field detected by radiometer AVHRR of the satellite NOAA.