

УДК 528.852

## АЛГОРИТМ КЛАСТЕРИЗАЦИИ ТЕКСТУРНЫХ ДАННЫХ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ\*

В. С. Сидорова

*Учреждение Российской академии наук  
Институт вычислительной математики и математической геофизики  
Сибирского отделения РАН,  
630090, г. Новосибирск, просп. Академика Лаврентьева, 6  
E-mail: sus@ooi.ssc.ru*

Предложен гистограммный кластерный алгоритм, учитывающий особенности сбора текстурных статистик изображения. Алгоритм позволяет объединить ложные кластеры, возникающие на границах объектов с различной текстурой, существенно уменьшив их число. Для анализа кластеров используется оценка их делимости в многомерном векторном пространстве признаков и контекст изображения. Рассмотрено применение алгоритма для автоматизации распознавания типов покрытия земной поверхности по аэроснимку лесного ландшафта. Сравнение карт кластеров и картосхем наземной таксации показывает их хорошее соответствие.

*Ключевые слова:* дистанционное зондирование, кластерный анализ, многомерная гистограмма, текстура.

**Введение.** Для автоматизации распознавания типов земного покрытия используются методы контролируемой и неконтролируемой классификации. Методы контролируемой классификации предполагают исследование объектов и их связи со спектральными или другими признаками. Для сокращения объёма данных предварительно могут быть использованы методы кластерного анализа. Кластерные алгоритмы применяются и непосредственно при распознавании в задачах неконтролируемой классификации, особенно когда отсутствует априорная информация. Оба типа классификации предполагают хорошую делимость полученных кластеров. Наиболее распространённые кластерные методы, используемые в дистанционном зондировании, —  $K$ -средних и гистограммные — не обеспечивают делимости кластеров. Поэтому необходим последующий анализ результатов кластеризации, проверка достоверности полученных кластерных распределений или валидация.

В [1] предложено использовать оценку делимости кластеров в процессе кластеризации спектральных признаков гистограммным алгоритмом Нарендры [2], что позволяет автоматизировать выбор числа уровней предварительного квантования векторного пространства и получать лучшие кластерные распределения признаков в смысле заданной меры изолированности кластеров. Указанный алгоритм затем был модифицирован для кластеризации данных по статистическим текстурным признакам изображения [3]. Модернизация связана с особенностями сбора текстурных статистик. Во-первых, алгоритм осуществил автоматический выбор окна одинакового размера во всех точках изображения для вычисления статистик. Во-вторых, были предложены принципы выявления и присоединения ложных кластеров, образующихся на границах различных текстур изображения. Для присоединения ложного кластера к основному учитывается соседство сегментов кла-

---

\*Работа выполнена частично при поддержке Российского фонда фундаментальных исследований (проект № 10-07-00131).

стеров на изображении и соседство кластеров в векторном пространстве. Ложные кластеры могут образовывать последовательности тонких сегментов, заключённых между двумя различными текстурами на изображении.

Цель данной работы — предложить алгоритм объединения тонких ложных кластеров, возникающих на границах текстур, и их слияния с основными, а также исследовать применимость алгоритма для конкретных изображений лесных ландшафтов.

**Основной алгоритм кластеризации.** Кратко опишем основной алгоритм кластеризации. Детальное описание можно найти в [3]. Алгоритм опирается на быстрый непараметрический гистограммный метод Нарендры [2]. Гистограмма сохраняется в оперативной памяти компьютера вместе со списком присутствующих на изображении линейно упорядоченных многомерных векторов. Многомерная гистограмма рассматривается как аппроксимация плотности вероятности векторов признаков. Алгоритм кластеризации является жёстким, т. е. каждый вектор он относит только к одному кластеру. С помощью графов алгоритм разделяет векторное пространство признаков по унимодальным кластерам, модальные векторы которых соответствуют локальным максимумам гистограммы. Границы кластеров в результате кластеризации проходят по долинам гистограммы (по областям низкой плотности векторов). Направление элементарного графа в каждой точке дискретного векторного пространства совпадает с направлением максимума положительного градиента плотности, найденного по окрестности ближайших соседей точки. Такое соседство определяется как совокупность векторов, каждая из компонент которых отстоит от этой точки не далее чем на единицу. Время работы алгоритма линейно зависит от  $K$  — числа векторов. Список соседей окрестности для всех векторов может быть вычислен заранее. Благодаря дискретной природе данных и линейной упорядоченности списка присутствующих векторов требуется около  $2NM_L$  простых операций их сравнения, чтобы найти соседей всех векторов (здесь  $M_L$  — число возможных соседей вектора в  $L$ -мерном пространстве признаков).

Для сокращения объёма данных и уменьшения числа кластеров алгоритм Нарендры предполагал предварительное квантование дискретного векторного пространства путём операции сдвига вправо байта информации. Эта операция соответствует уменьшению числа уровней квантования вдвое для каждого спектрального канала. Если данные имеют сложную иерархическую структуру, результаты кластеризации существенно зависят от выбора числа уровней квантования. В [1] предложен алгоритм, автоматизирующий выбор числа уровней квантования в зависимости от делимости полученных кластеров. Рассматривая число уровней квантования  $n$  как параметр, с помощью алгоритма Нарендры можно построить ряд кластерных распределений и из них выбирать лучшие по средней делимости кластеров. Детальность представления данных изменяется более плавно, чем при отсечении бит, особенно для больших  $n$ . Это позволяет тщательно проследить поведение меры изолированности кластеров и выбрать её минимумы, соответствующие лучшим классификациям для различных диапазонов изменения  $n$ . Пусть начальное число  $n < n_0$ ,  $n_0 = 256$ ; размер ячейки векторного пространства для  $n$  в каждом спектральном канале  $s = (n_0 - 1)/(n - 1)$ ;  $L$  — число признаков;  $f = [f(1), f(2), \dots, f(L)]$  — вектор признаков;  $g = [g(1), g(2), \dots, g(L)]$  — вектор, в который преобразуется  $f$ :

$$g(k) = \left[ \frac{f(k)}{s} \right], \quad k = 1, \dots, L,$$

где  $[\cdot]$  — целая часть числа.

Основной алгоритм отыскивает такое  $n$  (и соответствующие  $g$ ), при котором полученное методом Нарендры распределение векторов по унимодальным кластерам даёт минимум мере делимости кластеров в заданном диапазоне изменения  $n$ .

В [1] также определены мера изолированности для унимодального кластера  $m^j(n)$  и мера качества распределения в целом  $m(n)$  по  $K(n)$  кластерам в следующих выражениях:

$$m^j(n) = \frac{1}{B^j(n)H^j(n)} \sum_{i=1}^{B^j(n)} h_i^j(n), \quad (1)$$

$$m(n) = \frac{1}{K(n)} \sum_{j=1}^{K(n)} m^j(n), \quad (2)$$

где  $h_i^j(n)$  — значение гистограммы в  $i$ -й точке границы кластера  $j$ ;  $B^j(n)$  — число точек границы кластера;  $H^j(n)$  — максимальное значение гистограммы.

Мера (1) определяется как отношение среднего значения гистограммы на границе к максимальному значению гистограммы кластера. Всегда  $m^j(n) \leq 1$  и  $m(n) \leq 1$ . Заметим, что границы не являются общими для любой пары кластеров, так как алгоритм жёсткий и кластеры не имеют общих точек. Граница в формуле (1) определяется для каждого кластера как совокупность точек, таких что для каждой из них найдётся хотя бы одна соседняя точка в векторном пространстве, не принадлежащая этому же кластеру. Границы кластера легко вычислить, используя список соседей всех векторов, найденный для алгоритма Нарендры.

Минимумы (2) соответствуют лучшим классификациям. Для тесно расположенных унимодальных кластеров мера (2) удовлетворяет требованиям, предъявляемым к индикаторным мерам качества классификации в задачах кластерной достоверности [4]: чем компактнее кластеры и больше расстояние между ними, тем лучше классификация в смысле изолированности кластеров. Природа классифицируемых объектов — типов покрытия земной поверхности — такова, что подавляющую часть векторов признаков, спектральных или текстурных, составляют кластеры, тесно примыкающие друг к другу. Как показывают исследования, с увеличением числа уровней квантования наблюдается тенденция к падению средней разделимости кластеров и росту значения меры (2). Компактность кластера уже не может быть измерена дисперсией, и часто применяемые оценки разделимости, связывающие дисперсию кластеров и расстояние между их центрами, не подходят. Дисперсия становится зависимой от этого расстояния.

**Алгоритм кластеризации текстур.** В работе [3] предложена модификация алгоритма, учитывающая специфику вычисления статистических текстурных признаков. Поиск размера квадратного окна по сбору статистик, одинакового для всего изображения, осуществляется на основе следующих соображений. Начиная с некоторого небольшого значения размер окна постепенно увеличивается. Когда он становится существенно больше элемента или зерна текстуры (в окне начнут действовать законы статистики), значение текстурного признака стабилизируется (не изменяется при дальнейшем увеличении окна). При достаточно большом размере стабилизация признаков будет достигнута для всех текстур изображения. Тогда и кластерные распределения стабилизируются, и число кластеров перестанет меняться. Заметим, что с ростом размера окна наибольшие колебания значений признаков будут наблюдаться на границах кластеров. Поэтому выбор размера окна предложено производить для распределений, лучших по изолированности кластеров, для которых плотность в области границ меньше. Таким образом, для каждого последовательно увеличивающегося размера окна отыскивается лучшее распределение. Как только

число кластеров перестанет меняться с увеличением размера окна, этот размер и выбирается для сбора статистик. Тем самым находится лучшее распределение, число уровней  $n$  и число кластеров  $K(n)$ .

На границах объектов изображения окна по сбору статистик содержат смесь точек соседних текстур, поэтому сегменты границ могут давать дополнительные ложные кластеры. Эти сегменты обычно тонкие. Для индикации ложного кластера предложено [3] вычислять  $d$  — отношение длины границы всех его сегментов к объёму. Чем тоньше сегменты или их больше, или изрезанней их границы, тем больше  $d$ . Если сегменты кластера тоньше окна для сбора статистик, то кластер можно считать ложным. Можно также определить значение порога для его индикации.

Не ложные кластеры назовём основными. Ложные кластеры объединяются с основными по предлагаемому правилу. Сначала отыскиваются два наиболее представительных соседа ложного кластера по изображению. Представительность определяется по длине границы. Для её вычисления карта кластеров, полученная основным алгоритмом, единожды построчно просматривается и суммируется число граничных точек сегментов каждого кластера по вертикали и горизонтали. Затем из этих двух представительных выбирается тот кластер, который слабее отделён от ложного в векторном пространстве. В формуле (1) для ложного кластера суммируются только векторы границы с представительным кластером. Так как сравнение проводится по границам внутри одного кластера, формула (2) может быть переписана в виде

$$m_l^{j_{\text{false}}(n)} = \frac{1}{B_l^{j_{\text{false}}(n)}} \sum_{i=1}^{B_l^{j_{\text{false}}(n)}} h_i^{j_{\text{false}}(n)}, \quad (3)$$

где  $l$  — номер одного из двух кластеров, претендующих на присоединение;  $h_i^{j_{\text{false}}(n)}$  — значение гистограммы в  $i$ -й точке границы ложного кластера  $j_{\text{false}}$  с кластером  $l$ ;  $B_l^{j_{\text{false}}(n)}$  — число точек границы кластера  $j_{\text{false}}$  с кластером  $l$ .

Ложный кластер присоединяется к тому из двух претендентов, на границе с которым значение меры (3) больше и средняя плотность векторов выше.

**Алгоритм объединения последовательности ложных кластеров.** На границах объектов с различной текстурой часто образуется последовательность ложных кластеров, чьи тонкие сегменты заключены между двумя соседними. Обычно они плохо разделены в векторном пространстве. Автоматически выбирается определённое число наиболее крупных и компактных в плоскости изображения кластеров, которое может быть вычислено, если задать другие ограничения, например: по минимальному объёму кластера или по значению максимальной делимости кластера  $m^j(n)$ , или по порогу компактности  $d$ . Выбранные кластеры объявляются основными, и к ним присоединяются остальные (ложные) следующим образом. Рассмотрим последовательно список всех кластеров. Если кластер ложный, то исследуем двух его соседей для присоединения по описанному выше правилу. Если кластер для присоединения окажется основным, то ложный присоединим к нему, иначе начнём выстраивать цепочку ложных кластеров, пока не попадётся основной, и тогда всей цепочке присвоим его номер. Если же цепочка замкнётся, то объявим её новым кластером. В результате работы алгоритма соседние ложные кластеры будут объединены в областях высокой плотности векторов, граница же между объединёнными кластерами будет проходить в областях низкой плотности, следуя принципу кластеризации метода Нарендры.

**Текстурные признаки.** Рассматриваются две системы признаков: статистики Харалика [5] и приближённые параметры авторегрессионной (SAR — Simultaneous Autoregressive) модели стохастического поля [6]. Последние показали бóльшую различительную мощность. В работе [7] эти признаки использовались для автоматической классификации изображения хвойных насаждений леса на аэроснимках. Они позволили различить очень близкие по текстуре, но разные по типу и возрасту насаждения, что не удалось сделать по признакам статистики Харалика. Оценка качества кластерных распределений также показала лучшую изолированность кластеров при классификации по признакам, основанным на SAR-модели. Приведём её краткое описание.

На дискретном изображении  $M \times M$  задан двумерный массив  $\{g(x, y); x, y = 0, 1, \dots, M - 1\}$ . Матрица  $g(x, y)$  находится вычитанием среднего  $T$  из значения уровня серого в каждой точке окна и делением на стандартное отклонение  $D$ . Пусть  $(x = 0, y = 0)$  и  $(x = M - 1, y = M - 1)$  — координаты верхнего левого и нижнего правого углов соответственно. В предположении, что среднее выборки равно нулю,  $g(x, y)$  определяется на тороидальной решётке  $M \times M$  как

$$g(x, y) = \sum_{(i, j) \in N}^{B^j(N)} \theta_{(i, j)} g(x \oplus i, y \oplus j) + \sqrt{\rho_N} \omega(x, y), \quad x, y = 0, 1, \dots, M - 1,$$

где  $N$  — множество соседей пикселя  $(x, y)$  в пространственной области;  $\theta_{(i, j)}$  — коэффициенты модели, характеризующие зависимость уровня серого тона этого пикселя от уровней серого тона соседей;  $\oplus$  — сложение по модулю  $M$ ;  $\omega(x, y)$  — независимые одинаково распределённые гауссовские случайные величины с нулевым средним и единичной дисперсией, характеризующие флуктуации и шум модели;  $\rho_N$  — общая дисперсия шума.

Множество  $N$  состоит из пар целых чисел, соответствующих координатам соседей по отношению к пикселю  $(x, y)$ , исключая  $(0, 0)$ . Общепринятое множество определяется как  $N_1 = \{(1, 0), (0, 1), (-1, 0), (0, -1)\}$ .

Для приближённого вычисления параметров модели использовался метод максимального правдоподобия [6]. Обозначим их значения  $f_N = \{\hat{\theta}_{(i, j)}; (i, j) \in N, \hat{\rho}_N\}$ . Параметры SAR-модели могут интерпретироваться с точки зрения некоторых визуальных свойств текстуры. Величины  $\hat{\theta}_{(i, j)}$  характеризуют направленность текстуры: если выбор множества соседей пикселя таков, что направленность текстуры совпадает с направлением от пикселя к одному из соседей, то соответствующие элементы  $\hat{\theta}_{(i, j)}$  будут больше остальных. Параметр  $\hat{\rho}_N$  имеет прямую связь со степенью зернистости текстуры. Чем больше значение  $\hat{\rho}_N$  образца, тем тоньше текстура.

Текстурное изображение предварительно эквализуется [5]. Признаки  $f_N$  вычисляются для каждой точки изображения по квадратному окну  $M \times M$ . Затем они нормализуются в пределы от 0 до 255.

**Эксперименты.** Изображение лесного ландшафта Западной Сибири на аэроснимке масштаба 1 : 50000 показано на рис. 1, *a*. Размер электронной версии изображения составляет  $582 \times 1374$ , разрешение  $2,5 \times 2,5 \text{ м}^2/\text{пиксель}$ .

Лес на снимке относится к ценнейшему типу зелёномошных кедровников, которые, возобновляясь на горях, проходят путь восстановления за двести лет [8]. Восстановление кедровника происходит в сообществе с берёзой. На ранних стадиях развития преобладает берёза, с возрастом кедр постепенно её вытесняет. Лесоводы определяют шесть фаз развития сообщества, качественно различающихся по внутреннему строению леса и текстуре отображения на снимке. При данном разрешении текстуру леса составляют чередующиеся светлые группы крон берёз (осенняя съёмка) и тёмные — кедровники. На рис. 1, *a* представлены три старшие возрастные фазы развития: 4, 5 и 6 (указаны на картосхеме рис. 1, *b*).

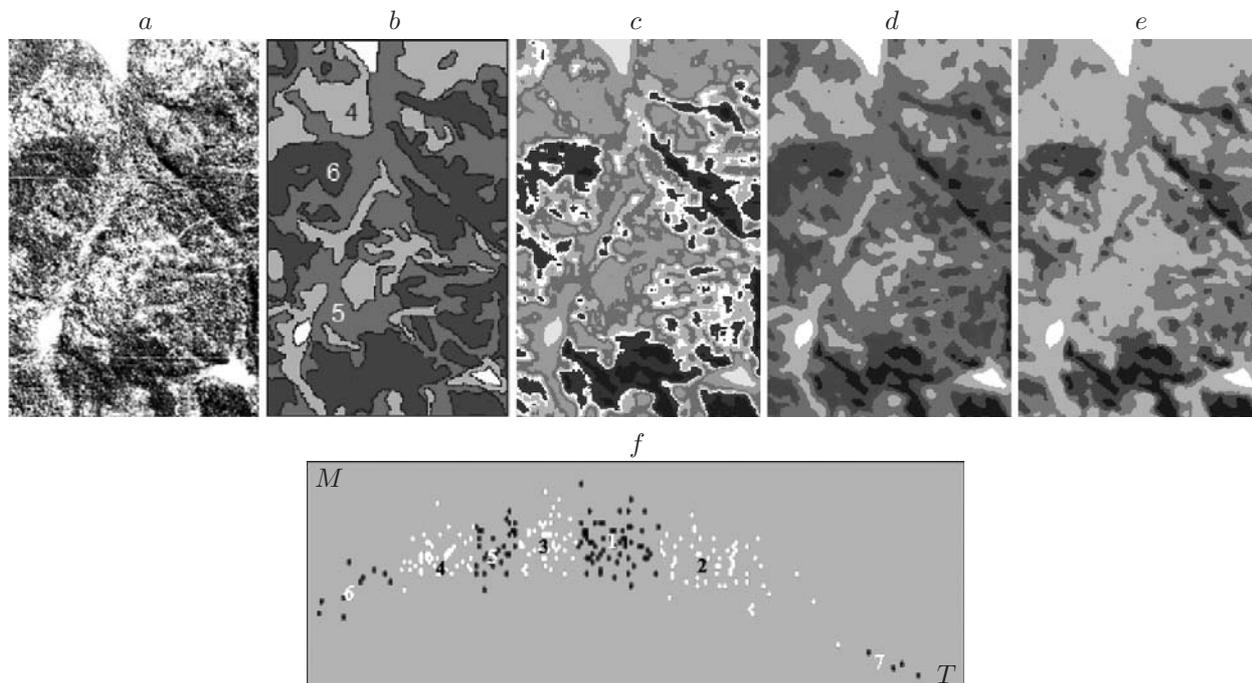


Рис. 1. Автоматическая классификация кедровников Западной Сибири: *a* — аэроснимок кедровников масштаба 1 : 50000; *b* — картосхема наземной таксации; *c* — классификация основным алгоритмом; *d* — кластерная карта при объединении ложных кластеров по разделимости; *e* — кластерная карта при объединении ложных кластеров по расстоянию; *f* — векторная диаграмма в евклидовом пространстве признаков

Три светлых однородных пятна соответствуют болотам. Классификация проводилась по двум текстурным признакам: среднему тону *Tone* ( $T$ ) и средней разности тона Харалика *Mean* ( $M$ ). В результате определён размер окна для сбора статистик  $14 \times 14$ . Лучшее распределение в смысле минимума меры (2)  $M(32) = 0,19$  соответствует двум кластерам, разделяющим область признаков на лес и болото. Распределение для следующего по возрастанию минимума  $M(34) = 0,252$  соответствует семи кластерам.

Диаграмма распределения признаков текстуры (представлена с большим прореживанием векторов) показана на рис. 1, *f*. Предварительная кластерная карта полученных семи унимодальных кластеров дана на рис. 1, *c*. Порог компактности сегментов выбран  $d_0 = 0,28$  (это отношение периметра к площади элементарного сегмента для окна по сбору статистик  $14 \times 14$ ). Для трёх ложных кластеров  $d > d_0$ . Их тонкие сегменты составляют последовательность на границах текстур. Окончательный результат классификации существенно зависит от того, как ложные кластеры объединить с основными, т. е. где будет проведена окончательная граница. По предложенному алгоритму сначала для сегментов ложных кластеров были найдены по два наиболее представительных соседних кластера в плоскости изображения. Для всех ложных кластеров они оказались также соседями в признаковом пространстве. Согласно алгоритму присоединения ложных кластеров кластер 1 объединяется с кластером 3. Ложный кластер 5 — с кластером 4 (а не с ближайшим кластером 3 по евклидову расстоянию между модальными векторами кластеров, как видно на рис. 1, *f*). Окончательно получено пять кластеров. Границы между ними лежат в областях низкой плотности векторов. Классификационная карта представлена на рис. 1, *d*. Каждой возрастной фазе кедровников соответствует один кластер, шестой фазе — два кластера. Если выбирать соседа для присоединения по наименьшему расстоянию между

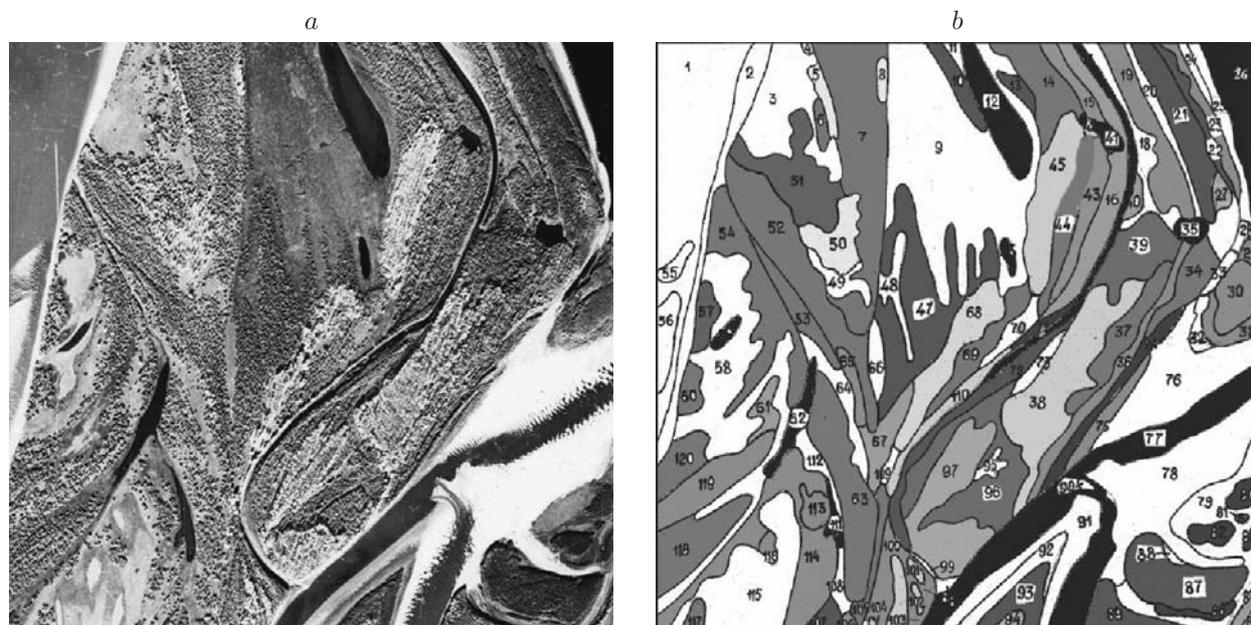


Рис. 2. Автоматическая классификация лиственных лесов: *a* — аэроснимок ландшафта лиственных лесов масштаба 1 : 50000, разрешение  $2,5 \times 2,5 \text{ м}^2/\text{пиксель}$ ; *b* — картосхема наземной таксации: *тополёвники* возраста 25 (27), возраста 45 (101, 102, 103, 104), возраста 50 (38), возраста 50 + *березняки* возраста 30 (45), возраста 65 (97), возраста 75 (68), возраста 150 (4, 5, 8, 50); *ивняки* возраста 10 (23, 29, 30, 31), возраста 20 (71, 74, 80, 81, 82, 83, 86), возраста 25 (22, 87, 89), возраста 30 (21), возраста 65 (39), возраста 30 + 75 (10, 13, 16, 47, 72, 93, 96), возраста 150 + 40 (6, 7, 14, 19, 34, 36, 37, 40, 44, 52, 54, 60, 61, 63, 67, 69, 100, 105, 113, 114, 116, 117, 118, 119, 120); *березняки* возраста 150 (51, 53, 57); *луга* (3, 9, 11, 18, 20, 24, 28, 32, 42, 48, 49, 58, 64, 66, 70, 73, 79, 85, 88, 98, 92, 95, 108, 109, 110, 112, 115); *озёра* (12, 17, 33, 35, 41, 59, 62, 99, 111); *русло реки, вода* (1, 26, 77); *пески* (2, 25, 26, 56, 76, 78, 90, 91)

центрами кластеров, то получится кластерная карта на рис. 1, *e*. Сравнение кластерных карт с картосхемой в пользу предложенного алгоритма.

Более сложное изображение представлено на рис. 2, *a*. Это чёрно-белый аэроснимок ландшафта лиственных ивняков и тополёвников Западной Сибири. Стандартный кадр съёмки, размер электронной версии  $1178 \times 1157$ . Изрезанность границ выделов, большое число различных возрастных фаз лесов характеризуют это изображение. Если для кедровников фаза развития охватывает 20–40 лет, то для лиственных лесов — всего 5–10 лет, а число фаз восстановительной динамики доходит до тридцати. Хотя близкие по возрасту фазы одного типа леса близки и по изображению, опытный дешифровщик способен различить их визуально. На изображении также присутствуют березняки и луга, обладающие собственной текстурой, часто визуально схожей с лесной. На рис. 2, *b* показана картосхема выделов, построенная лесоводами по данным наземной таксации, и описание выделов (возраст леса в годах, в скобках номера выделов). Выдел соответствует насаждениям преобладающего типа и возраста, но может включать определённый процент других типов.

Применяя предложенный алгоритм, удалось автоматически различить практически все типы и состояния покрытия, получив для каждого из них небольшое число кластеров. Для классификации был использован только один признак  $\rho_N$  SAR-модели ( $\rho$  на рис. 3), характеризующий степень зернистости текстуры (так как текстура рассмотренных выделов изотропна), а также средний тон  $T$  и стандартное отклонение  $D$ , которые были исключены при построении матрицы  $g(x, y)$ . В результате классификации основным алгоритмом

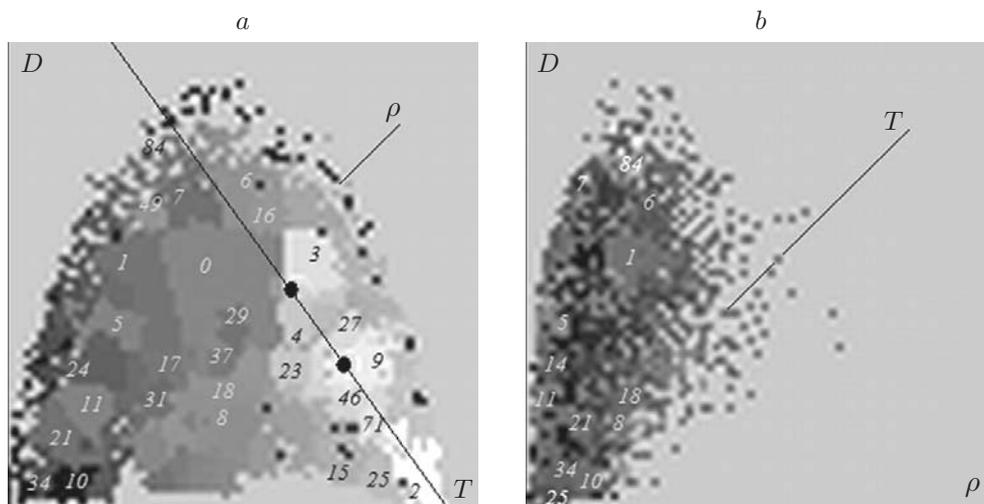


Рис. 3. Проекция кластерной диаграммы на плоскости:  $a — \{D, T\}$ ,  $b — \{D, \rho\}$

по трём признакам были получены: размер окна  $16 \times 16$ , минимум меры (2)  $M(61) = 0,38$  для диапазона изменения  $40 < n < 255$ . Число кластеров  $K(61) = 528$ . Для числа уровней квантования  $n$  меньше 40 векторы, соответствующие некоторым возрастным фазам ивняков и березняков, не разделяются.

Проекция трёхмерной кластерной диаграммы на плоскости  $\{D, T\}$  и  $\{D, \rho\}$  показаны на рис. 3,  $a, b$ . Ось, соответствующая третьему признаку, направлена от зрителя. Расцветка кластеров непрозрачная, т. е. ближайшие к зрителю кластеры по третьему признаку экранируют более удалённые, с бóльшим значением этого признака. Крупные и интересные кластеры пронумерованы курсивным шрифтом. Кластеры левой части рис. 3,  $a$  соответствуют ивнякам, кластеры правой части (светло-серые) — тополёвникам. В верхней части кластеры (например, 7, 6, 16) соответствуют березнякам. В нижней части слева — кластеры (34, 10), относящиеся к наиболее тёмным и слаботекстурным водным поверхностям. В нижней части посередине — кластеры (18, 8) разнотравных лугов, в нижней части справа — кластеры (15, 25, 2) светлых песков. Для того чтобы показать плотность данных, диаграммы рис. 3 построены с прореживанием выводимых точек (через 50). Благодаря этому видно, что больших, компактных кластеров относительно немного, но они

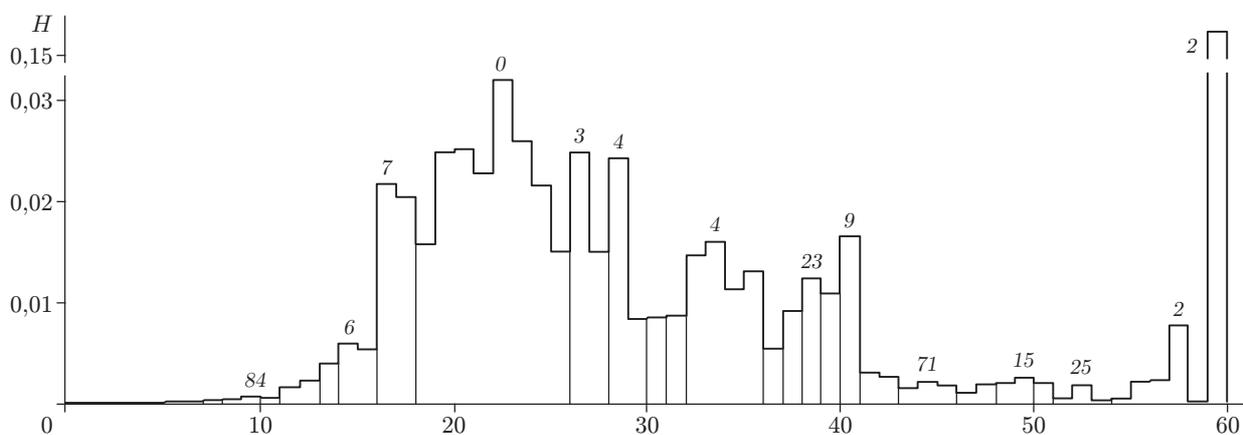


Рис. 4. Профиль трёхмерной гистограммы по линии, проходящей через модальные векторы кластеров 3 и 9

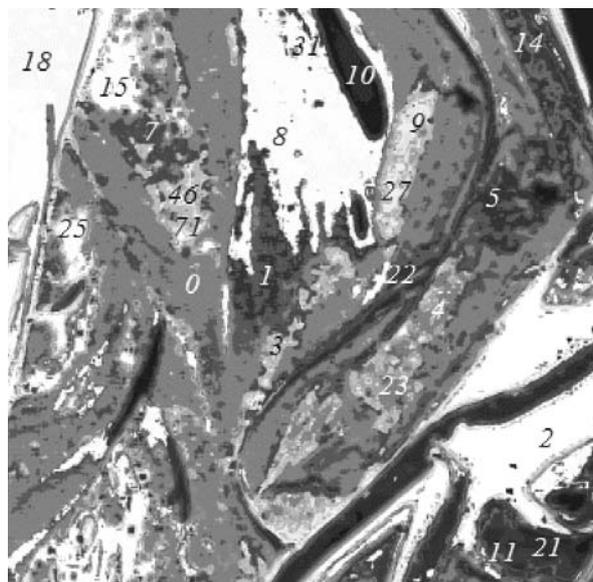


Рис. 5. Кластерная карта

плотные и составляют основной объём данных. Вокруг них видна масса менее плотных кластеров. Они показаны тёмным цветом. Эти кластеры составляют большинство, хотя по объёму в них мало данных. В основном они являются тонкими ложными кластерами. Однако даже мелкие кластеры расположены плотно, гистограмма почти не имеет нулевых значений. Трёхмерную гистограмму отобразить невозможно, но чтобы получить представление о поведении функции, покажем её профиль (рис. 4) вдоль прямой, проходящей через модальные векторы кластеров 3 и 9, относящихся к ивнякам. (Проекция этой прямой на плоскость  $\{D, T\}$  показана на рис. 3, а.) По оси абсцисс последовательно пронумерованы воксели, через которые проходит эта прямая в трёхмерном пространстве признаков, сверху вниз и слева направо. Их число 61 равно полученному числу уровней квантования векторного пространства. По оси ординат показаны значения гистограммы  $H$ . Тонкие вертикальные линии проведены между пронумерованными унимодальными кластерами. Жирные линии обозначают разделы между окончательно построенными кластерами после присоединения ложных к основным.

Вышеописанный алгоритм объединения тонких кластеров автоматически выбрал 100 крупных кластеров с наиболее компактными сегментами в плоскости изображения и присоединил к ним остальные. При этом было выделено ещё пять дополнительных кластеров. В результате окончательной классификации каждый из описанных лесоводами информационных классов согласно картосхеме на рис. 2, б (семь возрастов тополёвников, семь ивняков и т. д.) оказался представлен несколькими (от одного до трёх) только своими кластерами. Признак  $\rho_N$  имеет большие значения для разнотравных лугов, чем для леса, соответствуя мелкой, более зернистой текстуре. Луга также представлены собственными кластерами.

Карта окончательной классификации показана на рис. 5: лесу соответствует 44 кластера из 105. Цвет кластера на этой карте устанавливается с учётом раскраски картосхемы выделов.

**Заключение.** В основе использованного алгоритма кластеризации данных дистанционного зондирования лежит быстрый непараметрический гистограммный метод деления векторного пространства по унимодальным кластерам (метод Нарендры). Он применялся совместно с предварительным квантованием признакового пространства, однако процеду-

ра выбора числа уровней квантования не была формализована. Использованный алгоритм автоматизирует выбор числа уровней, отыскивая минимумы меры изолированности кластеров и соответствующие минимумам лучшие кластерные распределения. В данной работе алгоритм был дополнен методом объединения последовательности ложных кластеров, возникающих на границах текстур по принципу плохой изолированности в векторном пространстве, с учётом близости их сегментов в плоскости изображения. Границы полученных объединённых кластеров проходят по областям низкой плотности векторов согласно алгоритму Нарендры. Алгоритм использует меру качества классификации, пригодную для тесно расположенных унимодальных кластеров. В результате классификации рассмотренных изображений лесных ландшафтов на аэроснимках по текстурным признакам получено, что каждому из представленных типов (и возрастов) леса соответствует небольшое число кластеров (1–3), но каждый тип представлен своим набором кластеров. (Цветные кластерные карты можно увидеть на сайте <http://loi.sccc.ru/lab/RFFI10/RU/svs10.htm>.) Анализ показал, что различение типов лесных покрытий по текстурным признакам аэроснимка не уступает точности наземной таксации.

### СПИСОК ЛИТЕРАТУРЫ

1. **Сидорова В. С.** Оценка качества классификации многоспектральных изображений гистограммным методом // *Автометрия*. 2007. **43**, № 1. С 37–43.
2. **Narendra P. M., Goldberg M.** A non-parametric clustering scheme for LANDSAT // *Pattern Recogn.* 1977. **9**, N 4. P. 207–215.
3. **Sidorova V. S.** Unsupervised classification of image texture // *Pattern Recogn. Image Analys.* 2008. **18**, N 4. P. 694–700.
4. **Halkidi M., Batistakis Y., Vazirgiannis M.** On clustering validation techniques // *Journ. Intel. Inform. Syst.* 2001. **17**, N 2–3. P. 107–145.
5. **Haralick R. M., Shanmugam K., Dinstein I.** Textural features for image classification // *IEEE Trans. Syst. Man. Cybern.* 1973. **SMS-3**. P. 610–621.
6. **Kashyap R. L., Chellapa R.** Estimation and choice of neighbors in spatial interaction models of images // *IEEE Trans. Inform. Theory*. 1983. **29**, N 1. P. 60–72.
7. **Sidorova V. S.** Unsupervised classification of a forest's image by texture model features // *Pattern Recogn. Image Analys.* 2009. **19**, N 4. P. 698–703.
8. **Седых В. Н.** Формирование кедровых лесов Приобья. Новосибирск: Наука, 1979. 109 с.

*Поступила в редакцию 1 июня 2010 г.*

---