

РОССИЙСКАЯ АКАДЕМИЯ НАУК

СИБИРСКОЕ ОТДЕЛЕНИЕ

А В Т О М Е Т Р И Я

---

2008, том 44, № 4

УДК 528.852

**КОНТРОЛИРУЕМАЯ КЛАССИФИКАЦИЯ ДАННЫХ  
ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ ЗЕМЛИ\***

**В. В. Асмус<sup>1</sup>, А. А. Бучнев<sup>2</sup>, В. П. Пяткин<sup>2</sup>**

<sup>1</sup>*Научно-исследовательский центр «Планета», Москва*

<sup>2</sup>*Институт вычислительной математики и математической геофизики СО РАН,*

*г. Новосибирск*

*E-mail: pvp@ooi.sccc.ru*

Рассматривается система контролируемой классификации (с обучением) данных дистанционного зондирования Земли. Проведены вычислительные эксперименты для оценки эффективности распределенной обработки этих данных.

**Введение.** Центральный вопрос интерпретации данных дистанционного зондирования Земли (ДДЗЗ) – повышение качества дешифрирования – непосредственно связан с проблемой выбора адекватного алгоритма распознавания [1]. Возникающие при этом трудности обусловлены следующими причинами [2]:

1. Структура реальных данных не соответствует их модели, используемой в предлагаемом алгоритме контролируемой классификации, например, не выполняется предположение о нормальном распределении векторов данных или условие, что поле измерений является случайным. Опыт показывает, что такие ситуации возникают тогда, когда излучение от сканируемого объекта выходит за пределы динамического диапазона съемочной аппаратуры. В этих случаях приходится либо вообще отказываться от методов, требующих обращения ковариационных матриц, либо прибегать к приемам, повышающим дисперсию данных.

2. Нерепрезентативность обучающих последовательностей: недостаточное количество данных для восстановления параметров решающего правила; несоответствие обучающих данных и данных, предъявляемых на распознавание («загрязнение» выборок смешанными векторами измерений, т. е. векторами, которые образуются при попадании в элемент разрешения съемочной системы нескольких природных объектов; неполное соответствие обучающих данных, получаемых с помощью кластеризации, истинным тематическим классам; помехи аппаратуре; влияние атмосферных условий и т. п.).

Таким образом, современный опыт автоматизированного распознавания ДДЗЗ показывает, что заранее практически невозможно установить, какой алгоритм будет лучше с точки зрения соотношения точности классификации

---

\* Работа выполнена частично при поддержке Российского фонда фундаментальных исследований (проект № 07-07-00085).

и стоимости. Поэтому в распознающую систему целесообразно закладывать несколько алгоритмов и выбор оптимального алгоритма проводить эмпирически по результатам классификации тестовых данных на этапе обучения. Выбранный алгоритм используется затем для распознавания всего набора векторов измерений.

Разработанная в Институте вычислительной математики и математической геофизики СО РАН (г. Новосибирск) совместно с Научно-исследовательским центром «Планета» (Москва) система контролируемой классификации (с обучением) ДДЗЗ в программном комплексе состоит из семи классификаторов (один поэлементный классификатор и шесть объектных), основанных на использовании байесовской стратегии максимального правдоподобия, и двух объектных классификаторов, базирующихся на минимуме расстояния. Эта система является частью программного комплекса по обработке ДДЗЗ [3].

Цель представленной работы – предложить спектр алгоритмов контролируемой классификации данных дистанционного зондирования Земли, адекватных их модели.

**Поэлементная классификация.** Под элементом здесь понимается  $N$ -мерный вектор измерений (признаков)  $x = (x_1, \dots, x_N)^T$ , где  $N$  – число спектральных диапазонов. Предполагается, что векторы  $x$  имеют в классе  $\omega_i$  нормальное распределение  $N(m_i, B_i)$  со средним  $m_i$  и ковариационной матрицей  $B_i$ . В этом случае байесовская стратегия максимального правдоподобия для поэлементного классификатора формулируется следующим образом [4–6].

Пусть  $\Omega = (\omega_1, \dots, \omega_m)$  – конечное множество классов,  $p(\omega_i)$  – априорная вероятность класса  $\omega_i$ . Тогда дискриминантная функция класса  $\omega_i$  имеет вид

$$g_i(x) = \ln(p(\omega_i)) - 0,5 \ln(|B_i|) - 0,5(x - m_i)^T B_i^{-1}(x - m_i). \quad (1)$$

Классическое решающее правило для классификатора принимает следующий вид: вектор  $x$  заносится в класс  $\omega_i$ , если  $g_i(x) > g_j(x)$  для всех  $j \neq i$ .

Для класса  $\omega_i$  определим параметр

$$T_i = \ln p(\omega_i) - 0,5A(N, Q) - 0,5 \ln |B_i|, \quad (2)$$

где  $A(N, Q)$  – критическое значение уровня  $Q$  распределения  $\chi^2$ . Пусть  $t_i$  – переменная, значение которой зависит от параметра классификатора  $thr$ :

$$t_i = \begin{cases} -\infty, & \text{если } thr = 1, \\ T_i, & \text{если } thr = 2, \\ \min_{i=1}^m T_i, & \text{если } thr = 3, \\ \max_{i=1}^m T_i, & \text{если } thr = 4, \\ \left( \sum_{i=1}^m T_i \right) / m, & \text{если } thr = 5. \end{cases} \quad (3)$$

Тогда решающее правило для классификатора с учетом (3) принимает вид [2]: вектор  $x$  заносится в класс  $\omega_i$ , если  $g_i(x) > g_j(x)$  для всех  $j \neq i$  и  $g_i(x) > t_i$  (при  $t_i = T_i$  это означает ограничение расстояния Махалонобиса  $(x - m_i)^T \times B_i^{-1}(x - m_i) < A(N, Q)$  до центра класса). В противном случае вектор заносится в класс отклоненных векторов (класс с номером  $m+1$ ).

Значения  $A(N, Q)$  для размера вектора  $N \leq 30$  находятся из статистических таблиц. Например, для  $N = 4$  и уровня  $Q = 0,05$  (т. е. 5 % векторов может быть отклонено)  $A = 9,488$ . При  $N > 30$  для нахождения значений  $A(N, Q)$  используется аппроксимация

$$\chi^2_{1-Q}(N) \approx N \left( 1 - \frac{2}{9N} + u_{1-Q} \sqrt{\frac{2}{9N}} \right)^3, \quad (4)$$

где  $u_{1-Q}$  – значение стандартизованной нормальной величины для вероятности  $1-Q$  (в частности, для уровня  $Q = 0,05$  значение  $u_{0,95} \approx 1,645$ ).

**Объектная классификация.** Под объектом в данной работе понимается блок смежных векторов квадратной или крестообразной формы. Поскольку физические размеры реально сканируемых пространственных объектов, как правило, больше разрешения съемочных систем, между векторами данных существуют взаимосвязи. Использование информации подобного рода дает возможность повысить точность классификации, если пытаться распознавать одновременно группу смежных векторов – объект в приведенном выше смысле. Рассмотрим вектор (объект)  $X = (x_1, \dots, x_L)^T$ , состоящий из смежных  $N$ -мерных векторов  $x_i$ ,  $i=1, \dots, L$ , например, в окрестностях  $3 \times 3$ ,  $5 \times 5$ , ... элементов. Мы работаем с объектами двух видов: квадратными либо крестообразными. Решение об отнесении центрального элемента объекта к тому или иному классу принимается на основе результата классификации всего объекта.

Такой подход порождает целое семейство решающих правил. Во-первых, это использование принципа голосования, т. е. независимая классификация элементов объекта и отнесение центрального элемента к тому классу, к которому было отнесено большинство элементов объекта. Во-вторых, это применение текстурных операторов (простейший пример – описание объекта  $X$  через вектор средних составляющих его элементов) с последующим отнесением центрального элемента к классу, к которому был отнесен параметр, характеризующий  $X$ . В-третьих, описание объекта  $X$  случайным марковским полем

$$p(X | \omega_i) = p(x_1 | x_2, \dots, x_L; \omega_i) p(x_2 | x_3, \dots, x_L; \omega_i) \dots p(x_L | \omega_i).$$

В этом случае модель выглядит следующим образом. Пусть вектор  $x$  имеет в классе  $\omega_i$  нормальное распределение  $N(m_i, B_i)$  со средним  $m_i$  и ковариационной матрицей  $B_i$ . Тогда вектор  $X$  также нормально распределен в классе  $\omega_i$  со средним  $M_i$  размером  $NL$  и ковариационной матрицей  $K_i$  размером  $NL \times NL$ . Оценка этой матрицы при большом значении  $NL$  (требуется очень большое количество обучающих данных), а также ее обращение на практике трудно реализуемы. Поэтому введем упрощающие структурные предположения. Если считать, что корреляция между элементами объекта во всех зонах съемки одинакова, то ковариационную матрицу  $K_i$  можно представить в

виде прямого произведения матрицы пространственной корреляции  $R_i$  и ковариационной матрицы  $B_i$ . Если  $R_i$  является единичной, то  $p(X | \omega_i) = \prod_{l=1}^L p(x_l | \omega_i)$ . Тогда мы имеем известное решающее правило при предположении, что элементы объекта независимы.

Более адекватные модели возникают при других предположениях о структуре корреляционных связей. Например, вводя допущение о разделимости автокорреляционной функции элементов объекта по вертикали и горизонтали, получаем каузальную авторегressiveю модель первого либо третьего порядка (в зависимости от формы объекта).

Приведем алгоритмы работы некоторых объектных классификаторов. Предположим, что векторы внутри блока независимы. Рассмотрим векторы, составляющие объект  $X$ , как один вектор размером  $NL$ . Тогда имеем дискриминантную функцию класса  $\omega_i$ :

$$g_i(X) = \ln(p(\omega_i)) - 0,5L \ln(|B_i|) - 0,5 \sum_{l=1}^L (x^l - m_i)^T B_i^{-1} (x^l - m_i).$$

Решающее правило для этого классификатора принимает следующий вид: центральный элемент объекта  $X$  заносится в класс  $\omega_i$ , если  $g_i(X) > g_j(X)$  для всех  $j \neq i$  и  $g_i(X) > t_i$ , в противном случае – в класс отклоненных векторов. Здесь  $t_i$  определяется по (2) и (3) с  $A = A(LN, Q)$ .

Снова считаем, что векторы внутри блока независимы. Классифицируется вектор  $x$ , равный среднему по всем векторам объекта  $X$ :

$$x = \frac{1}{L} \sum_{l=1}^L x^l. \quad (5)$$

Дискриминантную функцию класса  $\omega_i$  запишем как

$$g_i(X) = \ln(p(\omega_i)) - 0,5 \ln(|B_i|) - 0,5L(x - m_i)^T B_i^{-1} (x - m_i).$$

Решающее правило для таких классификаторов имеет следующий вид: центральный элемент объекта  $X$  заносится в класс  $\omega_i$ , если  $g_i(X) > g_j(X)$  для всех  $j \neq i$  и  $g_i(X) > t_i$ , в противном случае – в класс отклоненных векторов. Здесь  $t_i$  определяется по (2) и (3).

Классифицируется средний вектор (5) блока в предположении, что векторы внутри блока независимы и ковариационные матрицы равны единичной. Фактически это объектные классификаторы, решающие правила которых основаны на минимуме евклидова расстояния до центра класса. Дискриминантная функция класса  $\omega_i$  имеет вид

$$g_i(X) = \ln(p(\omega_i)) - 0,5(x - m_i)^T (x - m_i).$$

Решающее правило для данных классификаторов имеет следующий вид: центральный элемент объекта  $X$  заносится в класс  $\omega_i$ , если  $g_i(X) > g_j(X)$  для всех  $j \neq i$  и  $g_i(X) > t_i$ , в противном случае – в класс отклоненных векторов. Здесь  $t_i = -A$ , где  $A > 0$  – число, задаваемое пользователем.

Система классификации содержит также объектные классификаторы, основанные на модели каузального марковского случайного поля первого и третьего порядков.

**Обучение и работа классификаторов.** Необходимые для построения дискриминантных функций классов оценки статистических характеристик: векторов средних, ковариационных матриц, коэффициентов пространственной корреляции между значениями координат соседних векторов в горизонтальном и вертикальном направлениях – определяются на основе векторов из обучающих выборок (полей). Кроме обучающих для каждого класса может быть задан набор контрольных полей. Контрольное поле – выборка из обучающего образа набора векторов измерений с известной классификацией, которая не участвует непосредственно в определении параметров классификатора, но предъявляется для распознавания классификатору, построенному на основе векторов измерений из обучающих полей, для оценки вероятностей правильной классификации.

Все классификаторы могут использоваться в двух режимах: тестовом и рабочем. По результатам работы классификаторов в тестовом режиме над векторами обучающих и контрольных полей рассчитываются матрица ошибок и оценки вероятностей правильной классификации. Известно (см., например, [4, 6]), что эти оценки для векторов из обучающих полей являются в среднем оптимистическими, а для векторов из контрольных полей – пессимистическими. Анализируя эти данные, можно оценить (проконтролировать) качество обучения.

Как отмечалось выше, возможны ситуации, при которых нарушается условие о случайности поля измерений, следствием чего являются нулевые дисперсии в некоторых каналах. Тогда формулы типа (1) становятся неприменимыми, так как ковариационные матрицы  $B$  вырожденные. Для исправления таких ситуаций в системе классификации предусмотрена функция добавления гауссовского шума с нулевым средним и единичной дисперсией к спектральным каналам с нулевой дисперсией.

При моделировании стандартной нормальной случайной величины  $X$  используется формула для приближенного вычисления, основанная на центральной предельной теореме [7]:

$$X = \sum_{i=1}^{12} U_i - 6, \quad (6)$$

где  $U_i$  – независимые равномерно распределенные на интервале  $(0, 1)$  случайные величины. Известны методы «точного» моделирования случайной величины  $X$  (см., например, [8]), однако они требуют значительно большего времени вычислений.

Результат использования классификаторов в рабочем режиме – одноканальное (байтовое) изображение, значениями пикселей которого являются номера классов. Это изображение окрашивается в предопределенные цвета, которые в интерактивном режиме могут быть заменены цветами, задаваемыми пользователем. Кроме того, к этому изображению можно применить функцию редактирования, которая определяется как уточнение карты классификации на основе учета контекста без изменения перечня ранее выделенных классов. Эта функция может работать в двух режимах: режиме Vote, при котором центральный пиксель окрестности  $3 \times 3$  заменяется модой гистограммы.

Т а б л и ц а 1

Количество классов	Перекрестие		Квадрат	
	$3 \times 3$	$5 \times 5$	$3 \times 3$	$5 \times 5$
5	80,7	147,4	311,6	1049,1
10	150,8	291,0	610,1	2120,4

граммами окрестности, и режиме Allsame, при котором центральный пиксель такой же окрестности меняется только тогда, когда все окружающие его пиксели имеют одинаковое значение.

Система контролируемой классификации имеет следующие характеристики: число обучающих образов до 9, число классов до 15, число обучающих и контрольных полей в классе до 10, размер каждого поля до  $50 \times 50$  векторов, размер объекта от  $1 \times 1$  до  $11 \times 11$ , размер векторов данных не ограничивается.

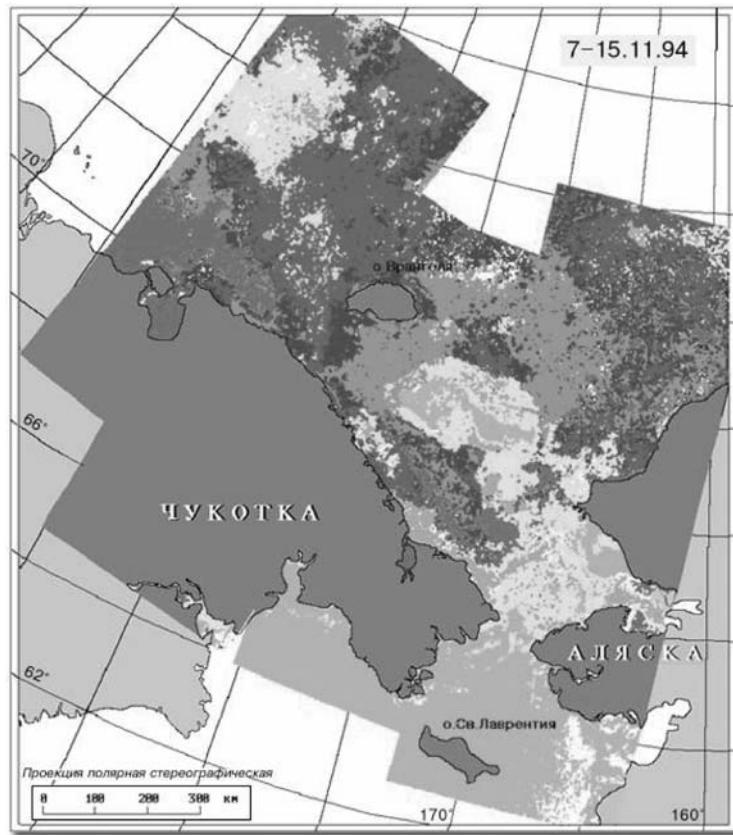
**Распределенные вычисления.** Анализ формул для вычисления значений решающих функций объектных классификаторов показывает, что определяющий вклад во временные затраты вносит вычисление значений квадратичной формы с матрицей размера  $N$ , где  $N$  – количество спектральных диапазонов. В частности, в классификаторах, основанных на модели каузального марковского случайного поля, для объекта размером  $3 \times 3$  при классификации каждого вектора значение квадратичной формы необходимо вычислять  $13m$  раз в случае перекрестия и  $53m$  раз для квадрата, где  $m$  – количество выделяемых классов. Для объекта размером  $5 \times 5$  количество вычислений значений квадратичной формы каждого вектора составит  $25m$  и  $186m$  раз соответственно. В качестве примера в табл. 1 приведены временные характеристики (в секундах) классификации  $10^7$  векторов размером  $N = 5$  на компьютере IBM PC с процессором AMD Athlon XP 3200+.

Существенно уменьшить временные затраты позволяет создание системы классификации, распределенной между персональным компьютером и многопроцессорной ЭВМ МВС-1000/М. На персональном компьютере выполняется обучение классификатора. Результаты обучения вместе с классифицируемым набором данных передаются по протоколу SFTP на МВС-1000/М, где запускается параллельная версия соответствующей программы. Распараллеливание состоит в распределении набора данных между заданным количеством процессов, каждый из которых результаты своей работы записывает в отдельный файл. Эти файлы, в свою очередь, передаются на персональный компьютер, где выполняется их «склеивание» и дальнейшая интерпретация результатов выполненной классификации. В табл. 2 отражена временная динамика выполнения классификации  $10^7$  векторов на МВС-1000/М в зависимости от количества запускаемых процессов. Размер векторов  $N = 3$ , количество выделяемых классов  $m = 5$ , размер объекта  $9 \times 9$  пикселей, тип объекта – квадрат.

На рисунке представлена тематическая карта ледовой обстановки в восточном секторе Арктики, получен-

Т а б л и ц а 2

Количество процессов				
1	2	3	4	20
10200	5070	3242,5	2412,5	593



Вода	Торосистый однолетний лед
Суша	Сильноторосистый однолетний лед
Серый лед	Многолетний лед
Гладкий однолетний лед	Начальные стадии льда, нилас

ная с применением контролируемой классификации. В качестве распознаваемых изображений использовались мозаики радиолокационных и радиометрических снимков с искусственного спутника Земли «Океан-О1». Для выбора тестовых участков было взято цветосинтезированное изображение.

**Заключение.** Представленная в данной работе система классификации является частью программного комплекса по обработке данных дистанционного зондирования Земли, внедренного в практику оперативной и научной деятельности Научно-исследовательским центром «Планета». Следует отметить, что предложенные для контролируемой классификации так называемые объектные классификаторы отсутствуют в стандартных коммерческих пакетах цифровой обработки изображений.

#### СПИСОК ЛИТЕРАТУРЫ

1. Дистанционное зондирование: количественный подход: Пер. с англ. В. П. Пяткина, О. А. Юдиной /Под ред. А. С. Алексеева. М.: Недра, 1983.

2. **Асмус В. В.** Программно-аппаратный комплекс обработки спутниковых данных и его применение для задач гидрометеорологии и мониторинга природной среды. Дис. в виде науч. докл. на соискание ученой степени д-ра физ.-мат. наук. М., 2002. 75 с.
3. **Асмус В. В., Бучнев А. А., Пяткин В. П.** Программный комплекс для обработки данных дистанционного зондирования Земли // Тр. XXXII Междунар. конф. «Информационные технологии в науке, образовании, телекоммуникации и бизнесе» (IT+SE'2005) // Открытое образование. 2005. Спец. вып. С. 229.
4. **Ту Дж., Гонсалес Р.** Принципы распознавания образов. М.: Мир, 1978.
5. **Гонсалес Р., Вудс Р.** Цифровая обработка изображений. М.: Техносфера, 2005.
6. **Marques de Sa J. P.** Pattern Recognition: Concepts, Methods and Applications. Berlin-Heidelberg: Springer-Verlag, 2001.
7. **Бусленко Н. П., Шрейдер Ю. А.** Метод статистических испытаний (Монте-Карло) и его реализация на цифровых вычислительных машинах. М.: Физматгиз, 1961.
8. **Винклер Г.** Анализ изображений, случайные поля и динамические методы Монте-Карло. Математические основы. Новосибирск: Изд-во СО РАН, 2002.

*Поступила в редакцию 3 сентября 2007 г.*

---