

Проблемы классификации гиперспектральных авиакосмических изображений

**Т.В.Кондранин¹, В.В.Козодеров², О.Ю.Казанцев³,
В.И.Бобылев³, Е.В.Дмитриев⁴, В.Д.Егоров⁴,
В.П. Каменцев⁵, В.В.Борзяк²**

¹Московский физико-технический институт (государственный университет)

*²Московский государственный университет им.
М.В.Ломоносова*

³НПО «Лептон», г. Зеленоград

⁴Институт вычислительной математики РАН

⁵Технопарк Тверского государственного университета

**Данная часть совместных исследований
реализуется в рамках проектов:**

- ФЦП «Научные и научно-педагогические кадры инновационной России» на 2009 - 2013 годы.**
- Аналитической ведомственной целевой программы «Развитие научного потенциала высшей школы (2009-2010 годы)».**
- Проектов РФФИ.**
- Хоздоговорной тематики.**

Общие положения

- **Современные системы гиперспектрального аэрокосмического зондирования (сотни спектральных каналов в видимой и ближней инфракрасной области, разрешение в единицы нанометров) способствует повышению точности решения прикладных задач распознавания образов природно-техногенных объектов в сравнении с многоспектральными системами (не превышают десяти спектральных каналов).**
- **Пакеты прикладных программ обработки данных гиперспектрального и многоспектрального зондирования (ERDAS, ENVI и др.), поставляемые зарубежными фирмами, содержат лишь некоторые стандартные процедуры классификации объектов по их аэрокосмическим изображениям.**
- **Имеется необходимость всестороннего рассмотрения классификаторов разного уровня сложности с целью оптимизации вычислительных процедур обработки гиперкубов данных (две пространственные координаты и длина волны).**


Принципы распознавания образов объектов по их гиперспектральным изображениям

- **Распознавание образов (pattern recognition) – обширная область прикладной и вычислительной математики, в которой исследуются особенности компьютерных систем выделять характерные признаки (features) объектов на окружающем их фоне (background) и принимать решения по возможной классификации образов этих объектов на основе сравнения выделенных признаков и текущих измерений состояния объектов.**
- **Типичными являются две разные процедуры распознавания образов объектов по данным дистанционного зондирования: классификация с обучением (supervised classification); классификация без обучения (unsupervised classification), т.е. использование свойства кластеризации объектов в пространстве признаков.**
- **Каждая система распознавания функционирует тем самым в двух модах: обучение (training) и классификация (testing).**



Основополагающие категории расчетных схем распознавания образов природно-техногенных объектов

- **Число каналов аэрокосмического зондирования для матрицы размерности $N = n_1 \times n_2$ для каждого элемента разрешения (пиксела).**
- **Число обучающих пикселей $j \ll N$ для процедур с обучением.**
- **Число классов объектов, заданных априори и подлежащих уточнению в процессе реализации тех или иных классификаторов.**

Типичная форма спектров двух разных объектов, попадающих в поле зрения аппаратуры гиперспектрального зондирования: А – для сухой почвы; В – для зеленой растительности; С – смешанный регистрируемый спектр. А и В – «чистые спектры» (endmembers)



Отображение одного спектра данных гиперспектрального зондирования в виде вектора в двухмерном пространстве (слева) и представление набора из трех спектров (справа) для примера двух каналов – 0.7 мкм и 0.8 мкм




Пример простой решающей функции при разделении множества точек (векторов образов наблюдаемых объектов) на два класса


Если $d(x) = w_1 x_1 + w_2 x_2 + b = 0$ - уравнение разделяющей прямой, где w_i - параметры, b - свободный член, а (x_1, x_2) координаты вектора двумерного пространства признаков, то функцию $d(x)$ можно использовать в качестве решающей (или дискриминантной), поскольку можно утверждать, что образ x принадлежит классу ω_1 , если $d(x) > 0$, и классу ω_2 , если $d(x) < 0$.

Простейшая задача обучения – найти набор (w, b) для пикселей с известными априори классами.

Сложность нахождения наборов (w, b) – возможность переобучения (overtraining), т.е. появление переопределенных систем решаемых уравнений для большого числа обучающих пикселей в сравнении с числом спектральных каналов.




- Общие положения, касающиеся постановки задачи: δ^2 - расстояние Махалобиса – состоятельная мера сходства (подобия) кластеризуемых векторов, когда статистические характеристики образов объектов присутствуют в явном виде**
- **проблема оценки точности распознавания соответствующих объектов должна быть тесно увязана с оценкой информационного содержания данных конкретной аппаратуры с учетом возможной корреляции каналов, т.е. основополагающим является понимание качества прибора и динамического диапазона регистрируемых яркостей;**
 - **результаты классификации гиперспектральных изображений зависят от четырех взаимосвязанных факторов: делимость классов; размер обучающей выборки; размерность признакового пространства; тип классификатора.**





Разъяснение относительно нормального гауссовского распределения векторов

При исходных значениях векторов x , средних значений μ и ковариационной матрицы Σ мера сходства $\delta^2 = (x - \mu)^t \Sigma^{-1} (x - \mu)$ плотности распределения вероятности характеризуется контурными линиями ковариационной матрицы. Чем больше длина выборки, тем меньше дисперсии (на главных диагоналях матрицы Σ) и тем больше значения δ^2 .




Бликие к двухмодовым гистограммы относительных частот появления тех или иных градаций яркости (ось абсцисс) по данным гиперспектрального аэрозондирования для длин волн 670 нм (слева) и 800 нм (справа) создают основания для изначально бинарного разбиения на классы



Постановка задачи распознавания объектов с обучением по тестовой выборке

- Задано пространство исходных спектров – векторов
 $x = (x_1, \dots, x_n)$.
- Задано множество предварительных ответов о разделении классов y (например, -1 и +1).
- Для обучающей выборки задана целевая функция разбиения на классы.
- Требуется построить алгоритм, аппроксимирующую целевую функцию на всем пространстве.

Оптимальная разделяющая гиперплоскость показана зеленым цветом.



Метод опорных векторов (оси характеризуют многомерное признаковое пространство)


Для весовых векторов $w = (w_1, \dots, w_n)$ и свободного члена b производится одновременно максимизация зазора (margin) (минимизируется норма вектора w) и минимизация суммы ошибок всех ξ_i объектов-нарушителей. При нелинейном отображении $\Phi(x)$ решающее правило соответствует $\text{sign}[a(x)]$, где $a(x) = W \Phi(x) + b$.

При этом на объектах обучающей выборки $x_i, i = 1, \dots, I$ решается оптимизационная задача ($\langle \dots \rangle$ - символ скалярного произведения):

$$\frac{1}{2} \langle w, w \rangle + C \sum_i \xi_i \rightarrow \min_{w, b, \xi};$$

$$y_i (\langle w, x_i \rangle - b) \geq 1 - \xi_i, \quad \xi_i \geq 0;$$

$C \geq 0$ – управляющий параметр регуляризации решения.



Построение оптимальной разделяющей гиперплоскости для общего случая линейно неразделимой выборки

Для всех векторов x_i обучающей выборки задача сводится к минимизации квадратичной формы при следующих ограничениях неравенствах (их число равно длине выборки):
 $(\langle w, x_i \rangle + b) \leq -1$, если $y_i = -1$; $(\langle w, x_i \rangle + b) \geq 1$, если $y_i = +1$.

Задача эквивалентна двойственной задаче поиска седловой точки функции Лагранжа:

$$L(w, b, \xi, \alpha, \eta) = \frac{1}{2} \langle w, w \rangle - \sum_i \alpha_i (y_i (\langle w, x_i \rangle + b) - 1) - \sum_i \xi_i (\alpha_i + \eta_i - C),$$

где $\alpha_i = (\alpha_1, \dots, \alpha_I)$ – вектор двойственных переменных решаемой минимаксной задачи (*min* по w и b ; *max* – по α),
 $\eta_i = (\eta_1, \dots, \eta_I)$ – вектор переменных, двойственных по отношению к переменным $\alpha_i = (\alpha_1, \dots, \alpha_I)$.

Необходимое условие седловой точки – равенство нулю производных Лагранжиана

$$\partial L / \partial \mathbf{w} = \mathbf{w} - \sum_i \alpha_i y_i \mathbf{x}_i = 0 \rightarrow \mathbf{w} = \sum_i \alpha_i y_i \mathbf{x}_i, \mathbf{b} = y_i - \langle \mathbf{w}, \mathbf{x}_i \rangle;$$

$$\partial L / \partial \mathbf{b} = - \sum_i \alpha_i y_i = 0 \rightarrow \sum_i \alpha_i y_i = 0;$$

$$\partial L / \partial \xi_i = - \alpha_i - \eta_i + C = 0 \rightarrow \alpha_i + \eta_i = C.$$

Все объекты обучающей выборки $\mathbf{x}_i$ называются опорными векторами (support vector), если $\alpha_i > 0$ и $y_i = \langle \mathbf{w}, \mathbf{x}_i \rangle + b$.

Соответственно, при отступе (margin) $m_i = y_i (\langle \mathbf{w}, \mathbf{x}_i \rangle + b)$ объектов $\mathbf{x}_i$ от границы классов все объекты делятся на три типа:

$\alpha_i = 0; \eta_i = C; \xi_i = 0; m_i > 1$. Объект $\mathbf{x}_i$ классифицируется правильно и находится далеко от разделяющей полосы. Это периферийные объекты.

$0 < \alpha_i < C; 0 < \eta_i < C; \xi_i = 0; m_i = 1$. Объект $\mathbf{x}_i$ классифицируется правильно и лежит в точности на границе разделяющей полосы. Это опорные объекты.

$\alpha_i = C; \eta_i = 0; \xi_i > 0; m_i < 1$. Объект $\mathbf{x}_i$ либо лежит внутри разделяющей полосы, но классифицируется правильно ($0 < \xi_i < 1; 0 < m_i < 1$), либо попадает на границу класса ($\xi_i = 1; m_i = 0$), либо относится к чужому классу ($\xi_i > 1; m_i < 0$). Это объекты-нарушители.


Итог: для быстрого нахождения всех коэффициентов w решается задачи выпуклой оптимизации, имеющая единственное решение

$$\max_{\alpha} \{ \sum_i \alpha_i -$$

$$- \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j \langle x_i, x_j \rangle \};$$

$$0 < \alpha_i < C; \sum_i \alpha_i y_i = 0.$$

Нелинейность вводится с помощью ядерных функций $K(x_i, x_j) = \langle \Phi(x_i) \Phi(x_j) \rangle$, что при отображении $\Phi: X \rightarrow H$ расширяет пространство (X) входных векторов (H - гильбертово пространство со скалярным произведением).



Следствие – сведение задачи бинарной классификации к задаче квадратичного программирования, имеющей единственное решение, относительно двойственных переменных α_i

$$\begin{aligned} \max_{\alpha} \{ \sum_i \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j \Phi(x_i) \Phi(x_j) \}; \\ 0 < \alpha_i < C; \sum_i \alpha_i y_i = 0. \end{aligned}$$

Если перенумеровать объекты так, чтобы первые h объектов оказались опорными, то поскольку $\alpha_i = 0$ для всех неопорных объектов, $i = h+1, \dots, I$, при решающем правиле $\text{sign}[a(x)]$ дискриминантная функция определяется суммированием следующего выражения только по опорным векторам используемой выборки ($i = 1, \dots, h$):

$$a(x) = \sum_i \alpha_i y_i K(x_i, x) + b,$$

где функция $K(x_i, x_j)$ должна быть симметричной $K(x_i, x_j) = K(x_j, x_i)$ и неотрицательно определенной $\int_X \int_X K(x, x') g(x) g(x') dx dx' \geq 0$ для любой функции g .

Отличительная особенность подхода – нет проблемы переобучения, которая присутствует в методе дискриминантного анализа при нахождении набора (w, b) .

Сложности возникающих приложений с ядерными функциями


Ядра могут быть полиномами $K(u, v) = (< u, v > + 1)^2$, гауссовскими функциями $K(u, v) = \exp(-\beta ||u - v||^2)$, где β – параметр и др. Например, если использовать гиперболический тангенс $K(u, v) = \text{th}(k_0 + k_1 < u, v >)$ (классическая нейронная сеть с сигмоидными функциями активации), то это ядро применимо только при $k_0 < 0$ или $k_1 < 0$.

Сложности возникают при переходе от бинарной классификации к проблеме многих классов. Возможные стратегии:


- «каждый против каждого» - решается $S(S-1)/2$ бинарных проблем распознавания пары классов и неким «голосованием» определенный класс получает большинство из ансамбля бинарных классификаторов;
- «один против всех», когда используется правило «победитель забирает всё», т.е. принимается решение, что ценность соответствующей дискриминантной функции наивысшая.

Связь метода опорных векторов с двухслойными нейронными сетями: сеть имеет n входных нейронов и h нейронов в скрытом слое.

- 1. Число нейронов скрытого слоя определяется самим методом решения.**
- 2. Становится понятен смысл двойственных векторов: α_i – это вес, выражающий степень важности ядра $K(x_i, x)$.**
- 3. Появляются возможности распараллеливания вычислений.**




Далее - два примера обработки гиперспектральных изображений (без лесных пожаров и пожар в районе торфоразработки вблизи пос. Редкино)




Летно-полевая кампания 2010 года: участок прибрежной зоны реки Тверца

Фотоизображение




1 - вспаханное поле; 2 - сосновый лес; 3 - лиственный лес; 4 - смешанный лес

Синтезированное RGB-изображение
(232 спектральных канала)




Местоположение обучающих выборок



Нормализованные калиброванные спектры обучающих пикселей, 19 каналов

- лиственный лес
- хвойный лес
- трава (тип 2)
- трава (тип 1)
- песчаная почва
- вспаханное поле
- постройки
- асфальт
- вода




Достоверность результатов классификации и оценки состояния объектов

Определяется с помощью матрицы ошибок, которая рассчитывается по контрольным участкам (не совпадающим с эталонными участками, которые использовались для создания обучающих выборок). Столбцы матрицы – классы объектов, установленные по наземным или эталонным данным. Строки матрицы – классы объектов, полученные в результате предлагаемых этапов обработки многоспектральных или гиперспектральных изображений. На главной диагонали – количество элементов правильной классификации, вне диагонали – ошибочной классификации.

Итог: расчет количества элементов разрешения, ошибочно не попавших в данный класс («ошибка пропуска цели»), а также ошибочно присоединенный к данному классу («ошибка ложной тревоги»). Достоверность – процент правильно классифицированных элементов разрешения от общего количества проверяемых элементов.

Информационная продукция обработки гиперспектральных изображений имеет более высокое пространственное разрешение, чем данные наземных лесотаксационных обследований, и может использоваться для обновления имеющихся карт.

Распознавание объектов по методу опорных векторов (6 каналов с разрешением 100 нм)




Априорная оценка ошибки классификации

		Истинные классы								
		вода	ас-фальт	по-строй-ки	вспа-хан-ное поле	пес-чаная почва	травы (тип 1)	травы (тип 2)	хвой-ный лес	лист-вен-ный лес
Результат классификации	вода	717	0	0	0	0	0	0	0	0
	асфальт	0	188	6	0	0	0	0	0	0
	постройки	0	0	46	0	0	0	0	0	0
	вспаханное поле	0	0	6	1364	0	0	0	0	0
	песчаная почва	0	0	0	0	177	0	0	0	0
	травы (тип 1)	0	0	0	0	0	482	0	0	0
	травы (тип 2)	0	0	0	0	0	0	72	0	0
	хвойный лес	0	0	0	0	0	0	0	470	0
	лиственный лес	0	0	0	0	0	0	0	0	386
	Неклассифицированные пиксели	0	0	13	0	0	0	0	0	0
	общее число обучающих спектров	717	188	71	1364	177	482	72	470	386

- - лиственный лес
- - хвойный лес
- - трава (тип 2)
- - трава (тип 1)
- - песчаная почва
- - вспаханное поле
- - постройки
- - асфальт
- - вода

Распознавание объектов по методу опорных векторов (10 каналов с разрешением 60 нм)




Априорная оценка ошибки классификации

		Истинные классы								
		вода	ас-фальт	по-строй-ки	вспа-хан-ное поле	пес-чаная почва	трав-а (тип 1)	трав-а (тип 2)	хвой-ный лес	листв-вен-ный лес
Результат классификации	вода	717	0	0	0	0	0	0	0	0
	асфальт	0	188	1	0	0	0	0	0	0
	постройки	0	0	54	0	0	0	0	0	0
	вспаханное поле	0	0	3	1364	0	0	0	0	0
	песчаная почва	0	0	0	0	177	0	0	0	0
	трав-а (тип 1)	0	0	0	0	0	482	0	0	0
	трав-а (тип 2)	0	0	0	0	0	0	72	0	0
	хвойный лес	0	0	0	0	0	0	0	470	0
	лиственный лес	0	0	0	0	0	0	0	0	386
	Неклассифицированные пиксели	0	0	13	0	0	0	0	0	0
Общее число обучающих спектров		717	188	71	1364	177	482	72	470	386

- лиственный лес
- хвойный лес
- трава (тип 2)
- трава (тип 1)
- песчаная почва
- вспаханное поле
- постройки
- асфальт
- вода

Специфика летно-полевой и исследовательской кампаний 2010 года – рассмотрение особенностей возникновения и развития торфяных и лесных пожаров. Вверху – аэрофотоснимок территории к северо-западу от пос. Редкино, слева – маршрут самолета, справа внизу – RGB-синтезированное изображение со щели гиперспектрометра. Дата съемки 30.07.2010. Расшифровка: 1 – области закончившегося верхового пожара; 2 – фронт интенсивного горения; 3 – изменение интенсивности шлейфа дыма.





AB100730-1-022-042_*,*



30.07.2010.
10:50:13
N56°38.685'
E36°21.366'





2010-07-30_10-50-13_RGB_10-51-29---.tif

30.07.2010.
10:51:29
N56°38.319'
E36°24.932'







Местоположение выборок (вверху) и их расшифровка (слева) внутри области и в окрестности торфяного пожара, распространяющегося от торфоразработок вблизи пос. Редкино в направлении на северо-восток к поселку Ст. Мелково и р. Волга. Выборки отобраны в соответствии с рекомендациями специалистов Технопарка ТвГУ.





Спектры разных гарей (1-4) и стандартные отклонения спектров отличаются друг от друга: чем ближе гарь расположена к очагу текущего пожара (вверху слева), тем больше у нее амплитуда коротковолновой области спектра; чем дальше от очага, тем больше амплитуда длинноволновой области (внизу справа)






По мере увеличения задымления (справа внизу) в сравнении со слабым задымлением (слева внизу) уменьшается амплитуда длинноволновой области спектра; для дыма вблизи фронта горения (слева вверху) заметен максимум амплитуды спектра в коротковолновой области спектра





Отличительная черта лесной растительности – проявление полосы поглощения хлорофилла (вблизи 670 нм). Для разных типов лесной растительности, находящей за пределами дымовой завесы, наблюдается переход от зеленой лесной растительности (вверху слева) к более разреженной растительности (внизу слева). Вырубка (внизу справа) имеет явное отличие от трех других примеров лесной растительности.



Спектр песчаной почвы (вверху слева) существенно отличается от спектра травянистой растительности (внизу слева и вверху справа). Для сравнения внизу справа снова приведен спектр одного из сильно задымленных участков, используемых для обучения




Распознавание дымов различной интенсивности (сцена 6_1)



-  - дым в зоне горения;
-  - сильное задымление;
-  - среднее задымление;
-  - слабое задымление.

Распознавание объектов (сцена 6_1)



- дым;
- гарь;
- пожелтевшая растительность;
- почва;
- торфозаготовки;
- трава;
- лесная растительность.

Заключение

- **Аэрокосмическая гиперспектрометрия – новейшее достижение научно-технологических приложений в области использования оптических измерительных средств с разрешением в единицы нанометра для получения информационной продукции обработки гиперспектральных изображений.**
- **Продemonстрированы особенности разработки классификаторов (вычислительных процедур распознавания объектов) при обработке данных гиперспектрального зондирования.**
- **Открываются перспективы создания новых программно-алгоритмических средств для распараллеливания вычислительных процессов по распознаванию образов природно-техногенных объектов при решении рассматриваемых прикладных задач.**