

МЕТОДЫ И СИСТЕМЫ АВТОМАТИЗАЦИИ. ОБРАБОТКА ДАННЫХ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ

УДК 528.85; 621.396

К.Т. Протасов

ВЫДЕЛЕНИЕ ПОЛЕЙ ОДНОРОДНОСТИ НА КОСМИЧЕСКИХ СНИМКАХ НЕПАРАМЕТРИЧЕСКИМ АЛГОРИТМОМ СЕГМЕНТАЦИИ В ПРОСТРАНСТВАХ ИНФОРМАТИВНЫХ ПРИЗНАКОВ

Разработан новый комбинированный непараметрический алгоритм сегментации многоспектральных космических снимков подстилающей поверхности Земли и облачности, основанный на четырехэтапной процедуре. На первом шаге производится пофрагментная локальная кластеризация видеоданных с использованием расстояния Бхаттачария или дивергенции Кульбака, на втором шаге объединяются ближайшие из найденных классов с использованием функционала эмпирического риска, на третьем шаге укрупненные классы служат материалом обучения непараметрического 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 на непараметрических оценках неизвестных условных вероятностных распределений. Кроме того, решается задача исследования комплексов признаков на информативность в смысле минимума критерия эмпирического риска.

Введение

При решении задач природопользования, климато-экологического мониторинга и оценивания состояний 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 [1–4]. Наличие облачности является мешающим фактором, и лишь выделив эти участки изображения, следует решать задачу выделения классов текстурной однородности видеоданных, относящихся к подстилающей поверхности Земли.

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 изображений, основанный на поиске мод смешивающих распределений с последующим укрупнением классов с помощью расстояний Бхаттачария или информационного критерия Кульбака. На втором этапе объединяются полученные классы всех фрагментов в более крупные блоки с использованием эмпирического риска. На третьем этапе происходит обучение алгоритма распознавания образов выявлять классы, полученные на втором шаге агрегирования данных и исследуются комплексы признаков на информативность. Наконец, на четвертом шаге обученным решающим правилом происходит распознавание компонентов 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 служит непараметрическая оценка функционала риска, либо непараметрические оценки границ этого функционала, а вероятностные модели классов восстанавливаются с помощью непараметрических аппроксимаций неизвестных условных функций плотности.

Математические основы синтеза алгоритмов распознавания образов

Вначале рассмотрим вопросы, связанные с построением алгоритмов автоматической классификации и приведем основные математические соотношения синтеза алгоритмов распознавания образов, используемые в дальнейшем [1–5, 8].

Пусть результатом наблюдения является совокупность оцифрованных полей видеоданных, заданных 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; $\mathbf{X} \in R^n \equiv \chi$, 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 смешивающей функции плотности вероятностей:

$$f(\mathbf{x}) = \sum_{v \in \mathcal{L}} P(v) f_v(\mathbf{x}; \theta_v), v \in \mathcal{L} \equiv \{1, \dots, L\}, \quad (1)$$

где и \mathcal{L} – пространство классов, L – число классов, и $f_v(\mathbf{x}; \theta_v)$ – условная одномодальная параметрическая (с вектором параметров $\theta_v \in R^{m_v}$, m_v – размерность пространства параметров) функция плотности класса v , и $P(v)$ – вес функции плотности $f_v(\mathbf{x}; \theta_v)$ в смеси, имеющей смысл априорной вероятности появления класса v ; $\sum_{v \in \mathcal{L}} P(v) = 1$, неизвестны. Задача заключается в том, чтобы по имеющейся неклассифицированной выборке наблюдений $\mathbf{X}_1, \dots, \mathbf{X}_N$ объема N идентифицировать все компоненты смеси (1) $\{L, P(v), f_v(\mathbf{x}; \theta_v), v \in \mathcal{L}\}$.

Следует заметить, что задача восстановления компонент смеси (1) имеет решение лишь в случае её идентифицируемости [1–3]. 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 $f_v(\mathbf{x}; \theta_v)$, которые и являются моделями искомого классов. В такой общей постановке задача поиска неизвестных параметров θ_v и других компонент выражения (1), например методом максимального правдоподобия, безнадежно громоздка. Если в качестве $f(\mathbf{x})$ воспользоваться непараметрическими оценками неизвестных распределений, то задача лишь усложнится.

Предположим, что декомпозиция смеси (1) каким-либо образом произведена и соответствующие параметрические вероятностные меры $f(\mathbf{x}/v)$, $v \in \mathcal{L}$, восстановлены. Тогда задачу построения решающих правил распознавания образов с оценкой их качества можно сформулировать следующим образом. В евклидовом n -мерном пространстве наблюдений R^n и пространстве гипотез $\mathcal{L} \equiv \{1, \dots, L\}$ определены вероятностные меры с априорными распределениями ситуаций $P(v)$, условными функциями плотности вероятностей $f(\mathbf{x}/v)$, случайного вектора наблюдений $\mathbf{X} \in R^n \equiv \chi$, $v \in \mathcal{L}$ и простая матрица потерь $1 - \delta_{v\mu}$, где $\delta_{v\mu}$ – символ Кронекера, $v, \mu \in \mathcal{L}$. Тогда качество предполагаемой классификации можно оценить минимумом средних потерь или минимумом средних ошибок распознавания (минимумом функционала риска)

$$r = \sum_{v \in \mathcal{L}} \int_{R^n} P(v) f(\mathbf{x}/v) \left[1 - \prod_{\mu \in \mathcal{L}} E\{I_{v\mu}(\mathbf{x})\} \right] d\mathbf{x}, \quad (2)$$

$$E\{t\} = \begin{cases} 1, & t \geq 0, \\ 0, & t < 0; \end{cases}$$

где $I_{v\mu}(\mathbf{x}) = P(v)f(\mathbf{x}/v) - P(\mu)f(\mathbf{x}/\mu) \geq 0$; $\forall \mu \in \mathcal{L}$, $\mu \neq v$, \mathcal{L} – пространство классов, $\mathcal{L} \equiv \{1, \dots, L\}$, L – число классов, при их нумерации натуральным рядом. В этом случае для простой матрицы потерь это есть усредненная вероятность ошибки, доставляемая байесовым решающим правилом $I_{v\mu}(\mathbf{x})$. Декомпозиция в (1) может быть произведена другим, непараметрическим, путем, а именно указанием классов, которым принадлежат те или иные выборочные значения смешанной выборки, представленной отдельными классами $\mathbf{X}_1^v, \dots, \mathbf{X}_{N_v}^v$, $v \in \mathcal{L}$. В этом случае, при известных $f(\mathbf{x}/\mu)$, средний риск (2) естественно оценить эмпирическим риском, а именно

$$\hat{r} = \sum_{v \in \mathcal{L}} \frac{1}{N_v} \sum_{j=1}^{N_v} P(v) I \{v = \arg \max_{\mu \in \mathcal{L}} P(\mu) f(\mathbf{X}_j^v/\mu)\}, \quad (3)$$

где $I \{ \text{«истина»} \} = 0$; $I \{ \text{«ложь»} \} = 1$ – характеристическая функция; N_v – объем выборки класса $v \in \mathcal{L}$, а

$$u(\mathbf{x}) = \arg \max_{\mu \in \mathcal{L}} P(\mu) f(\mathbf{x}/\mu) \quad (4)$$

– байесово решающее правило в иной, тождественной записи, $u(\mathbf{x})$ – принимаемое решение (в простейшем случае решениями могут быть элементы из \mathcal{L}), $u \in \mathcal{L}$.

Если в качестве неизвестных условных функций плотности $f(\mathbf{x}/\mu)$, $\mu \in \mathcal{L}$ использовать их непараметрические оценки $\hat{f}(\mathbf{x}/\mu)$ по обучающим последовательностям $\mathbf{X}_1^\mu, \dots, \mathbf{X}_{N_\mu}^\mu$, $\mu \in \mathcal{L}$, то эмпирический риск (3), для целей экономии выборки, подсчитывается методом «скользящего» контроля следующим образом. Когда в выражении (3) при $v = \mu$ подсчитывается $\hat{f}(\mathbf{x}/v = \mu)$ в точке $\mathbf{x} = \mathbf{X}_j^v$, последняя исключается из выборочных значений, по которым, собственно, оценивается $\hat{f}(\mathbf{x}/v)$. В качестве непараметрических оценок неизвестных функций плотности будем использовать следующие две оценки, отличающиеся типом ядра. Так, оценка с гауссовым ядром имеет следующее выражение:

$$\hat{f}(\mathbf{x}/v) = \frac{1}{N_v} \sum_{j=1}^{N_v} (2\pi)^{-n/2} |\hat{R}_v|^{-1/2} h_v^{-n} \times \exp \left\{ -\frac{1}{2h_v^2} (\mathbf{x} - \mathbf{X}_j^v)^T \hat{R}_v^{-1} (\mathbf{x} - \mathbf{X}_j^v) \right\}, \quad (5)$$

где \hat{R}_v – ковариационная матрица (выборочная оценка); T – знак транспонирования; h_v – параметр сглаживания, обладающий свойствами, обеспечивающими

асимптотическую сходимость $\hat{f}(\mathbf{x}/v)$ к соответствующей функции плотности [1–3]. В другом случае для повышения быстродействия вычислений будем использовать ядро Епанечникова с «внутренней» системой координат, обеспечивающей разворот эллипса рассеяния, согласованный с рассеянием выборочных данных [6, 7]:

$$\hat{f}(\mathbf{x}/v) = \frac{1}{N_v} \sum_{j=1}^{N_v} \prod_{i=1}^n \left\{ \frac{1}{\lambda_n^{1/2} h_v} \left[a - b \frac{(\mathbf{g}_i^T (\mathbf{x} - \mathbf{X}_j^v))^2}{\lambda_n^i h_v^2} \right] \right\}, \quad (6)$$

где введена следующая вспомогательная система координат:

$$\mathbf{u} = G\mathbf{x}, \quad M[\mathbf{U}\mathbf{U}^T] = GM[\overset{\circ}{\mathbf{X}}\overset{\circ}{\mathbf{X}}^T]G^T = G\hat{R}_v G^T = \Lambda,$$

$$\Lambda = \begin{pmatrix} \lambda^1 & & 0 \\ & \ddots & \\ 0 & & \lambda^n \end{pmatrix}, \quad G = \begin{pmatrix} \mathbf{g}_1^T \\ \vdots \\ \mathbf{g}_n^T \end{pmatrix},$$

G – матрица декоррелирующего ортогонального преобразования; $M[\cdot]$ – оператор математического ожидания; $\overset{\circ}{\mathbf{X}}$ – центрированные наблюдения; Λ – диагональная матрица собственных значений; $a = 3/4\sqrt{5}$; $b = a/5$. Особенность модифицированного ядра Епанечникова заключается в том, что единый параметр сглаживания для всех размерностей пространства наблюдений масштабируется по координатам собственными значениями λ_i , $i = 1, \dots, n$, оценочной ковариационной матрицы \hat{R}_v .

При использовании непараметрических оценок неизвестных распределений (5), (6) остается недоопределенным параметр сглаживания h_v , $v \in \mathcal{L}$; таким образом, появляется возможность дополнительной адаптации вероятностных моделей образов к конкретным условиям наблюдений и обучающим выборкам. Наиболее естественным, хотя и достаточно громоздким в вычислительном плане, подходом к определению параметров сглаживания является способ, основанный на минимизации функционала риска (эмпирического риска) по набору параметров сглаживания с учетом многоэкстремальности, недифференцируемости этого функционала. В связи с этим рассмотрим следующую двухэтапную процедуру поиска глобального экстремума функционала (3). На первом этапе в области поиска, представляющем собой многомерный квадрат

$$\prod_{v=1}^L [h_{\min}^v, h_{\max}^v], \quad v \in \mathcal{L},$$

где h_{\min} и h_{\max} – нижняя и верхняя оценочные границы параметра сглаживания соответственно, случайно с равномерным распределением «бросается» точка, затем из этой точки осуществляется градиентный спуск, при этом используются поисковые методы

адаптации [8]. С этой целью осуществляется вариация функционала качества (3) по параметрам сглаживания следующим образом. Вычисляются значения приращений функционала

$$r_+[\mathbf{h}, a] = (r[\mathbf{h} + a\mathbf{e}_1], \dots, r[\mathbf{h} + a\mathbf{e}_L]),$$

$$r_-[\mathbf{h}, a] = (r[\mathbf{h} - a\mathbf{e}_1], \dots, r[\mathbf{h} - a\mathbf{e}_L]),$$

где L – количество параметров h , соответствующих количеству классов и собранных в вектор параметров $\mathbf{h} = (h^1, \dots, h^L)^T$; a – скалярный параметр, определяющий величину поискового шага; $\mathbf{e}_i = \begin{pmatrix} 0, \dots, 1, \dots, 0 \end{pmatrix}^T$,

$i = 1, \dots, L$ – базисные векторы поисковых направлений.

Оценочное значение градиента вычислим следующим образом:

$$\frac{r_+[\mathbf{h}, a] - r_-[\mathbf{h}, a]}{2a} = \nabla_{h^\pm} r[\mathbf{h}, a],$$

где ∇_{h^\pm} – обозначение градиента. Поисковый алгоритм адаптации в рекуррентной форме имеет вид

$$\mathbf{h}[j] = \mathbf{h}[j-1] - \gamma[j] \nabla_{h^\pm} r[\mathbf{h}[j-1], a[j]], \quad (7)$$

выбор поискового $a[\cdot]$ и рабочего $\gamma[\cdot]$ шага рассмотрен в [8], причем $\gamma[\cdot] < a[\cdot]$.

Следует заметить, что функционал риска является единственным функционалом, адекватным задаче оценивания качества решающих правил распознавания образов, однако для аналитических и численных методов синтеза оптимальных решающих правил достаточно громоздок. В связи с этим рассмотрим более простые критерии оценивания качества распознающих систем.

Риск для распознавания двух образов $\mu, v \in \mathcal{L}$, когда задана простая матрица потерь, совпадает с усредненной ошибкой распознавания и ограничен сверху следующей величиной ε , называемой границей Чернова [2]:

$$r \leq [P(\mu)P(v)]^{1/2} \exp \left\{ -\beta_h \left(\frac{1}{2} \right) \right\} = \varepsilon, \quad (8)$$

где $\beta_h \left(\frac{1}{2} \right) = -\ln \int_c [f(\mathbf{x}/\mu)f(\mathbf{x}/v)]^{1/2} d\mathbf{x}$ – расстояние

Бхаттачария.

Вероятность ошибки можно представить через вариационное расстояние Колмогорова

$$2r = 1 - \int_x |P(\mu)f(\mathbf{x}/\mu) - P(v)f(\mathbf{x}/v)| d\mathbf{x}.$$

Используя неравенство Шварца, можно получить и границу снизу для вероятности ошибки r :

$$\frac{1}{2} - \frac{1}{2}(1 - 4\varepsilon^2)^{1/2} \leq r \leq \varepsilon; \quad (9)$$

если ε мало, то $\varepsilon^2 \leq r \leq \varepsilon$. Границы Чернова и расстояние Бхаттачария обладают всеми необходимыми свойствами критериев разделимости условных вероятностных распределений, являющихся моделями образов.

Рассмотрим следующий вариант оценивания расстояния Бхаттачария, основанного на технологии интегрирования функционалов по эмпирическим распределениям [9]. В симметричной записи интеграл в выражении для расстояния Бхаттачария имеет следующий вид:

$$\begin{aligned}
 2 \int_{\mathcal{C}} [f(\mathbf{x}/\mu) f(\mathbf{x}/\nu)]^{1/2} d\mathbf{x} &\cong \int_{\mathcal{C}} \left[\frac{f(\mathbf{x}/\mu)}{f(\mathbf{x}/\nu)} \right]^{1/2} dF_M(\mathbf{x}/\nu) + \int_{\mathcal{C}} \left[\frac{f(\mathbf{x}/\nu)}{f(\mathbf{x}/\mu)} \right]^{1/2} dF_N(\mathbf{x}/\mu) \cong \\
 &\cong \frac{1}{N_\nu} \sum_{j=1}^{N_\nu} \left\{ \frac{\frac{1}{N_\mu} \sum_{i=1}^{N_\mu} (2\pi)^{-n/2} |\hat{R}_\mu|^{-1/2} h_\mu^{-n} \exp \left\{ -\frac{1}{2 h_\mu^2} \rho_\mu(\mathbf{X}_j^\nu, \mathbf{X}_i^\mu) \right\}}{\frac{1}{N_\nu - 1} \sum_{\substack{i=1 \\ i \neq j}}^{N_\nu} (2\pi)^{-n/2} |\hat{R}_\nu|^{-1/2} h_\nu^{-n} \exp \left\{ -\frac{1}{2 h_\nu^2} \rho_\nu(\mathbf{X}_j^\nu, \mathbf{X}_i^\nu) \right\}} \right\}^{1/2} + \\
 &+ \frac{1}{N_\mu} \sum_{j=1}^{N_\mu} \left\{ \frac{\frac{1}{N_\nu} \sum_{i=1}^{N_\nu} (2\pi)^{-n/2} |\hat{R}_\nu|^{-1/2} h_\nu^{-n} \exp \left\{ -\frac{1}{2 h_\nu^2} \rho_\nu(\mathbf{X}_j^\mu, \mathbf{X}_i^\nu) \right\}}{\frac{1}{N_\mu - 1} \sum_{\substack{i=1 \\ i \neq j}}^{N_\mu} (2\pi)^{-n/2} |\hat{R}_\mu|^{-1/2} h_\mu^{-n} \exp \left\{ -\frac{1}{2 h_\mu^2} \rho_\mu(\mathbf{X}_j^\mu, \mathbf{X}_i^\mu) \right\}} \right\}^{1/2}, \quad (10)
 \end{aligned}$$

где $F_M(\mathbf{x}/\nu)$ – эмпирическая функция распределения [6, 9]. В (10) введена функция расстояния

$$\rho_\mu(\mathbf{X}_j^\nu, \mathbf{X}_i^\mu) = (\mathbf{X}_j^\nu - \mathbf{X}_i^\mu)^T \hat{R}_\mu^{-1} (\mathbf{X}_j^\nu - \mathbf{X}_i^\mu). \quad (11)$$

Таким образом, наравне с риском, точнее, эмпирическим риском, непараметрическая оценка расстояния Бхаттачария может служить мерой разделимости образов.

Теперь рассмотрим другую меру близости вероятностных моделей образов, аналогичную расстоянию Бхаттачария. При построении решающих правил распознавания образов фундаментальную роль играют отношение правдоподобия либо монотонные преобразования этого отношения, например $\ln \{f(\mathbf{x}/\mu)/f(\mathbf{x}/\nu)\}$. В связи с этим эффективной мерой разделимости классов является дивергенция Кульбака [10], обладающая всеми нужными свойствами расстояний. Используя технологию интегрирования по эмпирическим распределениям [9] и подставляя в выражение для дивергенции непараметрические оценки неизвестных функций плотности по выборкам, получим

$$\begin{aligned}
 D &= \int_{\mathcal{X}} \ln \frac{f(\mathbf{x}/\mu)}{f(\mathbf{x}/\nu)} dF_M(\mathbf{x}/\mu) - \int_{\mathcal{X}} \ln \frac{f(\mathbf{x}/\mu)}{f(\mathbf{x}/\nu)} dF_N(\mathbf{x}/\nu) \cong \\
 &\cong \frac{1}{N_\mu} \sum_{j=1}^{N_\mu} \ln \frac{\frac{1}{N_\mu - 1} \sum_{\substack{i=1 \\ i \neq j}}^{N_\mu} (2\pi)^{-n/2} |\hat{R}_\mu|^{-1/2} h_\mu^{-n} \rightarrow}{\frac{1}{N_\nu} \sum_{\substack{i=1 \\ i \neq j}}^{N_\nu} (2\pi)^{-n/2} |\hat{R}_\nu|^{-1/2} h_\nu^{-n} \rightarrow}
 \end{aligned}$$

$$\begin{aligned}
 &\rightarrow \exp \left\{ -\frac{1}{2 h_\mu^2} \rho_\mu(\mathbf{X}_j^\mu, \mathbf{X}_i^\mu) \right\} \\
 &\rightarrow \exp \left\{ -\frac{1}{2 h_\nu^2} \rho_\nu(\mathbf{X}_j^\mu, \mathbf{X}_i^\nu) \right\} \\
 &\frac{1}{N_\mu} \sum_{i=1}^{N_\mu} (2\pi)^{-n/2} |\hat{R}_\mu|^{-1/2} h_\mu^{-n} \rightarrow \\
 &-\frac{1}{N_\nu} \sum_{j=1}^{N_\nu} \ln \frac{\frac{1}{N_\mu} \sum_{\substack{i=1 \\ i \neq j}}^{N_\mu} (2\pi)^{-n/2} |\hat{R}_\mu|^{-1/2} h_\mu^{-n} \rightarrow}{\frac{1}{N_\nu - 1} \sum_{\substack{i=1 \\ i \neq j}}^{N_\nu} (2\pi)^{-n/2} |\hat{R}_\nu|^{-1/2} h_\nu^{-n} \rightarrow} \\
 &\rightarrow \exp \left\{ -\frac{1}{2 h_\mu^2} \rho_\mu(\mathbf{X}_j^\nu, \mathbf{X}_i^\mu) \right\} \\
 &\rightarrow \exp \left\{ -\frac{1}{2 h_\nu^2} \rho_\nu(\mathbf{X}_j^\nu, \mathbf{X}_i^\nu) \right\}. \quad (12)
 \end{aligned}$$

Заметим, что аналогичным образом в выражениях (10) и (12) могут быть использованы непараметрические оценки распределений с ядром Епанечникова (6).

Таким образом, наравне с непосредственным критерием отделимости распознаваемых классов (3) получены оценки более простых критериев (10) и (12), обладающие свойством «гладкости», что упрощает решение тех или иных оптимизационных задач.

Теперь перейдем непосредственно к изложению этапов построения алгоритма сегментации. В начале остановимся на проблеме выбора материала обучения.

Выбор локальных фрагментов и формирование материала обучения

При решении задачи сегментации больших массивов видеоданных возникает проблема выбора фрагментов, по которым производится обучение алгоритма распознавания образов. От качества этого обучения в большей степени зависит и качество классификации всего изображения. В связи с этим набор фрагментов материала обучения должен быть задан из тех соображений, чтобы он отражал разнообразие всего поля видеоданных. Другими словами, небольшой набор фрагментов должен отражать статистические свойства всей генеральной совокупности данных. В одном из вариантов работы алгоритма выбор фрагментов на большом изображении может быть предоставлен интуиции оператора или задан случайным механизмом.

Остановимся на возможности выбора материала обучения, в какой-то мере «очищенного» от смешанных пикселей. Заметим, что одна из причин многообразия выделяемых классов заключается, с одной стороны, в многообразии состояний природных образований, а с другой – в появлении большого количества смешанных пикселей, порождаемых плохим разрешением систем сканирования. Например, для спутника серии NOAA и прибора AVHRR разрешение в надире составляет всего лишь 1,1 км × 1,1 км и, если при аэрофотосъемке ландшафтов фация считается наименьшей наблюдаемой единицей [13], то можно предположить, что на площади 1,1 км × 1,1 км может быть сосредоточено большое количество и разнообразие элементарных ландшафтных форм, что и приводит к появлению смешанных пикселей, являющихся интегральными характеристиками реальных ситуаций. В связи с этим целесообразно при формировании материала обучения выбирать не фрагменты данных, а попытаться выделить некоторые участки со стационарным поведением радиояркостей. По-видимому, можно сформулировать гипотезу о том, что стационарный участок радиояркостей соответствует и стационарному ландшафтному образованию, выделение портрета которого и является нашей целью. В связи с этим целесообразно ввести в материал обучения именно эти квазистационарные участки изображения. Такую задачу можно решить путем пространственного дифференцирования видеоданных с последующим выделением участков с малым и близким к нулю градиентом.

Поиск локальных мод смешивающего распределения (первый этап алгоритма)

Снова обратимся к выражению (1). Пусть верна гипотеза о том, что задача идентификации смеси имеет решение, означающее, что смешивающее распределение многомодально, каждая мода является претендентом на собственный класс, который будем

называть подклассом или локальным классом. Таким образом, возникает первоочередная задача поиска локальных мод смешивающего распределения (1). В терминах выборки, состоящей из представителей всех классов, это означает поиск локальных скоплений, сгустков выборочных значений в общей массе данных материала обучения X_1, \dots, X_N , полученных с фрагмента видеоданных. Основная идея формирования алгоритма поиска локальных мод заключается в том, что в окрестности каждой локальной моды, по определению, сосредоточено большее количество выборочных значений, нежели в соседствующих областях. Если задать некоторый элементарный объем, описываемый, например, эллипсоидом рассеяния, и перемещать этот объем – эллипсоид по выборочному пространству, фиксируя количество точек, попадающих в этот объем, то наибольшее количество выборочных векторов окажется в нем в случае, когда центр поискового эллипсоида близок к локальной моде смешивающего распределения. Вопросы сходимости такого алгоритма поиска мод рассмотрены в [11]. Следует заметить, что количество направлений движения поискового эллипсоида резко возрастает с увеличением размерности пространства наблюдений. В упрощенном варианте естественно оценивать каждую локальную моду ближайшим выборочным вектором. Таким образом, центр поискового эллипсоида следует помещать лишь в точках смешанной выборки X_1, \dots, X_N и оценивать число ближайших соседей, попавших в эллипсоид, что существенно упрощает задачу. Для формирования функции расстояния (11) между выборочными наблюдениями оценим ковариационную матрицу с использованием всей смешанной выборки X_1, \dots, X_N :

$$\hat{R} = \frac{1}{N} \sum_{i=1}^N (X_i - \hat{\mu})(X_i - \hat{\mu})^T,$$

где $\hat{\mu}$ – оценочное математическое ожидание по этой же выборке. Обобщенную функцию расстояния определим следующим образом:

$$\rho(x, y) = (x - y)^T \hat{R}^{-1} (x - y), \quad (13)$$

где x и y замещаются наблюдениями из выборки X_1, \dots, X_N .

Возьмем в качестве ядра восстанавливаемой непараметрической оценки неизвестной функции плотности, для определенности, ядро Гаусса и зададим границы параметров сглаживания, полученные из соображений, связанных с максимизацией функционала правдоподобия, а точнее эмпирической оценкой функционала энтропии [12]:

$$h_{\min} = \sqrt{\frac{\sum_{i=1, i \neq j}^N \min \rho(X_i, X_j)}{N n}},$$

$$h_{\max} = \sqrt{\frac{\sum_{i=1}^N \max_{\{j\}} \rho(\mathbf{X}_i, \mathbf{X}_j)}{Nn}}, \quad (14)$$

где h_{\min} и h_{\max} – оценочные границы параметра сглаживания, записанные без индекса принадлежности к классу. Будем помещать «центр» с точкой \mathbf{Y} ядерной функции

$$f(\mathbf{x}) = (2\pi)^{-n/2} |\hat{R}|^{-1/2} h_{\min}^{-n} \exp\left\{-\frac{1}{2h_{\min}^2} \rho(\mathbf{X}, \mathbf{Y})\right\} \quad (15)$$

последовательно в каждую из выборочных точек $\mathbf{X}_1, \dots, \mathbf{X}_N$, $\mathbf{Y} \in \{\mathbf{X}_1, \dots, \mathbf{X}_N\}$ и в каждом таком положении будем оценивать количество выборочных значений, попавших в окрестность центральной точки \mathbf{Y} , причем окрестность определяется некоторым уровнем Δ , так что $\{\mathbf{X}: f(\mathbf{X}_j) \geq \Delta\}$, где Δ – уровень значимости области влияния.

Обозначим выделенный на первом шаге набор максимального объема N_1 выборочных значений $\mathbf{X}_1^1, \dots, \mathbf{X}_{N_1}^1$, попавших в Δ -окрестность, и удалим эти значения из общей выборки. Оставшуюся часть перенумеруем последовательным индексом $\mathbf{X}_1, \dots, \mathbf{X}_N$, где новое значение N есть предшествующее значение без N_1 . Повторяя этот процесс, мы выделим некоторое количество модообразующих подвыборок. Пусть эта величина будет L^1 для первого из обучающего набора фрагментов, причем, возможно, некоторые выборочные точки (векторы) окажутся одиночными и мы их на некоторое время оставим без внимания. Подобный процесс проводим с каждым элементарным фрагментом, выбранным в качестве обучающего, так что в общей совокупности мы получим достаточно большое количество классов $\sum_k L^k$, $k = 1, \dots, K$, где K – количество выбранных фрагментов.

Агрегирование локальных классов с использованием мер близости Бхаттачария или Кульбака

Задача этого этапа заключается в том, чтобы из всего многообразия выделить и объединить ближайшие в смысле мер (10), (12) подклассы. С этой целью будем исследовать расстояния между парами локальных классов. Предположим, что нам априорно известно некоторое минимальное ожидаемое количество классов L_{\min} и некоторое максимальное их количество L_{\max} , так что уместно рассматривать декомпозицию всего изображения на некоторое число классов L и $L_{\min} \leq L \leq L_{\max}$. Итерационный процесс заключается в переборе всевозможных пар классов с вычислением непараметрических оценок расстояния Бхаттачария (10) или меры Кульбака (12). В процессе первой итерации объединяется лишь та пара классов, расстояние между которыми, в смысле выбранных

мер, минимально. На этом этапе мы пользуемся обобщенной метрикой, основанной на $\rho(\mathbf{x}, \mathbf{y})$, так как мощность формируемых классов еще недостаточна для оценивания собственных метрик типа (11). Таким образом, продолжая итерационный процесс объединения пар локальных классов, мы приводим их к количеству, ближайшему к L_{\max} .

Объединение классов по критерию максимума эмпирического риска (второй этап алгоритма)

На этом этапе целесообразно производить более корректные объединения в классы, пользуясь, во-первых, собственными метриками классов с индивидуальными мерами (11) и, во-вторых, критерием эмпирического риска. Первые объединения пар классов производятся для самых больших значений риска $r \cong 0,5$, что означает полную неразличимость классов. При восстановлении условных распределений подсчитываются ковариационные матрицы классов \hat{R}_v с параметром сглаживания, выраженным через наблюдения [12]:

$$h_v \cong \sqrt{\frac{\sum_i \sum_{j \neq i} \rho_v(\mathbf{X}_i, \mathbf{X}_j)/nN_v}{N_v(N_v - 1)}},$$

где $v = 1, \dots, L$, L – некоторое количество классов, синтезированное на данном шаге. Для контроля качества разделимости классов вычисляется обобщенный риск (3) и запоминается его значение для заданного набора классов. Продолжая иерархический процесс объединения и укрупнения классов от L_{\max} до L_{\min} и сравнивая значения обобщенного риска, останавливаемся на его минимальном значении, которое порождается набором классов $L = L_{\text{опт}}$. В дальнейшем будем использовать этот набор классов, попытаемся оптимизировать байесовы решающие правила (4) по параметрам сглаживания и оценить качество признаковов подпространств.

Выбор информативных признаков по критерию минимума эмпирического риска распознавания компонент многозональных изображений (третий этап алгоритма)

В проблеме выбора информативных признаков следует выделить два основных момента, а именно: необходимо определить функционал информативности подсистемы признаков и технологию формирования последовательностей исследуемых на информативность подпространств признаков.

Прежде всего заметим, что адекватным задаче оценивания качества (информативности) комплексов признаков является лишь средний риск, или эмпирическая оценка последнего по обучающей выборке, т.е. тот же критерий, минимизацией которого получено оптимальное (байесово) правило распознавания образов. Что касается способов выбора подпространств

признаков, то разнообразие применяемых на практике способов невелико. Заметим, что решение поставленной задачи известно и тривиально: для получения оптимальной подсистемы из k признаков, выбранных среди n исходных компонент вектора наблюдения, нужно лишь произвести сравнения вычисленных на разных k -мерных подпространствах значения критерия информативности и зафиксировать тот набор k признаков, на котором выбранный критерий достигает оптимума. Количество таких подсчетов критерия оптимальности равно числу $\binom{n}{k}$ -сочетаний из n признаков по k и для сравнительно небольших k и n составляет астрономические цифры затрат машинного времени, поэтому на практике широко применяются способы усеченных переборов подпространств признаков. Так, в алгоритме, условно обозначенном «А», осуществляется усеченный перебор, сокращающий систему признаков путем выбрасывания один за одним малоинформативных признаков. В другом варианте «Б» система информативных признаков набирается последовательно путем включения один за одним высокоинформативных признаков. Нами реализован комбинированный алгоритм выбора информативных подпространств k признаков, представляющий собой модифицированный вариант усеченного перебора, заключающийся в том, что пока величина числа сочетаний $\binom{n}{i}$, определяющая варианты полного перебора систем по i признакам, мала и допустима в смысле вычислительных затрат на подсчеты функционала информативности i -мерных подпространств, используется полный перебор по i признакам из n . Таким образом, на первом шаге выбираем i ($i \ll k$) информативных признаков. На втором шаге, зафиксировав $(n-i)$ оставшихся признаков – претендентов на пополнение информативного набора, выбираем из них вновь полным перебором систему из j признаков, такую, что набор $i+j$ ($i+j \ll k$) из признаков оптимален по критерию информативности, и так далее. Процесс расширения системы признаков блоками продолжается до тех пор, пока информативная совокупность $i+j+\dots+l$ признаков не достигнет искомой величины k . В частном случае, полагая $i=j=\dots=l=1$, мы получим алгоритм «Б». Аналогичное обобщение допускает алгоритм усеченного перебора подпространств «А», в котором сокращение исходной размерности n также осуществляется блоками в режиме условно полного перебора. Тем самым предлагаемый алгоритм позволяет рассматривать дополнительные варианты пространств признаков и исследовать их на информативность.

Таким образом, все составляющие критерия информативности (3) доопределены и r может быть использовано для оценивания информативности наборов признаков, что и производится на этом этапе.

Непараметрическая классификация всего изображения алгоритмом распознавания образов в пространстве информативных признаков (четвертый этап алгоритма)

Наконец, после того как вероятностные модели классов восстановлены и выделен оптимальный комплекс информативных признаков, оценочное байесово решающее правило (4) относит неизвестный вновь наблюдаемый вектор $\mathbf{X} \in R^k$, где R^k – k -мерное пространство информативных признаков, последовательно выбираемый из всего поля анализируемого многослойного изображения, к одному из имеющихся классов. Тем самым производится сегментация всего изображения алгоритмом распознавания образов, в результате чего выделяются текстурно однородные поля видеоданных.

1. 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.
2. Фукунага К. Введение в статистическую теорию распознавания образов: Пер. с англ. М.: Наука, 1979. 368 с.
3. Ту Дж., Гонсалес Р. Принципы распознавания образов. М.: Мир, 1978. 408 с.
4. Протасов К.Т. Выделение полей облачности на космических снимках алгоритмом сегментации, основанным на классификации и распознавании образов // Оптика атмосферы и океана. 1998. Т. 11. № 1. С. 79–85.
5. Протасов К.Т. Распознавание образов и классификация агрегированных наблюдений в условиях статистической неопределенности // Изв. высших учебных заведений. Физика. 1995. Т. 38. № 9. С. 59–64.
6. Рао С.Р. Линейные статистические методы и их применения. М.: Наука, 1968. 548 с.
7. Епанечников В.А. Непараметрическая оценка многомерной плотности вероятности // Теория вероятностей и её применение. 1969. Т. 14. Вып. 1. С. 156–161.
8. Цыпкин Я.З. Адаптация и обучение в автоматических системах. М.: Наука, 1968. 400 с.
9. Тарасенко Ф.П. Непараметрическая статистика. Томск: ТГУ, 1976. 294 с.
10. Кульбак С. Теория информации и статистика: Пер. с англ. / Под ред. А.Н. Колмогорова. М.: Наука, 1967. 408 с.
11. Жиглявский А.А. Математическая теория глобального случайного поиска. Л.: Изд-во ЛГУ, 1985. 296 с.
12. Иванова Н.В., Протасов К.Т. Определение параметров сглаживания в непараметрических оценках функций плотности по выборке // Математическая статистика и её приложения. Томск: Изд-во ТГУ. Вып. 8. 1982. С. 50–65.
13. Толчельников Ю.С. Оптические свойства ландшафта. Л.: Наука, 1974.

K.T. Protasov. Distinguishing of Homogeneity Fields on Space-made Photographs Using Distribution-free Algorithm in Informative Signs' Spaces.

A new combined distribution-free algorithm is worked out for segmentation of multispectral space-made photographs of the Earth surface and cloudiness based on a four-stage procedure. At the first stage the fragment-to-fragment local clusterization of video-data is performed using Bhattacharia spaces or Kulbach divergences. The next step is joining the nearest found classes with use of empirical risk functional. A teaching of the distribution-free algorithm of pattern recognition basing on the obtained classes takes place at the third stage. The last step is a segmentation of the whole image by the pattern recognition algorithm. Such an approach permits us to solve reasonably the problem of a compromise between an awkwardness of the initial data and the necessity to use adequate models of the images under recognition based on nonparametric estimates of unknown conditional probability distributions. In addition, the problem of investigation of a set of signs for informativeness is being solved in terms of minimum of the empirical risk criterion.