Распознавание категорий наземных объектов на основе корреляционных портретов с применением в модели рассеяния атмосферных загрязнений

Б. М. Балтер¹, В. В. Егоров¹, В. А. Котцов¹, М. В. Фаминская²

¹ Институт космических исследований РАН, Москва, 117997, Россия E-mail: victor_egorov@mail.ru ² Российский государственный социальный университет, Москва, 129226, Россия E-mail: faminskaya@mail.ru

Описан метод распознавания эталонных объектов в многоспектральных и гиперспектральных данных дистанционного аэрокосмического зондирования Земли. Метод основан на вычислении межканальных корреляционных матриц и последующем корреляционном сравнении их с аналогичными матрицами эталонных объектов (так называемая двойная корреляция, ДК). Распознавание наземных объектов проводится по максимуму двойной корреляции с эталонами. Поскольку метод чувствителен к пространственной структуре участков, для которых строятся корреляционные портреты, он является естественным дополнением к методам классификации, ориентированным только на средние спектральные показатели, таким, как метод максимума правдоподобия (МП). Мы описываем совместное с МП применение метода ДК в задаче распознавания категорий объектов поверхности, существенных для моделирования рассеяния атмосферных загрязнений, на основе многолетних данных Landsat, организованных в подобие гиперспектральной структуры. Такая имитация гиперспектральных данных является неполной из-за дискретности по спектральной переменной и возможного дрейфа наземных структур со временем, однако это единственный тип данных, систематически доступных в задачах, связанных с индустриальным загрязнением воздуха. Рассчитаны вероятности распознавания и ложной тревоги, а также другие рабочие характеристики. Эффект ДК, измеренный по рабочим кривым для трёх наиболее проблемных для различения категорий в задаче рассеяния загрязнений (индустрия, плотная и неплотная жилая застройка), составляет от 2 до 14 % по сумме ошибок 1-го и 2-го рода. Соответствующий эффект применения ДК к одной реальной задаче рассеяния индустриальных загрязнений — от 2 до 3 % по максимальным почасовым концентрациям в 18 районах города (в одном районе эффект отрицательный) и до 30 % на отдельные даты по тем же районам (для некоторых дат эффект отрицательный).

Ключевые слова: корреляционная матрица, гиперспектральные и многоспектральные данные, эталонные объекты, максимум правдоподобия, рассеяние загрязнений, вероятность распознавания, вероятность ложной тревоги

Одобрена к печати: 10.03.2019 DOI: 10.21046/2070-7401-2019-16-2-29-41

Введение

Проблема использования информации многоспектрального и гиперспектрального зондирования Земли с аэрокосмических платформ оказалась довольно сложной в связи с большим числом спектральных каналов сенсоров, а также пространственной неоднородностью и временной изменчивостью зондируемой поверхности, изменениями условий съёмки и др. Попытки снижения размерности гиперспектральных изображений, например путём преобразования их к главным компонентам, приводят к резкому сокращению объёма данных при сохранении в целом объёма информации, но за счёт ухудшения распознавания некоторых конкретных, особенно мелких, объектов.

Одним из подходов к сокращению объёма гиперспектральных данных с сохранением ключевой информации, необходимой для распознавания наземных объектов, является метод межканальных корреляционных портретов, вычисляемых из спектров гиперспектральных или многоспектральных данных. Достоинство этого метода — устойчивость к изменению абсолютных значений спектральной яркости объектов зондирования, влиянию мешающих

факторов и др. Однако он не получил широкого распространения, вероятно, в связи со сложностью визуальной интерпретации корреляционных портретов и отсутствием алгоритмов их цифровой обработки, которые позволили бы придать их интерпретации более объективный характер.

В настоящей работе описано развитие данного метода, основанное на вычислении корреляции реальных корреляционных портретов с эталонными корреляционными портретами (метод двойной корреляции, ДК) и формировании карт величины этой двойной корреляции как меры сходства участков зондируемой сцены с эталонными объектами (Балтер и др., 2009). Эта мера учитывает как спектральную, так и пространственную изменчивость. Метод защищён патентом РФ 2586405 (Балтер и др., 2016, 2017).

В первой части статьи описан сам метод, во второй — применение метода ДК в сочетании с хорошо известным методом максимума правдоподобия (МП) для улучшения распознавания трудных для различения характеристик: плотной и неплотной застройки, индустриальной территории. Такое распознавание является критичным для расчёта рассеяния индустриальных загрязнений воздуха, которое зависит от типа поверхности, в частности от вида застройки. Приведены количественные характеристики эффекта ДК применительно к распознаванию категорий застройки и соответствующим расчётным концентрациям загрязнений.

Метод двойной корреляции

Способ формирования корреляционных портретов известен сравнительно давно (Biehl, Landgrebe, 2002; Lee, Landgrebe, 1993). Для этого производится вычисление коэффициента межканальной корреляции по данным гиперспектрального куба в пределах некоторого статистически однородного локального участка зондируемой поверхности или отрезка трассы. Корреляционный портрет — это цветокодированное представление межканальной корреляционной матрицы в виде квадрата, где по осям — спектральные каналы, а цвет пикселя портрета отражает величину корреляции пары каналов, соответствующей пикселю (*puc. 1*). В работах (Балтер и др., 1991; Попа и др., 1988; Chekalina et. al., 1992) теоретически исследованы получаемые при этом формы корреляционных портретов. В силу нормированности корреляции корреляционные портреты отражают не средние спектральные характеристики, а пространственную изменчивость зондируемой поверхности, что позволяет извлекать информацию, которая теряется в таких подходах к гиперспектральным данным, как главные компоненты. Интерпретация корреляционных портретов требует разработки специфических алгоритмов работы с ними.



Рис. 1. Корреляционные портреты эталонных типов застройки: *а* — индустрия; *б* — плотная; *в* — неплотная; *с* — спектральные области максимального контраста между ними. По многоспектральным данным Landsat-8: вниз и направо — 7 групп, соответствующих 7 спектральным каналам (разделены чёрными линиями), в каждой 12 дат съёмки. Цветокод корреляции: от фиолетового (–1) до красного (1), серые линии — отсутствие или дефект данных. Цветокод контраста относительно максимально-го значения: от фиолетового (0) до красного (1)

Способ двойной корреляции (ДК) для обработки многоспектральных или гиперспектральных данных (далее для краткости говорим только о последних) позволяет формализовать интерпретацию корреляционных портретов. В его основу положен пофрагментный проход зондируемой поверхности со сравнением матриц межканальных корреляций для каждого фрагмента с матрицей межканальных корреляций эталонов, выбираемых в качестве обучающих участков или построенных по априорным (модельным) данным. Метод впервые описан в работе (Балтер и др., 2006).

Сравнение корреляционных матриц (портретов) локальных участков (объектов) реального изображения с эталонными матрицами производится путём расчёта корреляции этих матриц (двойная корреляция). Результат такого сравнения отражает в виде карты степень сходства пространственно-спектральной изменчивости участка зондируемой территории с эталонными объектами. Пространственная разрешающая способность таких карт ниже, чем у исходных изображений, и соответствует размеру локальных участков, по которым строился корреляционный портрет. В силу чувствительности корреляции именно к вариациям спектра, на карте сходства чётко выделяются границы между объектами. Но это границы не между любыми объектами, а только между теми, которые содержат примерно те же спектральные линии, что и обучающий участок. Таким образом, корреляционная карта сходства есть результат фильтрации исходного гиперспектрального изображения, где роль фильтра выполняет эталонная корреляционная матрица. При этом происходит выделение одних границ и ослабление других. Такая «дифференциальная диагностика» весьма чувствительна к пространственным вариациям тонких спектральных различий классифицируемых объектов на гиперспектральных изображениях. Выбор в качестве критерия величины корреляции — нормированного параметра — существенно снижает зависимость получаемого результата от изменения условий наблюдения.

Эффективность метода зависит от выбора спектрального диапазона, числа и ширины используемых спектральных каналов. Целесообразно производить расчёт не между полными корреляционными портретами (рабочим и эталонным), а между их небольшими спектральными областями, наиболее чувствительными к интересующим нас изменениям состояния объекта. Эти области выбираются исходя из анализа эталонных корреляционных матриц. Например, такие, где максимален контраст между эталонами, соответствующими разным типам объектов (*puc. 1*).



Puc. 2. Карты корреляционного сходства многоспектральных данных Landsat-8 по 12 датам съёмки с эталонными типами застройки: *a* — исходная карта; *б* — результат распознавания этой карты методом МП. Красный цвет — индустриальная, синий — плотная жилая, зелёный — неплотная жилая; корреляции ниже порога не показаны

Для повышения эффективности визуального восприятия получаемая оценка величины ДК на карте сходства может кодироваться цветом. Цветовое кодирование можно использовать для одновременного сравнения сходства с тремя разными объектами-эталонами: показатели сходства с каждым из них можно поэлементно совместить в одно RGB-изображение (*puc. 2a*, см. с. 31). Дальнейшее применение ДК более эффективно, если карты ДК дискретизовать, классифицируя их методом МП, так что в каждой точке будет не мера ДК, а номер присвоенного ей эталонного класса (*puc. 26*). Но сама по себе эта классификация недостаточно точна и применяется как дополнение к обычному МП (см. ниже).

Применение метода в модели рассеяния атмосферных загрязнений

При моделировании рассеяния индустриальных загрязнений воздуха и связанного с этим риска для здоровья населения существенную роль играют характеристики территории, над которой происходит рассеяние. В модели рассеяния AERMOD, которой мы пользуемся в работах по оценке риска, важно, в частности, различие между типами застройки: индустриальной, плотной жилой и неплотной жилой. Эти различия связаны в основном с пространственной структурой застройки и плохо определяются традиционными методами обработки аэрокосмических данных, ориентированными на спектральные различия, в частности методом максимума правдоподобия (МП) и его вариантами. Поскольку гиперспектральные данные не находятся в открытом доступе и/или проходят в стороне от предприятий-загрязнителей, пришлось ориентироваться на многоспектральные данные, составляя из разных дат съёмки пакет-куб, имитирующий гиперспектральную структуру.

Такой пакет был составлен из данных Landsat-8 по Тюмени за 2013—2018 гг. В него вошло 12 дат съёмки, удовлетворявших требованиям по облачности и др. Для каждой даты использовались 7 спектральных каналов, так что куб имел квазиспектральную размерность 84. На первом шаге проводилась классификация этого куба без обучения методом кластеризации Кохонена в качестве «сырья» для последующей обработки с обучающими данными. Были идентифицированы кластеры, более или менее соответствующие требуемым для AERMOD категориям поверхности (получено 10 категорий из полного набора 21 категории AERMOD). Для каждой из 10 категорий из соответствующих кластеров были выделены наиболее характерные обучающие участки, которые использовались в дальнейшей обработке данных (*puc. 3a*).



Рис. 3. Исходные данные для МП: *а* — обучающие участки для МП; *б* — полная ручная классификация, принятая за истинную. Красный цвет — индустрия, тёмно-коричневый — плотная застройка, светло-коричневый — неплотная застройка

Наряду с этим для проверки качества обработки была построена как можно более тщательная ручная классификация территории (*puc. 36*) с использованием снимков высокого разрешения, доступных через Google Earth. Она далее считалась истинной классификацией (ground truth). Затем по обучающим участкам проводилась классификация с обучением методом опорных векторов (пока без учёта двойной корреляции). На *puc. 4* приведены рабочие характеристики результатов. Видно, что наиболее проблемными являются как раз три вышеуказанных варианта застройки (они имеют наихудшую точность). Поэтому далее применение ДК для повышения точности распознавания сосредоточено на этих трёх категориях. Проблема состоит именно в различении этих категорий друг от друга. Если объединить их в одну категорию «застройка», то вероятность её распознавания в оптимальной рабочей точке будет хорошей — около 90 %.



Рис. 4. Рабочие кривые для всех 10 категорий: *а* — вероятность обнаружения в зависимости от порога правдоподобия, ниже которого категория отвергается; *б* — взаимозависимость вероятностей обнаружения и ложной тревоги

Корреляционные матрицы для обучающих участков-эталонов трёх рассматриваемых категорий и построенная по ним RGB-карта сходства с этими категориями, измеряемая двойной корреляцией, приводятся на *рис. 1* и *2а.* Карта сходства дискретизуется обработкой её методом МП по тем же обучающим участкам (см. *рис. 26*). В результате получаются три карты двойной корреляции, по одной для каждой категории, где значения равны единице в том случае, если данная категория распознана по двойной корреляции.

При дальнейшей классификации по МП с учётом ДК для каждого пикселя величина его дискретизованной ДК для каждой из трёх категорий добавляется к правдоподобию этой категории, рассчитанному в данном пикселе по МП. Для каждой категории можно устанавливать порог МП и вес, с которым ДК добавляется к правдоподобию.

Обозначим как *x* вектор данных размерности *n* = 84. На обучающих участках (категория участка обозначается *i* = 1, 2, 3) получаются сигнатуры категорий: нормальные распределения $N[x|m^i, \Sigma^i]$ для *x*, имеющие математические ожидания — векторы *mⁱ* размерности *n* и ковариационные матрицы Σ^i размерности *n*×*n*. Их логарифмические правдоподобия обозначим $L^i(x) = \ln N[x|m^i, \Sigma^i]$. Обычная МП-оценка для наблюдения *x* — это категория $i_{MP}(x) = \arg \max_i \{L^i(x) - T \ge 0, 0\}$, где *T* — порог правдоподобия, ниже которого наблюдение считается нераспознанным (категория 0).

Корреляционные матрицы категорий C_{kl}^{i} (k, l = 1, ..., 84 — каналы вектора x) рассчитываются как:

$$C_{kl}^{i} = \frac{1}{N_{i}} \cdot \frac{\sum_{j} \left(x_{jk} - m_{k}^{i} \right) \cdot \left(x_{jl} - m_{l}^{i} \right)}{\sqrt{\sum_{kk}^{i} \cdot \sum_{ll}^{i}}},$$

где суммирование идёт по обучающему участку для категории *i*, а N_i — число пикселей в этом участке. Аналогично корреляционные матрицы для окрестности Ω пикселя с вектором наблюдений *x* это:

$$C_{kl}(x) = \frac{1}{N_{\Omega}} \cdot \frac{\sum_{j} (x_{jk} - M_{k}) \cdot (x_{jl} - M_{l})}{\sqrt{S_{kk} \cdot S_{ll}}},$$

где M и S — средние и дисперсии x, рассчитанные по окрестности Ω , по которой идёт суммирование. Двойная корреляция этой окрестности с категорией *i*:

$$DC^{i}(x) = \frac{1}{n^{2}} \cdot \frac{\sum_{kl} \left(C_{kl}(x) - MC(x) \right) \cdot \left(C_{kl}^{i}(x) - MI^{i} \right)}{\sqrt{SC \cdot SI^{i}}},$$

где *MC* и *SC* — среднее и дисперсия элементов матрицы $C_{kl}(x)$, рассчитанные по $n \times n$ элементам этой матрицы, по которым идёт суммирование, а *MIⁱ* и *SIⁱ* — соответственные средние и дисперсии элементов матрицы C^i . Для трёхмерного вектора двойной корреляции *DC* с компонентами DC^i (i = 1, 2, 3) рассчитываются сигнатуры на обучающих участках $N(DC|m_{DC}, \Sigma_{DC})$, имеющие математические ожидания — векторы m_{DC} размерности 3 и ковариационные матрицы Σ_{DC} размерности 3×3 . По их логарифмическим правдоподобиям $L^i_{DC}(x) = = \ln N(DC|m^i_{DC}, \Sigma^i_{DC})$ в каждом пикселе x выполняется классификация *DC*(x) методом МП; на выходе — категория $i_{DC}(x) = \arg\max_i \{L^i_{DC}(x) - T_{DC} \ge 0, 0\}$, где T_{DC} — порог (см. *puc. 26*).

МП-оценка с ДК — это категория $i_{MPDC}(x) = \arg \max_i \{L^i(x) - T + D \cdot L^i_{DC}(x) \ge 0, 0\}$, где D — вес, с которым учитывается логарифмическое правдоподобие ДК. Эффект ДК для категории i определяется как разность вероятностей правильного распознавания:

$$\Delta P(i) = P(i_{MPDC}) - P(i_{MP}),$$

где P(i) — вероятность правильного распознавания категории *i*, рассчитанная по всем пикселям. Также эта разность рассчитывается для вероятностей пропуска цели и ложной тревоги (ошибок 1-го и 2-го рода) и суммы этих ошибок, которая служит своего рода интегральным показателем качества распознавания.

На *рис. 5* (см. с. 35) показаны рабочие кривые (с ДК и без ДК), получаемые вариацией порога правдоподобия, по которому проводится классификация: для суммы ошибок распознавания 1-го и 2-го рода, точности распознавания, взаимозависимости вероятностей распознавания и ложной тревоги, точности распознавания как функции веса ДК при оптимальном пороге правдоподобия. (Вариация веса ДК позволяет строить для веса ДК-компоненты рабочие кривые, подобные построенным выше для МП). Использован стандартный подход (ср. *рис. 4*), при котором *вариация порога правдоподобия проводится для каждого рассматриваемого класса изолированно, без учёта конкуренции с другими классами в классификации*.

Приближение изолированных категорий общепринято, но на распознавание влияет не только порог правдоподобия, но и конкуренция между категориями. Поэтому мы построили рабочие кривые также в «нештатном» варианте: для каждой категории — с учётом воздействия всех остальных. При этом за счёт конкуренции категорий вероятность распознавания, естественно, снижается по сравнению с изолированным случаем, так что рабочие кривые не доходят до вероятности 1. Эти кривые приведены на *рис. 6* (см. с. 36) как функция

веса ДК (*puc. 6а* — для суммы ошибок распознавания 1-го и 2-го рода, *puc. 6б* — для точности распознавания) и как функция порога правдоподобия (*puc. 6в* — для вероятностей распознавания и ложной тревоги, *puc. 6г* — для точности распознавания).



Рис. 5. «Стандартный» вариант в изолированном приближении: a — сумма ошибки 1-го и 2-го рода в зависимости от порога правдоподобия, ниже которого категория отвергается; δ — вероятность распознавания в зависимости от порога; a — рабочие кривые каждой категории: взаимозависимость вероятностей обнаружения и ложной тревоги; c — вероятность распознавания в зависимости от веса ДК

Из кривых изолированного случая вытекают следующие выводы об эффекте ДК:

- В рассматриваемом приближении изолированной категории распознавание всех трёх категорий улучшается за счёт ДК при оптимальном для распознавания пороге по сумме ошибок 1-го и 2-го рода (порог около 9,5): на 0,14 — для индустрии, на 0,06 — для плотной застройки и на 0,02 — для неплотной. При других порогах эффект ДК может доходить до 0,3 для индустрии и 0,17 для плотной и неплотной застройки. Эти пороги не оптимальны для распознавания, но могут встретиться в реальных задачах, когда применяются стандартные пороги по умолчанию.
- Распознавание улучшается с увеличением веса ДК, но затем выходит на насыщение.



Рис. 6. «Нештатный» (совместный) вариант: *а* — сумма ошибки 1-го и 2-го рода; *б* — вероятность распознавания; *в* — взаимозависимость вероятностей обнаружения и ложной тревоги; *г* — вероятность распознавания в зависимости от порога правдоподобия

Из кривых «совместного» случая вытекают следующие выводы об эффекте ДК:

- Эффект ДК весьма существенен для индустрии, для плотной застройки менее существенен, а для неплотной отрицателен.
- Существует оптимальное значение веса (~40), с которым надо учитывать ДК: малые значения не дают эффекта, а слишком большие, наоборот, ухудшают классификацию, так как сама по себе ДК классифицирует хуже, чем МП, и может быть использована лишь как дополнение. В качестве критерия оптимальности веса ДК мы использовали либо максимум суммы вероятностей правильного распознавания по всем трём категориям, либо минимум суммы ошибок 1-го и 2-го рода по категориям. Это оптимальное значение и используется далее. Количественная оценка эффекта ДК в данном случае приводится в *табл. 1.* Он максимален для индустрии и плотной застройки (до 0,15–0,18). В критерий оптимальности веса ДК можно ввести веса, отражающие важность каждой категории для решаемой задачи, но в данной работе для их выбора не было оснований.

Вероятность ложной тревоги	0,02	0,04	0,06	0,08	0,1
Индустрия МП	0,10	0,18	0,26	0,31	0,35
Индустрия МП+ДК	0,08	0,19	0,30	0,40	0,50
Плотная застройка МП	0,16	0,30	0,40	0,45	0,50
Плотная застройка МП+ДК	0,22	0,42	0,55	0,63	0,66
Неплотная застройка МП	0,20	0,31	0,39	0,45	0,48
Неплотная застройка МП+ДК	0,25	0,36	0,41	0,45	0,46

Таблица 1. Вероятность распознавания в зависимости от вероятности ложной тревоги с ДК и без ДК. Выделены области рабочих кривых, где ДК имеет преимущество

Построенная классификация может быть применена в модели рассеяния AERMOD. На *рис.* 7 представлена наиболее существенная характеристика местности — мелкая неровность, определяющая рассеяние выбросов загрязнителей в AERMOD (для одного из четырёх сезонов). Вариант с ДК ближе к «истинной» классификации: без ДК часть пикселей типа «индустрия» неверно классифицирована как «плотная застройка».



Рис. 7. Неровность местности по AERMOD для летнего сезона по результатам классификации с ДК и без ДК. Цветокод: от фиолетового (0,1 м) до красного (>1 м), белый — менее 0,1 м. Масштаб 2×2 км

Расчёт рассеяния загрязнителей от основных индустриальных источников включает определение почасовых концентраций SO₂ за год на сетке размером 10×10 км вокруг промзоны без ДК (x_1) и с ДК (x_2). Точность измеряется отношением к расчёту на основе «истинной» классификации территории (x_0). Мера пользы от ДК выражается величиной $D = |x_1/x_0 - 1| - |x_2/x_0 - 1|$. Для разных расчётных точек, загрязнителей, моментов времени D может различаться, в том числе быть отрицательной, так что ДК приносит не пользу, а «вред». Поэтому для оценки эффекта ДК необходимо перейти к агрегированным по времени и пространству показателям. В первом варианте эффект ДК можно измерять, беря максимумы почасовых концентраций за год в роли x_0 , x_1 , x_2 , а во втором варианте — рассчитывая D для каждого момента времени и беря её максимум за год (или минимум её отрицательных величин как меру «вреда» от ДК). Кроме того, мы агрегируем результаты по точкам каждого района, используя максимум по району (минимум для отрицательных значений D) или среднее по району.

В *табл. 2* показаны результаты сравнения в первом варианте с ДК и без ДК. В большинстве районов мера D положительная и меняется от -5 до 3%, составляя в среднем по районам 2%. Таким образом, на агрегированные по времени величины ДК оказывают небольшое положительное влияние в смысле повышения точности.

	Среднее		0,02		0,35	0,24	0,11		0,22	0,14	0,08																	
	18	-	0,006		0,32	0,22	0,10		0,20	0,11	0,09																	
	17																				0,031		0,47	0,25	0,22		0,20	0, 12
	16		0,024		0,38	0,33	0,05		0, 21	0, 17	0,04																	
T	15	ну	Hy	Hy	Hy	ну	0,021	ну	0,50	0,50	0,00	ły	0,35	0,26	0,09													
milound	14	по райс	0,024	по райс	0,60	0,50	0,10	то район	0,36	0,26	0,10																	
WAAR O	13	аксимум	0	аксимум	0,61	0,50	0,11	і ээндас	0,33	0, 17	0,16																	
	12	с ДК, ма	0,002	с ДК, ма	0,58	0, 29	0, 29	1 с ДК, с	0,26	0, 14	0,12																	
ť Y	11	ез ДК и	-0,05	ез ДК и	0,48	0,48	0,00	6e3 ДК 1	0,21	0,25	0,04																	
	10	раций б	0,022	раций б	0,28	0,25	0,03	гтраций	0,16	0,12	0,04																	
	6	концент	0,026	концент	0,20	0,10	0,10	к концен	0,20	0,10	0,10																	
	8	lacobblx	0,026	lacobbix	0,20	0,10	0,10	часовыл	0,20	0,10	0,10																	
1101 1110	7	тод поч	0,002	OCTE HOU	0,13	0,10	0,03	ность по	0,13	0,10	0,03																	
VIGGOOD	9	JIPHPIX 38	0,021	год разн	0,21	0,13	0,08	і год разі	0,18	0,12	0,06																	
1 011 110 1	5	лаксима.	0,029	ьная за	0,18	0,09	0,09	льная за	0,18	0,09	0,09																	
	4	I3HOCT5	0,034	аксимал	0,38	0,10	0,28	Лаксима	0,26	0,10	0,17																	
-	3	P_{a}	0,025	M	0,22	0,10	0,12	N	0,17	0,10	0,07																	
	2		0,017		0,22	0,10	0,12		0,15	0,10	0,05																	
	1		0,031		0,25	0,12	0,13		0,20	0,11	0,09																	
	№ района		Выигрыш		Выигрыш	Проигрыш	Разность		Выигрыш	Проигрыш	Разность																	

Таблица 2. Выигрыш от применения ДК, проигрыш (без знака) и их разность. Максимум почасовых значений. Последний столбец — среднее по всем районам

.....

....

Однако во многих случаях необходим более детальный анализ концентраций на конкретный момент времени. Здесь применим второй вариант, дающий оценку максимально возможного почасового *D*. В *табл. 2* приведена разность максимума положительных и минимума отрицательных *D*. В большинстве районов максимальная польза от ДК превышает максимальный «вред» довольно значительно: до 30 % в отдельных точках, до 16 % в среднем по каждому району, около 10 % в среднем по всем районам. Наибольший часовой выигрыш от ДК достигает 60 %, а проигрыш — 50 %.

Выводы

Метод двойной корреляции (ДК) применим как к гиперспектральным данным, так и к их имитации путём «пакетирования» многоспектральных данных различных дат съёмки. Пакетированные данные хуже для ДК, чем гиперспектральные, из-за дискретности по спектральной переменной и возможного дрейфа наземных структур со временем. Однако это единственный тип данных, систематически доступный в задачах, связанных с индустриальным загрязнением воздуха, и продемонстрированная в работе возможность применения ДК к таким данным имеет практическое значение. Метод может использоваться как дополнение к методу максимального правдоподобия (МП), улучшающее распознавание сложных пространственно-спектральных структур, как показано на примере различения типов городской застройки, важных для рассеяния индустриальных загрязнений воздуха. Для этого случая получены оценки эффекта комбинации МП+ДК сравнительно с чистым МП. Эффект составляет от единиц до первых десятков процентов по точности распознавания, сумме ошибок 1-го и 2-го рода и расчётным максимальным концентрациям загрязнителей. Для наиболее распространённой задачи оценки максимальных за год почасовых концентраций их уточнение с помощью ДК в среднем по расчётной территории составляет около 2 %, поэтому можно констатировать целесообразность применения ДК для этой задачи, хотя и с небольшим эффектом. Это улучшение достаточно устойчиво по территории: есть только один район из 18, где применение ДК ухудшает результаты. В более сложной и менее распространённой задаче анализа концентраций на конкретный момент времени их уточнение с помощью ДК в среднем по расчётной территории и времени составляет около 10 %. Оно также устойчиво по территории, однако гораздо менее устойчиво по времени: для значительного числа часовых интервалов ДК даёт ухудшение оценок. К таким задачам метод ДК, на наш взгляд, применим при дополнительных условиях, например при сглаживании его эффекта усреднением за достаточно длительный интервал времени.

Литература

- 1. *Балтер Б. М., Егоров В. В., Кузьмин А.А., Чекалина Т. И.* Применение спектрально-корреляционных методов и теории катастроф в изучении пространственной неоднородности земной поверхности // Исследование Земли из космоса. 1991. Т. 10. № 5. С. 10–15.
- 2. Балтер Б. М., Балтер Д. Б., Котцов В. А. Обработка гиперспектральных данных по Земле и Марсу // Современные проблемы дистанционного зондирования Земли из космоса. 2006. Вып. 3. № 1. С. 68–76.
- 3. Балтер Б. М., Егоров В. В., Котцов В. А., Стальная М. В. Корреляционные портреты гиперспектральных данных дистанционного зондирования // Всерос. научно-техн. конф. «Современные проблемы определения ориентации и навигации космических аппаратов»: сб. тр. конф. Россия, Таруса, 22–25 сент. 2008. М.: ИКИ РАН, 2009. С. 510–518.
- 4. *Балтер Б. М., Егоров В. В., Котцов В. А.* Способ преобразования изображения. Патент РФ 2586405. Рег. 10.06.2016.
- 5. *Балтер Б. М., Егоров В. В., Котцов В. А.* Новые возможности корреляционного анализа для систем технического зрения // Техническое зрение. 2017. № 1. С. 53–59.
- 6. Попа А., Балтер Б. М., Ганзориг М., Егоров В. В. Особенности корреляционной структуры спектра оптического сигнала, восходящего от зондируемых объектов (на примере морской поверхности) // Исследование Земли из космоса. 1988. Т. 7. № 3. С. 23–30.

- 7. *Biehl L., Landgrebe D.* MultiSpec a tool for multispectral–hyperspectral image data analysis // Computers and Geosciences. 2002. V. 28. Iss. 10. P. 1153–1159.
- 8. *Chekalina T. I., Popova I. V., Balter B. M., Egorov V. V.* Correlation portraits and neural networks for spaceborne high-resolution spectrometry // Proc. ISSSR Intern. Symp. Maui, Hawaii. 1992. V. 2. P. 1137–1149.
- 9. *Lee C., Landgrebe D.* Analyzing High Dimensional Multispectral Data // IEEE Trans. Geoscience and Remote Sensing. 1993. V. 31. P. 792–800.

Recognition of Earth surface categories based on correlation portraits and its use in modeling atmospheric pollution dispersion

B. M. Balter¹, V. V. Egorov¹, V. A. Kottsov¹, M. V. Faminskaya²

 ¹ Space Research Institute RAS, Moscow 117997, Russia E-mail: victor_egorov@mail.ru
² Russian State Social University, Moscow 129226, Russia E-mail: faminskaya@mail.ru

We describe a method for recognition of template objects in multi- and hyperspectral remote sensing data. The method uses the matrices of correlation between spectral channels and compares them to correlation matrices of template objects using the correlation between these matrices as a measure of similarity (so called double correlation, DC). Templates are recognized in remote sensing data using the maximum value of DC between a template and a fragment of data. The method is sensitive to spatial variations within the fragment analyzed; thus, it can serve as a complement to methods of classification based on averaged spectra, such as maximum likelihood (ML). We describe adding DC to ML in classification of multitemporal Landsat data stacked like a hyperspectral cube for recognition of surface types, which are important in modeling of air pollution dispersion. Such imitation of hyperspectral data is incomplete because it lacks spectral continuity and is vulnerable to temporal drift of target objects but it is the only type of data systematically available for industrial air pollution studies. We calculate the probabilities of recognition and false alarm as functions of ML threshold and DC weight. For three surface types, which are similar spectrally but have different spatial structures and so are potential targets for DC (industrial, dense residential and low intensity residential), the effect of DC measured by improvement of the sum of missed target and false alarm probabilities is between 2 and 14 %. The resulting effect for a real problem of modeling the maximal hourly industrial pollutant concentrations in a city is 2-3% for yearly maxima and up to 30% for specific dates. Although for some districts and dates, the effect of DC is negative, on the whole, DC improves the modeling accuracy.

Keywords: correlation matrix, hyperspectral and multispectral data, template objects, maximum likelihood, pollutant dispersion, probability of recognition, probability of false alarm

Accepted: 10.03.2019 DOI: 10.21046/2070-7401-2019-16-2-29-41

References

- 1. Balter B. M., Egorov V.V., Kuzmin A.A., Chekalina T. I., Primenenie spektral'no-korrelyatsionnykh metodov i teorii katastrof v izuchenii prostranstvennoi neodnorodnosti zemnoi poverkhnosti (Using spectro-correlational methods and catastrophe theory for studies of spatial nonuniformity of Earth surface), *Isslevovanie Zemli iz kosmosa*, 1991, Vol. 10, No. 5, pp. 10–15.
- 2. Balter B. M., Balter D. B., Kottsov V.A., Obrabotka giperspektral'nykh dannykh po Zemle i Marsu (Processing of hyperspectral data on Earth and Mars), *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2006, Vol. 3, No. 1, pp. 68–76.
- 3. Balter B. M., Egorov V. V., Kottsov V. A., Stalnaya M. V., Korrelyatsionnye portrety giperspektral'nykh dannykh distantsionnogo zondirovaniya (Correlation portraits of hyperspectral remote sensing data), *Vseros*siyskaya nauchno-tekhnicheskaya konferentsiya "Sovremennye problemy opredeleniya orientatsii i navigatsii

kosmicheskikh apparatov" (All-Russia Scientific and Technical Conf. "Current Problems of Orientation and Navigation of Spacecraft"), Proc., Russia, Tarusa, 22–25 Sept. 2008, Moscow, IKI RAN, 2009, pp. 510–518.

- 4. Balter B. M., Egorov V. V., Kottsov V. A., *Sposob preobrazovaniya izobrazheniya* (Method of converting the image), Patent RU 2586405, Reg. 10.06.2016.
- 5. Balter B. M., Egorov V. V., Kottsov V. A., Novye vozmozhnosti korrelyatsionnogo analiza dlya system tekhnicheskogo zreniya (New capabilities of correlation analysis for systems of technical vision), *Tekhnicheskoe zrenie*, 2017, No. 1, pp. 53–59.
- Popa A., Balter B. M., Ganzorig M., Egorov V.V., Osobennosti korrelyatsionnoi struktury spektra opticheskogo signala, voskhodyashchego ot zondiruemykh ob'ektov na primere morskoi poverkhnosti (Characteristics of spectral correlation structure of optical signal from remotely sensed objects exemplified by sea surface), *Isslevovanie Zemli iz kosmosa*, 1988, Vol. 7, No. 3, pp. 23–30.
- 7. Biehl L., Landgrebe D., MultiSpec a tool for multispectral–hyperspectral image data analysis, *Computers and Geosciences*, 2002, Vol. 28, No. 10, pp. 1153–1159.
- 8. Chekalina T. I., Popova I. V., Balter B. M., Egorov V. V., Correlation portraits and neural networks for spaceborne high-resolution spectrometry, *Proc. ISSSR Intern. Symp.*, Maui, Hawaii, 1992, Vol. 2, pp. 1137–1149.
- 9. Lee C., Landgrebe D., Analyzing High Dimensional Multispectral Data, *IEEE Transactions on Geoscience and Remote Sensing*, 1993, Vol. 31, pp. 792–800.