

УДК 504.064(4)

ПРИМЕНЕНИЕ РАСПРЕДЕЛЕНИЙ ДЖОНСОНА К ЗАДАЧЕ КЛАССИФИКАЦИИ АЭРОКОСМИЧЕСКИХ ИЗОБРАЖЕНИЙ

Ю.Б. Буркатовская, Н.Г. Марков, А.С. Морозов, А.П. Серых*

Томский политехнический университет

*Томский государственный университет

E-mail: julya@mail.tsu.ru

При решении задачи классификации аэрокосмических изображений предложено аппроксимировать плотности распределения признаков изображений распределениями Джонсона. Исследованы возможности такого подхода, показана его перспективность.

Введение

Аэрокосмические изображения (АИ) являются важным источником данных о состоянии поверхности Земли и используются, например, для распознавания пожаров, оценки экологического состояния территорий и т. д. Решение проблемы автоматизированной интерпретации АИ главным образом связано с разработкой новых методов, алгоритмов и программных средств классификации таких изображений [1–3]. Наиболее распространенным подходом при этом является приложение теории статистического распознавания образов [4] с использованием различных классификаторов. Классификация типов земной поверхности на АИ может проводиться с использованием как параметрических, так и непараметрических классификаторов. Однако, большинство этих классификаторов не удовлетворяет всё возрастающие требования к точности и скорости классификации, поэтому актуальной является задача разработки новых высокоэффективных методов и подходов к классификации АИ.

В данной работе развивается подход, позволяющий решать задачу классификации АИ с использованием распределений Джонсона. Приведены результаты исследования эффективности такого подхода.

Задача классификации аэрокосмических изображений

В общем случае АИ состоит из N точек и включает K каналов данных. По используемой для формирования АИ области спектра электромагнитных волн все АИ делят на ультрафиолетовые, оптические, инфракрасные и радиолокационные [1]. На сегодняшний день для анализа динамики земной поверхности используют панхроматические (их еще называют одноканальными) АИ, которые включают одну более или менее широкую зону спектра, а также мультиспектральные изображения (называемые многоканальными или многозональными), включающие несколько слоев (каналов), одновременно полученных в разных узких диапазонах спектра. Исходные АИ для последующей обработки и интерпретации представляются как в широко распространенных форматах (например, Windows Bitmap), так и в специальных форматах геоинформационных систем (например, ER Storage, GeoTiff, Imagine Image).

Пусть тем или иным способом удалось определить, что изучаемое АИ имеет M типов (классов) земной поверхности, таких как вода, растительность, хвойный лес и т. п. Каждому классу соответствует выборка (группа пикселей АИ), называемая обучающей. С учётом этого необходимо решить задачу классификации АИ, т. е. отнести каждую точку (пиксель) изображения к одному из M классов.

Чаще при классификации АИ с обучением применяется параметрический подход (в его основе лежит гипотеза о нормальном распределении значений признаков) или в рамках непараметрического подхода или нейросетевой классификации используют методы непараметрической статистики. В первом подходе для плотности распределения признаков строится ядерная оценка, а во втором – вопрос о том, к какому классу принадлежит рассматриваемая точка АИ, решается путем непараметрического оценивания признаков [1]. Первый подход дает хорошие результаты, если распределение признаков действительно близко к нормальному, что имеет место далеко не всегда. Второй подход не требует знаний о виде распределения и, как правило, дает более точные результаты, но обладает при этом высокой вычислительной сложностью.

Учитывая изложенное, авторы предлагают аппроксимировать плотности распределения признаков распределениями Джонсона, которые зависят от трех либо четырех параметров, а значит, адекватно описывают более широкий класс плотностей, чем зависящее от двух параметров нормальное распределение. Кроме того, случайные величины с распределениями из семейства Джонсона могут быть преобразованы к стандартным нормальным случайным величинам, что позволяет использовать для классификации АИ результаты, полученные для нормального распределения. Предлагаемый подход является, по сути, параметрическим, а значит, может позволить повысить скорость классификации по сравнению с непараметрическими и нейросетевыми методами классификации.

Сначала рассмотрим особенности распределений Джонсона применительно к поставленной задаче и получим выражение для многомерной плотности распределения. Затем получим формулы для оценок параметров распределения.

Распределения Джонсона (многомерный случай)

Пусть имеется многоканальное АИ, содержащее N точек. Каждая точка описывается вектором из m признаков (в набор входят как спектральные, так и текстурные признаки). Ставится задача нахождения эмпирического распределения, описывающего плотность распределения признаков каждой точки изображения.

Н.Л. Джонсон предложил находить эмпирические распределения путем преобразования нормированной нормально распределенной случайной величины [6]. Пусть ξ – случайная величина, для которой требуется подобрать распределение Джонсона. В общем случае преобразование имеет вид

$$\zeta = \gamma + \eta \tau(\xi; \varepsilon, \lambda); \quad -\infty < \gamma < +\infty, \eta > 0, -\infty < \varepsilon < +\infty, \lambda > 0; \quad (1)$$

где $\tau(\cdot)$ некоторая функция; $\gamma, \eta, \varepsilon$ и λ – параметры распределения, а ζ – случайная величина, распределенная по нормальному закону. Джонсон предложил следующие три различные формы или семейства функций $\tau(\cdot)$, называемые соответственно семействами распределений S_L, S_B и S_U Джонсона [6]:

$$\begin{aligned} S_L: \quad \tau_1(\xi; \varepsilon, \lambda) &= \ln\left(\frac{\xi - \varepsilon}{\lambda}\right), \quad \xi \geq \varepsilon; \\ S_B: \quad \tau_2(\xi; \varepsilon, \lambda) &= \ln\left(\frac{\xi - \varepsilon}{\lambda + \varepsilon - x}\right), \quad \varepsilon \leq \xi \leq \lambda + \varepsilon; \\ S_U: \quad \tau_3(\xi; \varepsilon, \lambda) &= \operatorname{Arsh}\left(\frac{\xi - \varepsilon}{\lambda}\right), \quad -\infty < \xi < +\infty. \end{aligned} \quad (2)$$

Как следует из (2), функция $\tau_1(\cdot)$ пригодна для описания плотностей с носителем, ограниченным слева, функция $\tau_2(\cdot)$ – с конечным носителем, $\tau_3(\cdot)$ – с бесконечным носителем. Однако сказанное выше не носит обязательного характера, т. к. вид функции $\tau(\cdot)$ может зависеть не только от носителя, но и от других характеристик гистограммы распределения.




Рис. 1. График для выбора семейства распределений Джонсона

В [6] предложено осуществлять выбор семейства распределений Джонсона на основании нормированных показателей асимметрии β_1 и эксцесса β_2 эмпирического распределения. Данные показатели вычисляются по следующим формулам:

$$\sqrt{\beta_1} = \frac{\mu_3}{(\mu_2)^{3/2}}; \quad \beta_2 = \frac{\mu_4}{(\mu_2)^2};$$

где μ_i – i -й центральный момент случайной величины ξ .

Семейство распределений S_L представляется в системе координат β_1, β_2 кривой, так как имеет один параметр формы, в отличие от семейств S_B и S_U , имеющих два параметра и представляющихся в виде областей (рис. 1). Кривая, соответствующая семейству S_L , задана в соответствии с [6].

Рассмотрим случайный вектор $\xi = [\xi_1, \dots, \xi_m]^T$. Предположим, что его компонента с номером i подчиняется распределению Джонсона с функцией $\tau_i(\cdot)$ и параметрами $(\gamma_i, \eta_i, \varepsilon_i, \lambda_i)$. Применяя преобразование Джонсона (1), получаем случайный вектор $\zeta = [\zeta_1, \dots, \zeta_m]^T$

$$\zeta = \gamma + \eta \tau(\xi; \varepsilon, \lambda), \quad (3)$$

где

$$\gamma = [\gamma_1, \gamma_2, \dots, \gamma_m]^T, \quad \varepsilon = [\varepsilon_1, \varepsilon_2, \dots, \varepsilon_m]^T, \quad \lambda = [\lambda_1, \lambda_2, \dots, \lambda_m]^T;$$

$$\eta = \begin{bmatrix} \eta_1 & 0 & \dots & 0 \\ 0 & \eta_2 & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & \eta_m \end{bmatrix}, \quad \tau(\xi; \varepsilon, \lambda) = \begin{bmatrix} \tau_{j_1}(\xi_1; \varepsilon_1, \lambda_1) \\ \tau_{j_2}(\xi_2; \varepsilon_2, \lambda_2) \\ \dots \\ \tau_{j_m}(\xi_m; \varepsilon_m, \lambda_m) \end{bmatrix},$$

$$j_i \in \{1, 2, 3\}.$$

Чаще всего на практике компоненты вектора ξ , а значит, и вектора ζ , являются зависимыми. Отдельные компоненты вектора ζ подчиняются стандартному нормальному распределению. Это, разумеется, не означает, что вектор ζ имеет многомерное нормальное распределение. Однако, случаи, когда совместное распределение гауссовских случайных величин не является гауссовским, не так уж часто встречаются на практике. Поэтому предположим, что совместное распределение компонент вектора ζ также является гауссовским. Рассмотрим матрицу ковариаций

$$\Sigma = \begin{bmatrix} 1 & \sigma_{12} & \dots & \sigma_{1m} \\ \sigma_{12} & 1 & \dots & \sigma_{2m} \\ \dots & \dots & \dots & \dots \\ \sigma_{1m} & \sigma_{2m} & \dots & 1 \end{bmatrix}, \quad \sigma_{ij} = M\{\zeta_i \zeta_j\}. \quad (4)$$

Тогда плотность распределения вектора ζ примет вид

$$f_\zeta(y) = \frac{1}{\sqrt{(2\pi)^m |\Sigma|}} \exp\left\{-\frac{1}{2} y^T \Sigma^{-1} y\right\}. \quad (5)$$

Построение матрицы ковариаций (4) и использование формулы (5) позволяет учесть линейные связи между компонентами вектора ζ .

Получим теперь плотность вектора ξ . Введем матрицу $\tau(\xi; \varepsilon, \lambda)$, элементами главной диагонали которой являются производные функций $\tau_{ji}(\xi_i; \varepsilon_i, \lambda_i)$:

$$\tau'(\xi; \varepsilon, \lambda) = \begin{bmatrix} \tau'_{j_1}(\xi_1; \varepsilon_1, \lambda_1) & 0 & \dots & 0 \\ 0 & \tau'_{j_2}(\xi_2; \varepsilon_2, \lambda_2) & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & \tau'_{j_m}(\xi_m; \varepsilon_m, \lambda_m) \end{bmatrix}.$$

Учитывая (3), имеем

$$f_\xi(x) = |\eta| |\tau'(x; \varepsilon, \lambda)| \frac{1}{\sqrt{(2\pi)^m |\Sigma|}} \times \exp\left\{-\frac{1}{2}[\gamma + \eta\tau(x; \varepsilon, \lambda)]^T \Sigma^{-1}[\gamma + \eta\tau(x; \varepsilon, \lambda)]\right\}.$$

Введем обозначения $\delta = \eta^{-1}\gamma$, $D = \eta^{-1}\Sigma\eta^{-1}$. Окончательно имеем

$$f_\xi(x) = |\tau'(x; \varepsilon, \lambda)| \frac{1}{\sqrt{(2\pi)^m |D|}} \times \exp\left\{-\frac{1}{2}[\tau(x; \varepsilon, \lambda) - \delta]^T D^{-1}[\tau(x; \varepsilon, \lambda) - \delta]\right\}. \quad (6)$$

Если обозначить многомерную нормальную плотность распределения с параметрами (δ, D) через $\varphi(x, \delta, D)$, то формула (6) примет вид

$$f_\xi(x) = |\tau'(x; \varepsilon, \lambda)| \varphi(\tau(x; \varepsilon, \lambda); \delta, D).$$

Благодаря тому, что преобразования Джонсона случайных величин приводят к стандартным гауссовским величинам, для работы с распределениями Джонсона можно использовать результаты, полученные для нормально распределенных случайных величин. В частности, рассмотрим оценивание параметров многомерной плотности распределения.

Изложим сначала результаты, полученные в [6] для одномерных случайных величин. Пусть имеется набор независимых случайных величин $\{x_1, \dots, x_N\}$, имеющих распределение Джонсона. Заметим, что параметры ε , λ имеют смысл параметров масштаба случайной величины. Поскольку в задачах обработки и интерпретации АИ в качестве наблюдаемой случайной величины используется яркость точки, которая может изменяться в некотором конечном интервале значений (часто от 0 до 255), то интервал изменения случайной величины априори известен, и эту информацию можно использовать при оценивании параметров ε , λ .

Для распределения S_L , где

$$\zeta = \gamma + \eta \ln\left(\frac{\xi - \varepsilon}{\lambda}\right),$$

проводится замена переменных, и число параметров уменьшается до трех:

$$\zeta = \gamma^* + \eta \ln(\xi - \varepsilon), \quad \gamma^* = \gamma - \eta \ln \lambda.$$

Параметр ε здесь имеет смысл левой границы распределения, и в задаче классификации АИ его можно положить равным нулю или минимальному

значению признака в обучающей выборке. При известном ε оценки для параметров γ^* и η имеют вид

$$\hat{\eta} = \frac{1}{\hat{\sigma}}, \quad \hat{\gamma}^* = -\frac{\hat{\mu}}{\hat{\sigma}},$$

$$\text{где } \hat{\mu} = \frac{1}{N} \sum_{i=1}^N \ln(x_i - \varepsilon), \quad \hat{\sigma} = \sqrt{\frac{\sum_{i=1}^N \ln(x_i - \varepsilon)^2}{N} - \hat{\mu}^2}.$$

Для семейства распределений S_B в случае, когда известны параметры ε (левая граница распределения) и λ (ширина носителя распределения), параметры η и γ оцениваются путём сопоставления двух эмпирических процентилей двум соответствующим процентиям стандартного нормального распределения:

$$\hat{\eta} = \frac{z_{1-\alpha'} - z_\alpha}{\ln\left(\frac{(x_{1-\alpha'} - \varepsilon)(\varepsilon + \lambda - x_\alpha)}{(x_\alpha - \varepsilon)(\varepsilon + \lambda - x_{1-\alpha'})}\right)},$$

$$\hat{\gamma} = z_{1-\alpha'} - \hat{\eta} \ln\left(\frac{x_{1-\alpha'} - \varepsilon}{\varepsilon + \lambda - x_{1-\alpha'}}\right),$$

где z_α и $z_{1-\alpha'}$ представляют собой $\alpha 100$ -й и $(1-\alpha) 100$ -й проценти стандартного нормального распределения, а x_α и $x_{1-\alpha'}$ — соответствующие эмпирические проценти. Если параметры ε и λ неизвестны, то можно принять их равными соответственно минимальному значению признака в обучающей выборке и разнице между максимальным и минимальным значением признака.

Более полно вопросы оценивания параметров одномерной случайной величины, подчиняющейся распределению Джонсона с неизвестными границами изменения, рассмотрены в [6]. Метод оценивания параметров распределения семейства S_U основан на численном решении нелинейных уравнений и рассмотрен в [7].

Пусть теперь $\{x_1, \dots, x_N\}$ — m -мерные вектора, компоненты которых подчиняются распределению Джонсона, т. е. $x_i = [\xi_1^i, \dots, \xi_m^i]^T$. Преобразуем вектора x_i в вектора y_i аналогично (3), но вместо параметров используем их оценки.

$$y_i = \hat{\gamma} + \hat{\eta}(x_i; \hat{\varepsilon}, \hat{\lambda});$$

$$\hat{\eta} = \begin{bmatrix} \hat{\eta}_1 & 0 & \dots & 0 \\ 0 & \hat{\eta}_2 & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & \hat{\eta}_m \end{bmatrix}, \quad \hat{\gamma} = \begin{bmatrix} \hat{\gamma}_1 \\ \hat{\gamma}_m \\ \dots \\ \hat{\gamma}_m \end{bmatrix}. \quad (7)$$

Далее оценим параметры (δ, D) плотности распределения (6)

$$\hat{\delta} = -\hat{\eta}^{-1} \hat{\gamma};$$

$$\hat{\sigma}_{ij} = \frac{1}{N} \sum_{l=1}^N y_l^i y_l^j, \quad \hat{\sigma}_{ii} = 1;$$

$$\hat{D} = \hat{\eta}^{-1} \hat{\Sigma} \hat{\eta}^{-1}. \quad (8)$$

Подставляя полученные оценки в (6), получаем оценку совместной плотности распределения компонент случайного вектора.

Результаты классификации АИ

С учётом полученных выше теоретических результатов обобщённый алгоритм классификации АИ методом максимального правдоподобия с применением распределений Джонсона выглядит следующим образом.

Шаг 1. Выбрать семейство распределений Джонсона и получить оценку параметров одномерного распределения Джонсона для каждого признака каждого класса (обучающей выборки).

Шаг 2. С помощью параметров, полученных на шаге 1, преобразовать вектора признаков пикселей обучающих выборок по формуле (3) к векторам со стандартным нормальным распределением, и получить оценки ковариации и параметров многомерного распределения для каждого класса по формулам (4), (7), (8).

Шаг 3. С помощью параметров, полученных на шаге 2, вычислить для каждого пикселя АИ оценку плотности распределения признаков по формуле (6) для каждого класса.

Шаг 4. Отнести каждый пиксель АИ к классу, доставляющему максимальное значение плотности распределения признаков.

Для исследования эффективности предложенного подхода, позволяющего решать задачу классификации АИ с использованием распределений Джонсона, с учётом приведенного алгоритма создано соответствующее программное обеспечение.

Для классификации изображений в экспериментах использовались реальные АИ различной детальности, полученные с космических систем дистанционного зондирования Земли. В качестве показателей точности классификации использовались каппа-индекс согласия (КИС) и интегральная вероятность правильной классификации (ВПК) [1]. На рис. 2 в качестве примера приведены результаты классификации исходного многоканального космического снимка (семь спектральных зон) фрагмента прибрежной зоны г. Сан-Диего (рис. 2, а), сделанного с помощью системы Landsat TM (США) [8]. Число классов для обучения, согласно результатам работы [2], выбрано равным десяти.

Для визуальной оценки результатов классификации АИ на рис. 2, в, приведено изображение, полученное при классификации с использованием распределений Джонсона, а на рис. 2, б, – результат классификации с использованием нормального распределения признаков. Видно, что при классификации с использованием нормального распределения линия прилива на исходном снимке (рис. 2, а, левый нижний угол), не включённая в число обучающих классов, была отнесена к классу «бетонные сооружения» (рис. 2, б), тогда как при классификации


с помощью распределений Джонсона эти пиксели не были классифицированы, как отстоящие достаточно далеко в пространстве признаков от всех используемых классов (чёрные пиксели на рис. 2, в).



а



б



в

Рис. 2. Примеры классификации АИ




Рис. 3. Зависимость времени классификации от количества признаков

В таблице приведены количественные показатели точности классификации АИ для описанного примера. Можно отметить, что классификация с использованием распределений Джонсона выполняется с несколько меньшей точностью, чем классификация в случае предположения о нормальном распределении признаков (приведённое изображение – это практически идеальный случай, когда распределение близко к нормальному). Кроме того, в силу ограниченности носителя распределений семейства S_B Джонсона (именно это семейство было выбрано для большинства признаков большинства классов с учетом значений β_1 и β_2 и рис. 1) 5,1 % пикселей остались неклассифицированными.

Таблица. Точность классификации, %

Вид оценки плотности	КИС	ВПК
Нормальное распределение	97,82	98,61
Распределение Джонсона	96,91	98,19

Результаты исследования вычислительной эффективности предложенного подхода приведены на рис. 3 (размер изображения 500×500 пикселей). Здесь же для сравнения показаны затраты машинного времени в случае классификации АИ с использованием нормального распределения признаков. Видно, что скорость выполнения алгоритма, реализующего предложенный подход к классификации АИ, выше, чем в случае классификации с

использованием нормального распределения. Этот результат объясняется ограниченностью носителя распределения семейства S_B Джонсона, поскольку при переборе классов те из них, в область определения которых рассматриваемый пиксель не попадает хотя бы по одному признаку, отбрасываются уже на начальной стадии вычислений. Скорость работы алгоритма с принудительным использованием семейства распределений S_U , которое имеет бесконечный носитель, несколько ниже традиционного метода.

Заключение

Для решения задачи классификации аэрокосмических изображений предложено аппроксимировать плотности распределения признаков изображений распределениями Джонсона. Приведен вывод формулы для многомерной плотности распределения признаков и оценки параметров плотности их распределения.

Проведена серия компьютерных экспериментов с реальными аэрокосмическими изображениями для изучения эффективности предложенного подхода. Получены первые обнадеживающие результаты, указывающие на перспективность использования распределений Джонсона при решении задачи классификации с обучением.

Работа поддержана грантом РФФИ № 06-07-89190а.

СПИСОК ЛИТЕРАТУРЫ

1. Замятин А.В., Марков Н.Г. Анализ динамики земной поверхности по данным дистанционного зондирования Земли. – М.: Физматлит, 2007. – 176 с.
2. Giacinto G., Roli F. Dynamic Classifier Selection Based on Multiple Classifier Behavior // Pattern Recognition. – 2001. – V. 34. – № 9. – P. 179–181.
3. Podest E., Saatchi S. Application on Multiscale Texture in Classifying JERS-1 Radar Data Over Tropical Vegetation // International Journal of Remote Sensing. – 2002. – V. 23. – № 7. – P. 1487–1506.
4. Фукунага К. Введение в статистическую теорию распознавания образов. – М.: Наука, 1979. – 368 с.
5. Haralick R.M., Shapiro L.G. Computer and Robot Vision. – Massachusetts: Addison-Wesley, 1992. – P. 199–218.
6. Хан Г., Шапиро С. Статистические модели в инженерных задачах. – М.: Наука, 1969. – 308 с.
7. Johnson N.L. Tables to Facilitate Fitting SV Frequency Curves. – Oxford: Biometrika Trust, 1965. – P. 52–57.
8. <http://www.leica-geosystems.com>

Поступила 11.10.2007 г.