

И. К. ВАСИЛЬЕВА, В. В. ЛУКИН

Национальный аэрокосмический университет им. Н. Е. Жуковского "ХАИ", Украина

АНАЛИЗ МЕТОДОВ ПОСТКЛАССИФИКАЦИОННОЙ ОБРАБОТКИ МНОГОКАНАЛЬНЫХ ИЗОБРАЖЕНИЙ

Предметом изучения в статье являются методы морфологической пространственной фильтрации изображений в псевдоцветах, полученных в результате статистической сегментации многоканальных спутниковых снимков. **Целью** является исследование эффективности различных вариантов методов постклассификационной обработки изображений для повышения вероятности правильного распознавания объектов наблюдения. **Задачи:** выбрать математическую модель для описания обучающих образов классов объектов; реализовать процедуру статистической контролируемой классификации по методу максимального правдоподобия; оценить результаты выделения объектов на тестовом изображении по критерию эмпирической вероятности правильного распознавания; формализовать процедуры локальной объектно-ориентированной фильтрации сегментированного изображения; исследовать эффективность процедур ранговой и взвешенной медианной фильтрации с учетом результатов классификации по k -ближайшим соседям в окне фильтра. Используемыми **методами** являются: методы аппроксимации эмпирических распределений, статистические методы распознавания, методы теории вероятностей и математической статистики, методы локальной пространственной фильтрации. Получены следующие **результаты**. Предложена методика синтеза универсальной математической модели для описания негауссовых сигнальных признаков образов объектов на многоканальных изображениях на базе многомерного варианта S_V -распределения Джонсона; данная модель применялась для статистической попиксельной классификации исходного спутникового снимка. Реализованы алгоритмы локальной постклассификационной обработки в окрестности границ выделенных сегментов. Выполнен анализ эффективности разработанных алгоритмов на основании оценок вероятностей правильного распознавания классов. **Выводы.** Научная новизна полученных результатов состоит в следующем: получили дальнейшее развитие комбинированные подходы к процедурам распознавания образов – показано, что использование методов локальной объектно-ориентированной фильтрации сегментированных изображений позволяет уменьшить количество точечных ошибок поэлементной классификации площадных объектов.

Ключевые слова: классификация; аппроксимация; распределение Джонсона; пространственная фильтрация; вероятность правильного распознавания.

Введение

Классификация, или распознавание (при неполной априорной информации о классах), представляет собой отнесение наблюдаемого объекта к одному из взаимоисключающих классов $\{A\} = \{a_1, a_2, \dots, a_k\}$. Поскольку объект задается матрицей наблюдений $[X] = \{x_{ij}\}_{p \times n}$ (p – количество признаков, n – количество измерений каждого признака), то полагают, что существует однозначное отображение $\{X\} \rightarrow \{A\}$ или, что эквивалентно, $\{X\} \rightarrow \{k\}$, где k – конечное множество натуральных чисел – номеров классов объектов. Такое отображение реализует функция $d(X) = k$, принимающая целочисленные значения. Особенностью реальных задач классификации является то, что результаты наблюдений подвержены случайным возмущениям, вероятностный характер которых сказывается на

всех стадиях, начиная от процесса получения измерений и до вычислений значений функции преобразования $d(\{x_{ij}\})$. Поскольку наблюдения x_{ij} – реализации случайных величин, преобразование $d(X)$ – случайная функция, то номер класса также оказывается случайной величиной. Таким образом, разработка методов распознавания неизбежно связана с исследованием случайных отображений и основана на информационно-статистических методах формирования признакового пространства, непараметрического оценивания плотностей вероятностей и принятия решений [1].

В частности, при обработке многоканальных (например, цветных или мультиспектральных) снимков одними из основных классификационных признаков являются яркостные (спектральные) признаки, т.к. они формируют многомерную числовую характеристику каждого пиксела анализируемого изображения, связанную с зарегистрированной

спектральной отражательной или излучательной способностью объектов сцены. Несмотря на то, что различные природные объекты обладают специфическими спектральными характеристиками, свойства объектов не постоянны во времени, зависят от степени освещенности, прозрачности атмосферы, угла поля зрения съемочной системы, рельефа местности и т.п. Таким образом, образы объектов местности на изображении формируются в зависимости от пространственного распределения их спектральной яркости и изменяющихся оптико-геометрических условий съемки. Кроме того, в процессе формирования изображений канал передачи информации может вносить дополнительные пространственно-частотные искажения, что приводит к потере пространственного разрешения. Это приводит к размытию структуры изображений объектов и радиометрическим искажениям, обусловленным светорассеянием в атмосфере. В результате искажаются шкалы тонопередачи и цветопередачи и снижается контраст; при этом степень искажений различна в различных зонах. Влияние этих воздействий приводит к усилению стохастичности и размытию структуры изображения, и, соответственно, к уменьшению достоверности интерпретации изображений объектов. К общепринятым способам повышения достоверности классификации относятся повышение точности измерений и увеличения размерности пространства признаков. Технически это наиболее просто сделать для яркостных признаков, увеличивая число каналов многозональной съемочной аппаратуры или используя многовременные снимки.

При интерпретации снимков, основанной на спектральных признаках объектов, применяют два подхода [2]:

- преобразование спектрального пространства признаков с целью подчеркивания различий объектов, в т.ч. повышение контрастности снимка, квантование снимка по яркости, создание изображений в синтезированных цветах и индексных изображений;

- попиксельная классификация изображений; при этом считают, что каждый пиксел образа объекта сохраняет спектральные признаки всего объекта, а целенаправленные комбинации признаков способны надежной идентификации объектов.

Алгоритмы попиксельной (или пиксельно-ориентированной) классификации позволяют решать достаточно большое множество задач в области анализа изображений и тематического дешифрирования данных дистанционного зондирования Земли (ДЗЗ). Однако к их недостаткам относится то, что решение о классе объекта принимается для каждого отдельного пиксела, без учета особенностей локальной структуры изображения. Такой подход вполне оправдан для обнаружения на снимках ком-

пактных (точечных) объектов, которые локализируются в небольшой части пространства, но, как правило, недостаточно эффективен для достоверного выделения линейных (пространственно-протяженных) и площадных объектов, поскольку из-за ошибок попиксельной классификации искажается геометрическая форма и размеры объектов, нарушается их связность и пространственное распределение элементов структуры. С учетом этого, для уменьшения количества ошибок поэлементного распознавания образов предлагается комплексный подход, включающий этап статистической сегментации изображения на однородные области по спектральным признакам (цветовым компонентам R, G, B) и этап постклассификационной обработки изображения в псевдоцветах, реализующий определенный алгоритм локальной морфологической фильтрации с учетом топологических свойств объектов [3, 4].

Целью работы являлось исследование эффективности алгоритмов пространственной фильтрации для повышения вероятности правильного распознавания объектов на многоканальных снимках ДЗЗ.

1. Этап статистической сегментации

Согласно теории распознавания образов, для классификации выборочное пространство признаков нужно разделить на замкнутые непересекающиеся области G_k , $k = 1, 2, \dots, K$, каждая из которых содержит значения признаков, наиболее характерные для одного из классов объектов. Тогда каждый пиксел изображения с пространственными координатами (i, j) приписывают тому классу, в область которого попал его вектор признаков. Обучающие образы каждого класса используются для вычисления оценок параметров соответствующей дискриминантной функции, после чего структура классификатора становится фиксированной, и качество его работы будет зависеть только от того, насколько хорошо реальные совокупности образов отвечают эталонным описаниям классов объектов.

Правило принятия решения формируют на основе признаков типичных объектов, принадлежность которых к определенному классу известна (например, признаки эталонных объектов на тестовых участках). В теории статистических решений все виды решающих правил основаны на формировании отношения правдоподобия L и его сравнения с определенным порогом c , значение которого определяется выбранным критерием качества [1]:

$$L = \frac{f(\bar{x}|a_2)}{f(\bar{x}|a_1)} \geq c, \quad (1)$$

где $f(\bar{x}|a_j)$ – условная многомерная плотность вероятности выборочных значений вектора признаков

\bar{x} при условии их принадлежности к классу a_j .

При построении многоальтернативного решающего правила ($K > 2$) используют критерий максимального правдоподобия: считают, что контрольная выборка \bar{x} (измеренные значения сигнальных признаков в текущем пикселе изображения) принадлежит классу a_n , $1 \leq n \leq K$, для которого функция правдоподобия максимальна:

$$f(\bar{x}|a_n) = \max_{1 \leq k \leq K} \{f(\bar{x}|a_k)\} \Rightarrow \bar{x} \in a_n. \quad (2)$$

Критерий максимального правдоподобия позволяет исключить неопределенность решения (когда ни один из классов нельзя считать предпочтительнее остальных), не требует знания априорных вероятностей классов и функции потерь, позволяет оценивать достоверность решений, обобщается на случай многих классов, прост в вычислениях.

Поскольку на практике плотности $f(\bar{x}|a_k)$ либо полностью неизвестны, либо, в лучшем случае, известен их вид, но неизвестны параметры, то в правую часть (1) подставляются оценки $\hat{f}(\bar{x}|a_k)$, получаемые на этапе обучения [5].

При распознавании сравнительно небольшого числа классов, когда выбраны такие тестовые участки, достоверность классификации которых можно проверить по наземным данным, или когда можно выделить хорошо различимые, однородные области, представляющие каждый класс, применяют методы «обучения с учителем».

Для исследования эффективности методов снижения ошибок классификации образов на многоканальных снимках ДЗЗ [6] было выбрано реальное изображение земной поверхности в условных цветах R, G, B, сформированное по данным трех спектральных каналов спутника Landsat-TM с длинами волн 0,66 мкм, 0,56 мкм и 0,49 мкм.

На полученном цветном изображении [7] (рис. 1) были выделены пять обобщенных классов объектов природного и антропогенного происхождения: 1 – «почва», 2 – «трава», 3 – «вода», 4 – «строения», 5 – «кусты»; при этом классы 3 и 4 содержали как площадные, так и линейные объекты: класс «вода» = {озеро, река}, класс «строения» = {здания, дороги}.

Для формирования обучающих выборок (фрагментов исходного изображения, содержащих объекты только одного класса) использовались цветовые маски [7, 8] (рис. 2):

– каждый класс a_k кодировался определенным цветом палитры C_k ;

– для каждого v -го пиксела маски M , помеченного цветом класса a_k , определялся соответствующий v -й пиксел исходного изображения S (

такими же пространственными координатами (i, j) , и значения интенсивностей этого пиксела в каналах R, G, B сохранялись в массивах обучающих выборок $\{R_v^{(k)}, G_v^{(k)}, B_v^{(k)}\}$ класса a_k .

Как показали результаты статистического анализа обучающих выборок, цветовые компоненты классов характеризуются негауссовыми распределениями и наличием сильных корреляционных связей (оценки нормированных коэффициентов корреляции между компонентами имеют значения 0,714...0,989), поэтому для их описания целесообразно применять многопараметрические законы распределения (ЗР), основанные на нелинейных преобразованиях нормальных случайных величин.



Рис. 1. Исходное изображение (снимок Landsat-TM)




Рис. 2. Цветовые маски для формирования обучающих выборок классов

За счет большого количества параметров (3...5) такие модели обладают высокой степенью универсальности, а использование нормального закона в качестве базового позволяет не выходить за рамки корреляционной теории. К числу универсальных вероятностных моделей относится система распределений Джонсона $\{S_L, S_B, S_U\}$, которая основана на нелинейных преобразованиях вида [9]

$$z = \gamma + \eta \cdot \tau(x, \varepsilon, \lambda),$$

обеспечивающих преобразование случайной величины x в случайную величину z с нормальным законом распределения. Преобразование Джонсона имеет два параметра формы (η и γ) и два параметра масштаба (ε и λ); функция $\tau(\bullet)$ определяется типом преобразования.

При $\tau(x, \varepsilon, \lambda) = \ln[(x - \varepsilon)/(\varepsilon - x + \lambda)]$, $\eta > 0$, $\gamma \in (-\infty, +\infty)$, $\lambda > 0$, $\varepsilon \in (-\infty, +\infty)$, $\varepsilon \leq x \leq \varepsilon + \lambda$ плотность распределения величины x имеет вид:

$$f(x) = \frac{\eta\lambda}{\sqrt{2\pi}(x - \varepsilon)(\varepsilon + \lambda - x)} e^{-\frac{1}{2}\left(\gamma + \eta \ln \frac{x - \varepsilon}{\varepsilon + \lambda - x}\right)^2}. \quad (3)$$

S_B -распределение Джонсона (3) позволяет аппроксимировать практически любые унимодальные и широкий спектр бимодальных распределений (рис. 3). Оценки параметров закона распределения $\bar{\theta} = \{\varepsilon, \lambda, \eta, \gamma\}$ находились путем численной оптимизации целевой функции, минимизирующей суммарную квадратичную ошибку представления эмпирического распределения (гистограммы) теоретической моделью (3).




Рис. 3. Форма S_B -распределения Джонсона при различных значениях параметров формы η и γ

Для более адекватного описания бимодальных распределений параметры ЗР оценивались отдельно для каждой моды эмпирического распределения; результирующие оценки имели вид:

$$\theta_i^{(k)}(x_j) = \begin{cases} \theta_{i,1}^{(k)}, & x_j < X_{j,k}; \\ \theta_{i,2}^{(k)}, & x_j \geq X_{j,k}, \end{cases}$$

где $\bar{x} = \{R, G, B\}$;

$X_{j,k}$ – пороговое значение j -й цветовой компоненты k -го класса (точка минимума гистограммы на интервале значений между модами эмпирического распределения).

Вид гистограмм признаков и соответствующие эталонные описания цветowych компонент классов 2, 4 показаны на рис. 4, 5.




Рис. 4. Гистограммы и эталонные описания цветowych компонент класса 2:
а – R; б – G; в – B




Рис. 5. Гистограммы и эталонные описания цветových компонент класса 4: а – R; б – G; в – B

Как показано на рис. 6, области, занимаемые классами в признаковом пространстве, существенно перекрываются. Поскольку вероятности ошибочных решений количественно выражают площади пересечения условных по классу плотностей распределения $f(x|a_k)$ (ограниченные порогами принятия решений), для повышения достоверности распознавания можно увеличить размерность вектора признаков. Модели p -мерных признаков должны описывать ЗР отдельных компонент вектора наблюдений и корреляционные связи между ними.

Многомерный вариант ЗР (3) имеет вид [10]

$$f(\bar{x}|a) = (2\pi)^{-p/2} \|\mathbf{R}\|^{-1/2} \prod_{i=1}^p \frac{\eta_i \lambda_i}{(x_i - \varepsilon_i)(\varepsilon_i + \lambda_i - x_i)} \times \exp \left[-\frac{1}{2} \sum_{i,j=1}^p \mathbf{R}_{ij}^{-1} \left(\gamma_i + \eta_i \ln \frac{x_i - \varepsilon_i}{\varepsilon_i + \lambda_i - x_i} \right) \times \left(\gamma_j + \eta_j \ln \frac{x_j - \varepsilon_j}{\varepsilon_j + \lambda_j - x_j} \right) \right], \quad (4)$$

где p – размерность вектора признаков;
 \mathbf{R} – выборочная корреляционная матрица.




Рис. 6. Вид статистических моделей цветových компонент пяти классов (плотности распределения R, G, B класса 3 – «вода» умножены на 0,2 для лучшей визуализации моделей других классов): а – R; б – G; в – B

Результаты распознавания классов ($K = 5$) на исходном снимке (см. рис. 1) по критерию максимального правдоподобия показаны на рис. 7.

Для визуальной экспертной оценки качества распознавания классов была выполнена процедура оконтуривания статистически однородных по векторному цветовому признаку $\{R, G, B\}$ областей.

Результаты выделения контуров распознанных объектов на сегментированном изображении (рис. 7) иллюстрирует рис. 8; показано, что однородные регионы разделены на множество отдельных сегментов, что обусловлено ошибками попиксельной статистической классификации.




Рис. 7. Результаты распознавания классов по критерию максимального правдоподобия




Рис. 8. Результаты выделения контуров объектов на сегментированном снимке

2. Этап постклассификационной обработки

Поэлементная классификация пикселей позволяет сегментировать изображение на области, относящиеся к различным классам. Путем цветового кодирования результаты распознавания можно представить в виде K -арного изображения в псевдоцветах (K – число классов). Ошибки распознавания при этом визуально проявляются в нарушении топологических свойств эталонных множеств (появление несвязных компонент, изолированных точек, незамкнутых контуров, дыр в объектах). Условно говоря, подобные ошибки классификации на изображении можно считать своего рода помехами, причем информация о характеристиках этого шума априори отсутствует, однако в ряде случаев (при контролируемой классификации) имеются сведения об эталонных образах объектов. Для повышения достоверности классификации к изображению в псевдоцветах целесообразно применять методы фильтрации. В этом случае необходимо либо проводить предварительный анализ свойств помех для обрабатываемого изображения в интерактивном режиме, либо использовать алгоритмы устойчивой локально-адаптивной обработки. Исследуемые в данной работе процедуры постклассификационной обработки, по сути, являются алгоритмами локальной пространственной фильтрации изображения в псевдоцветах (цвет каждого пиксела соответствует наиболее правдоподобию классу).

Для увеличения быстродействия процедуры обработки предлагается выполнять ее только в окрестностях границ отдельных сегментов: при просмотре пикселей изображения центральный элемент окна фильтра «скользит» по выделенным точкам границ между классами (см. рис. 8).

Как операции локальной обработки применялись следующие:

- $M1(w \times w)$ – взвешенная медианная фильтрация в окне $w \times w$ (центральный пиксел $S(i, j)$ учитывался трижды);
- $M2(w \times w)$ – расширенная медианная фильтрация (ряд значений в окне $w \times w$ дополнялся значением центрального пиксела $S(i, j)$ и результатом классификации по k -ближайшим соседям в окне);
- $K(w \times w)$ – метод k -ближайших соседей в окне $w \times w$;
- Φ – метод взвешенных k -ближайших соседей в окне 5×5 ; весовой коэффициент $W_{\Phi}(r, c)$ соответствует числу включений значения пиксела $S(r, c)$ в обрабатываемое множество (если $W_{\Phi}(r, c) = 0$, то значение $S(r, c)$ не учитывается, если $W_{\Phi}(r, c) = 2$ – учитывается дважды);

$$W_{\Phi} = \begin{bmatrix} 1 & 0 & 1 & 0 & 1 \\ 0 & 1 & 1 & 1 & 0 \\ 1 & 1 & 2 & 1 & 1 \\ 0 & 1 & 1 & 1 & 0 \\ 1 & 0 & 1 & 0 & 1 \end{bmatrix}.$$

Суть алгоритмов постобработки покажем на примере. Пусть фрагмент сегментированного изображения в окне 5×5 имеет вид:

$$S = \begin{bmatrix} 5 & 5 & 5 & 4 & 4 \\ 5 & 5 & 5 & 4 & 4 \\ 5 & 3 & 1 & 3 & 3 \\ 5 & 3 & 3 & 2 & 2 \\ 3 & 5 & 2 & 2 & 2 \end{bmatrix}.$$

Значение каждого пиксела S(r,c) определяется наиболее правдоподобным классом по результатам попиксельной классификации. При взвешенной медианной фильтрации выборочное множество элементов дополняется двумя значениями центрального пиксела: $S \cup 2 \times \{S(i,j)\}$, элементы упорядочиваются по возрастанию, и среднее значение упорядоченной последовательности (медиана) замещает собой значение центрального пиксела S(i,j). Отличие метода расширенной медианной фильтрации в том, что дополнением к выборочному множеству являются значение центрального пиксела и значение, определенное по «большинству представителей» какого-либо класса в окне (т.е., результат классификации по 24-ближайшим соседям). При использовании метода взвешенных k-ближайших соседей выборочное множество модифицируется в соответствии с маской W_{Φ} , после чего определяется модальное значение, которое ассоциируется с центральным пикселом.

Вариационные ряды для данных методов, а также результаты фильтрации тестового изображения S показаны в табл. 1 (a_k – значения пикселов в окне, n – абсолютная частота соответствующего значения, $S^f(i,j)$ – новое значение текущего центрального пиксела в скользящем окне 5×5).

Таблица 1

Результаты фильтрации тестового изображения S

a_k	1	2	3	4	5	$S^f(i,j)$
n M1	3	5	6	4	9	3
n M2	2	5	6	4	10	4
n K	1	5	6	4	9	5
n Φ	2	3	6	2	5	3

Оценками эффективности исследуемых процедур обработки являлись эмпирические вероятности правильной классификации P_{kk} класса (относительное количество решений в пользу k-го класса в серии тестовых распознаваний) и общая вероятность правильной классификации $P_{пр}$ [11].

Эталонное изображение для проверки качества классификации показано на рис. 9.




Рис. 9. Эталонное изображение для проверки качества классификации

На рис. 9 условными цветами маркированы области эталонных пикселов – точек на классифицированном изображении, для которых известны фактические данные о классе объекта.

Результаты оценок вероятностей правильного распознавания классов на этапе постклассификационной обработки даны в табл. 2. Для сравнения там же приведены соответствующие вероятности, полученные на этапе статистического распознавания по методу максимального правдоподобия (МП).

Символами #n (n = 1, 2, 3) обозначены номера итераций обработки (повторного выполнения указанного алгоритма фильтрации); оценка $P_{пр}^*$ была получена в предположении равных априорных вероятностей классов $P(a_k)$, оценка $P_{пр}$ – с учетом оценок $\hat{P}(a_k)$, определенных по эталонному изображению (рис. 9):

$$\hat{P}(a_k) = \{0,218 \ 0,437 \ 0,087 \ 0,108 \ 0,15\}.$$

Таблица 2

Оценки вероятностей правильного распознавания изображения (см. рис. 1) для исследуемых методов постклассификационной обработки

Оценка критерия	Метод обработки			
	МП	Φ#1	Φ#2	Φ#3
P_{11}	0,747	0,766	0,772	0,775
P_{22}	0,812	0,822	0,825	0,826
P_{33}	0,967	0,961	0,955	0,951
P_{44}	0,989	0,990	0,987	0,987
P_{55}	0,812	0,882	0,905	0,916
$P_{пр}^*$	0,865	0,884	0,889	0,891
$P_{пр}$	0,830	0,849	0,854	0,857

Продолжение табл. 2

Оценка критерия	Метод обработки		
	K(3×3)#1	K(5×5)#2	K(3×3)#3
P ₁₁	0,763	0,784	0,786
P ₂₂	0,821	0,831	0,832
P ₃₃	0,962	0,939	0,935
P ₄₄	0,983	0,966	0,965
P ₅₅	0,867	0,937	0,944
P*_{пр}	0,879	0,891	0,892
P_{пр}	0,845	0,861	0,862
	K(3×3)#1	K(3×3)#2	K(3×3)#3
P ₁₁	0,763	0,77	0,773
P ₂₂	0,821	0,824	0,826
P ₃₃	0,962	0,957	0,952
P ₄₄	0,983	0,984	0,98
P ₅₅	0,867	0,895	0,91
P*_{пр}	0,879	0,886	0,888
P_{пр}	0,845	0,852	0,855
	M1(3×3)#1	M1(3×3)#2	M1(3×3)#3
P ₁₁	0,745	0,768	0,771
P ₂₂	0,815	0,825	0,827
P ₃₃	0,957	0,957	0,953
P ₄₄	0,992	0,985	0,981
P ₅₅	0,820	0,887	0,902
P*_{пр}	0,866	0,884	0,887
P_{пр}	0,832	0,851	0,853
	M2(3×)#1	M2(3×3)#2	M2(3×3)#3
P ₁₁	0,762	0,777	0,785
P ₂₂	0,821	0,834	0,833
P ₃₃	0,962	0,944	0,932
P ₄₄	0,983	0,971	0,961
P ₅₅	0,864	0,913	0,946
P*_{пр}	0,878	0,888	0,891
P_{пр}	0,844	0,858	0,862
	M2(5×5)#1	M2(5×5)#2	M2(5×5)#3
P ₁₁	0,774	0,777	0,786
P ₂₂	0,832	0,834	0,838
P ₃₃	0,947	0,944	0,936
P ₄₄	0,971	0,971	0,959
P ₅₅	0,904	0,913	0,945
P*_{пр}	0,886	0,888	0,893
P_{пр}	0,855	0,858	0,862

Анализ полученных результатов показал, что локальная итеративная обработка сегментированного изображения в псевдоцветах приводит к повышению правильной классификации площадных объектов (при этом наблюдается сглаживание острых выступов контуров и удаление изолированных точек), однако вероятность правильного распознавания линейных объектов несколько снижается (разрываются

узкие перешейки и исчезают малоразмерные фрагменты).

Так, вероятность правильного распознавания площадных объектов классов 1 – «почва», 2 – «трава», 5 – «кусты» в результате постобработки увеличивается на 5–16 %, наилучшие результаты получены при использовании метода M2(5×5)#3 – три итерации расширенной медианной фильтрации. В то же время для обобщенных классов 3 – «вода» и 4 – «строения», содержащих линейные объекты (река, дорога), вероятность правильного распознавания уменьшается на величину от 1–2 % (для Ф#3 – три итерации метода взвешенных k-ближайших соседей) до 3–4 % (для M2(5×5)#3). Тем не менее, общая вероятность правильного распознавания классов объектов на тестовом изображении возрастает от 0,83 (метод максимального правдоподобия) до 0,862 (метод M2(5×5)#3, а также три итерации метода k-ближайших соседей с последовательным применением скользящих окон (3×3), (5×5) и (3×3)).

Для всех исследуемых методов постобработки увеличение количества итераций γ до четырех (и более) практически не оказывает влияния на достоверность классификации. Так для $\gamma = 4, 5$ по методу M2(5×5)# γ вероятность $P_{пр}$ составила, соответственно, 0,863 и 0,864 (т.е. увеличилась по сравнению с контрольным значением при $\gamma = 3$ всего на 0,23 %, что не оправдывает затраты времени на постобработку); для остальных методов выигрыш по величине $P_{пр}$ еще меньше и после четвертой итерации значение $P_{пр}$ уже не изменяется.

Таким образом, можно заключить, что фильтр M2(w×w) больше подходит для постобработки изображений с преобладанием площадных объектов местности; использование фильтра Ф позволяет лучше сохранить фрагменты линейных объектов (т.е., объектов антропогенного происхождения).

Рекомендуемое число итераций процедур постобработки $\gamma = 3$.

Применение методов пространственной фильтрации к сегментированному изображению позволяет существенно снизить эффекты избыточной сегментации и повысить достоверность классификации площадных объектов. Для повышения эффективности постклассификационной обработки необходимо дополнительно учитывать информацию о топологических свойствах объектов, что позволит включить в процедуры принятия решения описания основных связей и закономерностей пространственной структуры изображения [12 – 14].

Результаты постобработки сегментированного изображения (см. рис. 7) с использованием указанных выше методов локальной пространственной фильтрации показаны на рис. 10 – 13.




Рис. 10. Результаты постобработки изображения (см. рис. 7) по методу Ф#3




Рис. 12. Результаты постобработки изображения (см. рис. 7) по методу M2(5x5)#1




Рис. 11. Результаты постобработки изображения (см. рис. 7) по методу K(3x3)#3




Рис. 13. Результаты постобработки изображения (см. рис. 7) по методу M2(5x5)#3

Исследования показали, что алгоритмы, основанные лишь на спектральных признаках, позволяют эффективно выделять классы объектов только при наличии хороших эталонных участков, используемых для обучения, и только при условии достаточной статистической разделимости классов в пространстве признаков. К дополнительным факторам, усложняющим задачи обнаружения и распознавания, относятся разнообразие или изменчивость самих объектов наблюдения, эффекты маскирования одних объектов другими, сложный текстурированный фон, эффекты изменения среды между сенсорами и объектами, шумовые эффекты и т.п. [15].

Соответственно, при попиксельной классификации образов может возникать достаточно большое количество ошибок, когда объекты либо не выделяются, либо относятся к другому классу.

Использование методов постклассификационной обработки дает возможность включить в решающие правила не только спектральные значения отдельных пикселей изображения, но и комплексные яркостно-геометрические характеристики групп пикселей (сегментов) посредством учета признаков локальных окрестностей пикселей на границах сегментов; такой подход позволяет улучшить показатели достоверности распознавания классов.

Заключення

Предлагаемые в работе процедуры цифровой обработки многоканальных изображений включают два этапа. На первом этапе выполняется поэлементная классификация с обучением; в качестве эталонных описаний спектральных признаков классов используются S_B -распределения Джонсона. Решение о классе наблюдаемого объекта принимается по критерию максимального правдоподобия. Второй этап – локальная пространственная фильтрация сегментированного изображения, которая выполняется в окрестности границ выделенных сегментов. Эффективность метода постклассификационной обработки проверена на спутниковых изображениях, приведены результаты итеративного применения четырех вариантов метода (количество итераций $r = 1, 2, 3$) в сравнении с попиксельной классификацией.

Прикладное значение результатов состоит в том, что предлагаемый подход позволяет устранить на изображении точечные ошибки поэлементной классификации; при этом возрастает достоверность распознавания площадных объектов и снижается эффект избыточной сегментации. Полученные результаты могут быть использованы при разработке эффективных процедур анализа и интерпретации снимков ДЗЗ во вторичном пространстве признаков, описывающих пространственное распределение элементов и структурные связи между ними.

Направление дальнейших исследований – оценка и прогноз эффективности адаптивных методов локальной пространственной обработки многоканальных изображений и методов постобработки сегментированных изображений в задачах автоматического распознавания образов.

Литература

1. Bishop, Ch. M. *Pattern Recognition and Machine Learning [Text]* / Ch. M. Bishop. – Springer, 2010. – 738 p.
2. Schowengerdt, R. *Remote Sensing : Models and Methods for Image Processing [Text]* / R. Schowengerdt ; 3rd ed. – Cambridge : Academic Press, 2006. – 560 p. doi: 10.978.00804/80589.
3. *Correction of Misclassifications Using a Proximity-Based Estimation Method [Text]* / A. Niemistö, I. Shmulevich, V. Lukin et al. // *EURASIP J. Adv. Sig. Proc.* – 2004. – P. 1142 – 1155. doi: 10.1155/S1110865704402145.
4. Васильева, И. К. Морфологическая обработка изображений в псевдоцветах как способ повышения правдоподобности классификации [Текст] / И. К. Васильева, Е. А. Панкратова // *Радиоелектронні і комп'ютерні системи.* – 2011. – № 3 (51). – С. 64 – 67.
5. Попов, А. В. Метод принятия решений при распознавании объектов в условиях существенной априорной неопределенности [Текст] / А. В. Попов // *Радиоелектронні і комп'ютерні системи.* – 2015. – № 3 (73). – С. 53 – 60.
6. *Efficiency assessment of multitemporal C-band Radarsat-2 intensity and Landsat-8 surface reflectance satellite imagery for crop classification in Ukraine [Text]* / S. Skakun, N. Kussul, A. Shelestov et al. // *IEEE Journal of Selected Topics in Applied Earth Observation and Remote Sensing.* – 2016. – Vol. 9(8). – P. 3712 – 3719. doi: 10.1109/JSTARS.2015.2454297.
7. *Analysis of classification accuracy for pre-filtered multichannel remote sensing data [Text]* / V. Lukin, S. Abramov et al. // *Expert Systems with Applications.* – 2013. – Vol. 40. – P. 6400 – 6411.
8. *Deep learning classification of land cover and crop types using remote sensing data [Text]* / N. Kussul, M. Lavreniuk, S. Skakun, A. Shelestov // *IEEE Geoscience and Remote Sensing Letters.* – 2017. – Vol. 14(5). – P. 778 – 782. doi: 10.1109/LGRS.2017.2681128.
9. Хан, Г. *Статистические модели в инженерных задачах [Текст]* / Г. Хан, С. Шапиро. – М. : Мир, 1969. – 369 с.
10. Бабаков, М. Ф. *Об одном способе аппроксимации распределений многомерных поляриметрических характеристик [Текст]* / М. Ф. Бабаков // *Автоматизированные системы управления : сб. науч. тр. Харьк. авиац. ин-та им. Н. Е. Жуковского.* – 1981. – Вып. 3. – С. 166 – 167.
11. Congalton, R. *Accuracy assessment and validation of remotely sensed and other spatial information [Text]* / R. Congalton // *International Journal of Wildland Fire.* – 2001. – Vol. 10. – P. 321 – 328. doi: 10.1071/WF01031.
12. *Метод объектно-ориентированной классификации объектов подстилающей поверхности в задаче аэрокосмического мониторинга состояния импактных районов Арктики [Текст]* / А. А. Гурченков, А. Б. Мурынин, А. Н. Трекин, В. Ю. Игнатьев // *Вестн. МГТУ им. Н. Э. Баумана. Серия Естественные науки.* – 2017. – № 3. – С. 135 – 146. doi: 10.18698/1812-3368-2017-3-135-146.
13. Vasil'eva, I. *Multicomponent Model of Objects Attributive Signatures on Color Pictures [Text]* / I. Vasil'eva, A. Popov // *Problems of Infocommunications. Science and Technology : Proc. Internat. Scientific-Practical Conf., Kharkiv, Ukraine, 9-12 Oct. 2018.* – Kharkiv, 2018. – P. 281 – 284. doi: 10.1109/INFOCOMMST.2018.8632110.
14. *Современные методы интеллектуальной обработки данных ДЗЗ [Текст]* / Н. С. Абрамов, Д. А. Макаров, А. А. Талалаев, В. П. Фраленко // *Программные системы: теория и приложения.* – 2018. – Т. 9, №4(39). – С. 417 – 442. doi: 10.25209/2079-3316-2018-9-4-417-442.
15. Афанасьев, А. А. *Гибридные методы автоматизированной идентификации изменений ландшафтного покрова по данным дистанционного зон-*

дирования Земли в условиях шумов [Текст] / А. А. Афанасьев, А. В. Замятин // Компьютерная оптика. – 2017. – Т. 41, № 3. – С. 431 – 440. doi: 10.18287/2412-6179-2017-41-3-431-440.

References

1. Bishop, Ch. M. *Pattern Recognition and Machine Learning*. Springer, 2010. 738 p.
2. Schowengerdt, R. *Remote Sensing: Models and Methods for Image Processing*. 3rd ed. Cambridge : Academic Press, 2006. 560 p. doi: 10.978.00804/80589.
3. Niemistö, A., Shmulevich, I., Lukin, V., Dolia, A., Yli-Harja, O. Correction of Misclassifications Using a Proximity-Based Estimation Method. *EURASIP J. Adv. Sig. Proc.*, 2004, pp. 1142 – 1155. doi: 10.1155/S1110865704402145.
4. Vasil'eva, I. K., Pankratova, E. A. Morfolo-gicheskaya obrabotka izobrazhenii v psevdotsvetakh kak sposob povysheniya pravdopodobnosti klassifikatsii [Morphological image processing in pseudo-colors as a way to increase the likelihood of classification]. *Radioelektronni i komp'yuterni systemy – Radioelectronic and computer systems*, 2011, no. 3 (51), pp. 64 – 67. (In Russian).
5. Popov, A. V. Metod prinyatiya reshenii pri raspoznavanii ob'ektov v usloviyakh sushchestvennoi apriornoj neopredelennosti [A Decision-Making Method at Recognizing Objects in Conditions of Essential Prior Uncertainty]. *Radioelektronni i komp'yuterni systemy – Radioelectronic and computer systems*, 2015, no. 3, pp. 53 – 60. (In Russian).
6. Skakun, S., Kussul, N., Shelestov, A., Lavreniuk, M., Kussul, O. Efficiency assessment of multitemporal C-band Radarsat-2 intensity and Landsat-8 surface reflectance satellite imagery for crop classification in Ukraine. *IEEE Journal of Selected Topics in Applied Earth Observation and Remote Sensing*, 2016, vol. 9(8), pp. 3712 – 3719. doi: 10.1109/JSTARS.2015.2454297.
7. Lukin, V., Abramov, S., Krivenko, S., Kurekin, A., Pogrebnyak, O. Analysis of classification accuracy for pre-filtered multichannel remote sensing data. *Expert Systems with Applications*, 2013, vol. 40, pp. 6400 – 6411.
8. Kussul, N., Lavreniuk, M., Skakun, S., Shelestov, A. Deep learning classification of land cover and crop types using remote sensing data. *IEEE Geoscience and Remote Sensing Letters*, 2017, vol. 14(5), pp. 778 – 782. doi: 10.1109/LGRS.2017.2681128.

9. Khan, G., Shapiro, S. *Statisticheskie modeli v inzhenernykh zadachakh* [Statistical models in engineering problems]. Moscow, Mir Publ., 1969. 369 p.

10. Babakov, M. F. Ob odnom sposobe ap-proksimatsii raspredeleniy mnogomernykh polyarimetriceskikh kharakteristik [About one method of multidimensional polarimetric characteristics distributions approximation]. *Trudy KhAI «Avtomatizirovannye sistemy upravleniya» – Proc. of the KhAI “Automated control systems”*, 1981, no. 3, pp. 166–167. (In Russian).

11. Congalton, R. Accuracy assessment and validation of remotely sensed and other spatial information. *International Journal of Wildland Fire*, 2001, vol. 10, pp. 321 – 328. doi: 10.1071/WF01031.

12. Gurchenkov, A. A., Muryin, A. B., Trekin, A. N., Ignat'ev V. Yu. Metod ob"ektno-orientirovannoi klassifikatsii ob"ektov podstilayushchei poverkhnosti v zadache aerokosmicheskogo monitoringa sostoyaniya impaktnykh raionov Arktiki [Object-Oriented Classification of Substrate Surface Objects in Arctic Impact Regions Aerospace Monitoring]. *Vestnik MGTU im. N. E. Baumana. Seriya Estestvennye nauki – Herald of the Bauman MSTU. Series Natural Sciences*, 2017, no. 3, pp. 135 – 146. (In Russian). doi: 10.18698/1812-3368-2017-3-135-146.

13. Vasil'eva, I., Popov, A. Multicomponent Model of Objects Attributive Signatures on Color Pictures. *Proc. Internat. Scientific-Practical Conf. on Problems of Infocommunications. Science and Technology*, Kharkiv, Ukraine, 9-12 Oct. 2018, pp. 281 – 284. doi: 10.1109/INFOCOMMST.2018.8632110.

14. Abramov, N. S., Makarov, D. A., Talalaev, A. A., Fralenko, V. P. Sovremennye metody intellektual'noi obrabotki dannykh DZZ [Modern methods for intelligent processing of Earth remote sensing data]. *Programmnye sistemy : teoriya i prilozheniya – Program Systems : Theory and Applications*, 2018, vol. 9, no. 4(39), pp. 417 – 442. (In Russian). doi: 10.25209/2079-3316-2018-9-4-417-442.

15. Afanas'ev, A. A., Zamyatin A. V. Gibridnye metody avtomatizirovannoi identifikatsii izmenenii landshaftnogo pokrova po dannym distantsionnogo zondirovaniya Zemli v usloviyakh shumov [Hybrid methods of automated identification of changes in landscape cover by Earth remote sensing data in the conditions of noises]. *Komp'yuternaya optika – Computer optics*, 2017, vol. 41, no. 3, pp. 431 – 440. (In Russian). doi: 10.18287/2412-6179-2017-41-3-431-440.

Поступила в редакцию 5.02.2019, рассмотрена на редколлегии 15.03.2019

АНАЛІЗ МЕТОДІВ ПОСТКЛАСИФІКАЦІЙНОЇ ОБРОБКИ БАГАТОКАНАЛЬНИХ ЗОБРАЖЕНЬ

І. К. Васильєва, В. В. Лукін

Предметом вивчення в статті є методи морфологічної просторової фільтрації зображень у псевдоко-льорах, отриманих в результаті статистичної сегментації багатоканальних супутникових знімків. **Метою** є дослідження ефективності різних варіантів методів посткласифікаційної обробки зображень для підвищення ймовірності вірного розпізнавання об'єктів спостереження. **Завдання:** вибрати математичну модель для

опису навчальних образів класів об'єктів; реалізувати процедуру статистичної контрольованої класифікації за методом максимальної правдоподібності; оцінити результати виділення об'єктів на тестовому зображенні за критерієм емпіричної ймовірності вірного розпізнавання; формалізувати процедури локальної об'єктно-орієнтованої фільтрації сегментованого зображення; дослідити ефективність процедур рангової і зваженої медіанної фільтрації з урахуванням результатів класифікації за k -найближчими сусідами у вікні фільтра. Використовуваними **методами** є: методи апроксимації емпіричних розподілів, статистичні методи розпізнавання, методи теорії ймовірностей і математичної статистики, методи локальної просторової фільтрації. Отримано наступні **результати**. Запропоновано методіку синтезу універсальної математичної моделі для опису негаусових сигнальних ознак образів об'єктів на багатоканальних зображеннях на ґрунті багатовимірного варіанту S_B -розподілу Джонсона; зазначена модель була застосована для статистичної піксельної класифікації вихідного супутникового знімка. Реалізовано алгоритми локальної посткласифікаційної обробки в околиці границь виділених сегментів. Виконано аналіз ефективності розроблених алгоритмів на підставі оцінок ймовірностей вірного розпізнавання класів. **Висновки**. Наукова новизна отриманих результатів полягає в наступному: отримали подальший розвиток комбіновані підходи до процедур розпізнавання образів – показано, що використання методів локальної об'єктно-орієнтованої фільтрації сегментованих зображень дозволяє зменшити кількість точкових помилок поелементної класифікації площинних об'єктів.

Ключові слова: класифікація; апроксимація; розподіл Джонсона; просторова фільтрація; ймовірність вірного розпізнавання.

MULTICHANNEL IMAGES POST-CLASSIFICATION PROCESSING TECHNIQUES ANALYSIS

I. K. Vasilyeva, V. V. Lukin

The **subject matter** of the article is the methods of morphological spatial filtering of images in pseudo-colors obtained as a result of statistical segmentation of multichannel satellite images. The **aim** is to study the effectiveness of various methods of post-classification image processing in order to increase the probability of correct recognition for observed objects. The **tasks** to be solved are: to select a mathematical model describing the training sets of objects' classes; to implement the procedure of statistical controlled classification by the maximum likelihood method; to evaluate the results of objects' recognition on the test image by the criterion of the empirical probability of correct recognition; to formalize the procedures of local object-oriented filtering of a segmented image; to investigate the effectiveness of rank filtering as well as weighted median filtering procedures taking into account the results of the classification by k -nearest neighbors in the filter window. The **methods** used are methods of empirical distributions' approximation, statistical recognition methods, methods of probability theory and mathematical statistics, methods of local spatial filtering. The following **results** were obtained. A method for synthesizing a universal mathematical model has been proposed for describing non-Gaussian signal characteristics of objects on multichannel images based on a multi-dimensional variant of Johnson SB distribution; this model was used for statistical pixel-by-pixel classification of the original satellite image. Algorithms for local post-classification processing in the neighborhood of the selected segments boundaries have been implemented. The analysis of the developed algorithms' effectiveness based on estimates of classes' correct recognition probability is performed. **Conclusions**. The scientific novelty of the results obtained is as follows: combined approaches to the pattern recognition procedures have been further developed – it has been shown that the use of methods of local object-oriented filtering of segmented images allows to reduce the number of point errors for element-wise classification of spatial objects.

Key words: classification; approximation; Johnson distribution; spatial filtering; probability of correct recognition.

Васильєва Ірина Карловна – канд. техн. наук, доц., доц. каф. інформаційно-комунікаційних технологій ім. А. А. Зеленського, Національний аерокосмічний університет ім. Н. Е. Жуковського «Харьковский авиационный институт», Харьков, Україна.

Лукин Владимир Васильевич – д-р техн. наук, проф., зав. каф. інформаційно-комунікаційних технологій ім. А. А. Зеленського, Національний аерокосмічний університет ім. Н. Е. Жуковського «Харьковский авиационный институт», Харьков, Україна.

Vasilieva Irina – cand. tehn. sciences, docent, associate professor of the Department of Information-Communication Technologies named after O. O. Zelensky, National Aerospace University "Kharkiv Aviation Institute", Kharkiv, Ukraine, e-mail: i.vasilieva@khai.edu, ORCID Author ID: 0000-0002-1378-1104.

Lukin Vladimir – doctor tehn. sciences, professor, Head of the Department of Information-Communication Technologies named after O. O. Zelensky, National Aerospace University "Kharkiv Aviation Institute", Kharkiv, Ukraine, e-mail: lukin@ai.kharkov.com, ORCID Author ID: 0000-0002-1443-9685.