

И. К. ВАСИЛЬЕВА, В. В. ЛУКИН*Национальный аэрокосмический университет им. Н. Е. Жуковского "ХАИ", Украина*

ИССЛЕДОВАНИЕ ЭФФЕКТИВНОСТИ МЕТОДОВ ПОСТ-КЛАССИФИКАЦИОННОЙ ОБРАБОТКИ ЗАШУМЛЕННЫХ МНОГОКАНАЛЬНЫХ ИЗОБРАЖЕНИЙ

Предметом изучения в статье являются методы локальной пространственной пост-обработки изображений, полученных в результате статистической попиксельной классификации многоканальных спутниковых снимков, искаженных аддитивным гауссовым шумом. *Целью* является исследование эффективности различных вариантов методов пост-классификационной обработки изображений в широком диапазоне значений отношения сигнал-шум; в качестве критерия эффективности приняты показатели достоверности классификации объектов наблюдения. *Задачи*: сгенерировать случайные значения яркостей шумовых компонент, обеспечив их соответствие принятой вероятностной модели; реализовать процедуру статистической контролируемой классификации по методу максимального правдоподобия для изображений, искаженных шумом; оценить результаты выделения объектов на зашумленных изображениях по критерию эмпирической вероятности правильного распознавания; реализовать процедуры локальной объектно-ориентированной пост-обработки изображений; исследовать влияние дисперсии шума на эффективность процедур пост-обработки. *Используемыми методами* являются: методы стохастического моделирования, методы аппроксимации эмпирических зависимостей, статистические методы распознавания, методы теории вероятностей и математической статистики, методы локальной пространственной фильтрации. *Получены следующие результаты*. Реализованы алгоритмы ранговой и взвешенной медианной пост-обработки с учетом результатов классификации по k -ближайшим соседям в окне фильтра. Выполнен анализ эффективности разработанных алгоритмов на основании оценок вероятностей правильного распознавания объектов на зашумленных изображениях. Получены эмпирические зависимости оценок общей вероятности ошибок распознавания от дисперсии аддитивного шума. **Выводы**. Научная новизна полученных результатов состоит в следующем: получили дальнейшее развитие комплексные подходы к построению решающих правил с учетом дестабилизирующих факторов – показано, что использование методов локальной объектно-ориентированной фильтрации сегментированных изображений позволяет уменьшить количество точечных ошибок поэлементной классификации объектов, и частично восстановить связность и пространственное распределение элементов структуры изображения.

Ключевые слова: классификация; аппроксимация; аддитивный гауссов шум; пространственная фильтрация; вероятность правильного распознавания.

Введение

Достоверность принимаемых решений при анализе изображений дистанционного зондирования (ДЗ) во многом определяется качеством исходного снимка. К причинам, понижающим качество изображений, можно отнести: низкую контрастность изображения; помехи шумового характера; недостаточную или излишнюю освещенность объектов съемки; отсутствие резкости при получении изображения или вследствие применения сглаживающих фильтров; слишком мелкие размеры деталей, которые необходимо различить.

Одним из основных факторов, снижающих качество исходных данных многоканального ДЗ, является шум. Он особенно заметен на однородных участках. При этом шум не только снижает визуальное качество изображений, но и ухудшает показате-

ли достоверности их классификации [1]. Для устранения шума и улучшения конечных результатов решения практических задач ДЗ часто применяют предварительную фильтрацию изображений. Применительно к многоканальным изображениям возможны как покомпонентная обработка (при этом фильтрация выполняется для каждого канала по отдельности) [2, 3], так и совместная (векторная) обработка (она позволяет учесть межканальную корреляцию, которая характерна как для обычных цветных изображений, так и мульти- и гиперспектральных снимков). Особенности таких подходов обсуждены в работах [4 – 6].

Эффективность обработки и выбор методов зависят от типа помех [7, 8]. Аддитивные помехи часто используют в качестве простейшей модели шума для оптических изображений и других типов снимков. В большинстве практических ситуаций их

полагают гауссовыми с математическим ожиданием, равным нулю, и дисперсией σ_n^2 , которая примерно постоянна для всего изображения. Кроме того, обычно считают, что значения аддитивных помех пространственно-некоррелированы (независимы для соседних, и, тем более, удаленных друг от друга пикселей). Влияние таких помех проявляется в ухудшении результатов классификации изображений, а благодаря предварительной фильтрации показатели качества классификации обычно удается улучшить. При этом следует принимать во внимание, что эффективность классификации также зависит от множества других факторов, в частности, применяемого классификатора (решающего правила), репрезентативности обучающих выборок, адекватности эталонных описаний классов, информативности классификационных признаков и др. [9].

Альтернативным подходом к решению задачи повышения надежности классификации изображений, искаженных шумом, могут быть процедуры пост-классификационной обработки, реализующие некоторый метод локальной пространственной фильтрации сегментированных изображений в псевдоцветах (цвет каждого пиксела соответствует наиболее правдоподобному классу) [10 – 12]. Как показано в работе [13], предлагаемый подход позволяет устранить на изображении точечные ошибки поэлементной (попиксельной) классификации; при этом возрастает достоверность распознавания площадных объектов и снижается эффект избыточной сегментации. Поскольку при разработке методов пост-обработки сегментированных изображений (полученных в результате статистической классификации незашумленных изображений) ошибки попиксельной классификации рассматривались как визуальное проявление помех, то можно ожидать, что пост-классификационная обработка зашумленных изображений поможет снизить количество ошибок распознавания.

Цель работы – исследование эффективности процедур пост-классификационной обработки многоканальных изображений, искаженных аддитивным белым гауссовым шумом (АБГШ), для повышения вероятности правильного распознавания объектов (при варьировании мощности шумовой компоненты, определяемой параметром σ_n^2).

1. Этап формирования зашумленного изображения

Анализ реальных изображений различного типа показывает, что на всех из них в той или иной степени присутствуют помехи (шум). Значения яркости шумовой компоненты рассматривают как

случайные величины с определенными статистическими свойствами. При этом различные виды распределений соответствуют различной физической природе шума. Так, например, нормальный (гауссов) шум возникает на изображениях в результате воздействия таких факторов как шум в электронных цепях (флуктуационный шум, обусловленный недостатком освещения и/или высокой температурой).

Наиболее распространенным видом помех является случайный аддитивный шум, статистически независимый от сигнала. Часто аддитивный шум считают некоррелированным (белым) или слабокоррелированным. При восьмибитном представлении изображений аддитивный шум становится визуально заметным, если $\sigma_n^2 \geq 6 \dots 10$.

В данной работе принята классическая вероятностная модель шума – нормальный закон распределения (ЗР) $N(0, \sigma)$, где σ – среднеквадратическое отклонение (СКО); при этом предполагалось, что шум является аддитивным, не зависит от пространственных координат и не коррелирует с изображением. Генерация отсчетов гауссова шума выполнялась для каждой компоненты $\{R, G, B\}$ изображения: $\{n_R\}_{ij}$, $\{n_G\}_{ij}$, $\{n_B\}_{ij}$; оценки нормированных коэффициентов корреляции между шумовыми компонентами не превышали величин порядка 10^{-4} .

Так как для растровых изображений значение пиксела является целым числом (в частности, для восьмибитового изображения интервал яркости ограничен значениями от 0 до 255), то для зашумленного АБГШ изображения значения пикселей с координатами (i, j) определялись по правилу:

$$\begin{aligned} \{I_C^*\}_{ij} &= \{I_C\}_{ij} + \{n_C\}_{ij}, C \in \{R, G, B\}; \\ \text{если } \{I_C^*\}_{ij} &> 255, \text{ то } \{I_C^*\}_{ij} = 255; \\ \text{если } \{I_C^*\}_{ij} &< 0, \text{ то } \{I_C^*\}_{ij} = 0. \end{aligned}$$

Для нашего исследования необходимо иметь тестовое изображение (или изображения), для которого были бы сведения об участках, по которым проводится обучение классификатора и его верификация (оценка показателей надежности распознавания). Кроме того, желательно, чтобы для этого же изображения были результаты его классификации разными методами. Таким требованиям удовлетворяет представленное на рис. 1 исходное (незашумленное) изображение – снимок 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 рис. 2 приведено это же изображение, искаженное АБГШ с параметром $\sigma = 8$. Отметим, что этот снимок ранее использовался в работах [3, 13, 14].



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




Рис. 2. Аддитивная смесь изображения (рис. 1) и гауссова шума ($\sigma = 16$)

Для исследования влияния мощности шумовой компоненты на результаты распознавания значение параметра σ варьировалось в диапазоне 4...16.

Традиционными критериями оценки влияния шума на качество изображений, как известно, являются пиковое отношение сигнал-шум (peak signal-to-noise ratio – PSNR) и среднеквадратическая ошибка (mean square error – MSE), которые определяются по формулам, соответственно:

$$MSE_C = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (I_{Cij}^* - I_{Cij})^2, \quad C \subset \{R, G, B\},$$

$$MSE = \frac{1}{3} (MSE_R + MSE_G + MSE_B); \quad (1)$$

$$PSNR = 10 \log \left(\frac{I_{\max}^2}{MSE} \right), \quad (2)$$

где $I_{\max} = 255$ – верхняя граница диапазона интенсивностей для исходного изображения.

Значения PSNR и MSE для полученных зашумленных изображений приведены в табл. 1.

Считается, что чем больше PSNR, тем лучше качество изображения, и, соответственно, тем достовернее его классификация. Если значение PSNR лежит в интервале между 20 и 25, то качество изображения приемлемо, например, для беспроводной передачи.

Таблица 1

Оценки критериев PSNR и MSE для исследуемых зашумленных изображений

σ	4	6	8	10	12	14	16
MSE	15,93	35,64	63,14	98,48	141,2	191,5	250,4
PSNR, дБ	36,11	32,61	30,13	28,20	26,63	25,31	24,14

2. Этап классификации изображений

Как было рассмотрено в предыдущей работе [13], процедура классификации многоканальных изображений включает два этапа.

На первом этапе выполняется поэлементная статистическая классификация с обучением «с учителем»; в качестве эталонных описаний спектральных признаков классов предлагается использовать S_V -распределение Джонсона [15]:

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

где η и γ – два параметра формы, связанных с коэффициентами асимметрии и эксцесса ($\eta > 0$, $\gamma \in (-\infty, +\infty)$);

ε и λ – два параметра масштаба, определяющие размах случайной величины x ($\varepsilon \in (-\infty, +\infty)$, $\varepsilon \leq x \leq \varepsilon + \lambda$).

За счет большого количества параметров модель (3) является достаточно универсальной, что позволяет с ее помощью аппроксимировать практически любые унимодальные и широкий спектр бимодальных распределений. Кроме того, поскольку распределения Джонсона основаны на нелинейных преобразованиях нормальных случайных величин, их использование при описании эмпирических распределений позволяет не выходить за рамки корреляционной теории, что особенно актуально для цветных признаков объектов, которые характеризуются негауссовыми распределениями и наличием сильных взаимных корреляционных связей. Многомерный вариант распределения (3) имеет вид [16]

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

где $p = 3$ – размерность вектора $\bar{x} = \{R, G, B\}$;

Ξ – выборочная корреляционная матрица.

Оценки параметров маргинальных распределений $\bar{\theta}|a_k = \{\varepsilon_k, \lambda_k, \eta_k, \gamma_k\}$ были найдены в [13] путем минимизации суммарной квадратичной ошибки представления гистограммы моделью (3).

Для формирования обучающих выборок (фрагментов исходного незашумленного изображения, содержащих объекты только одного класса) использовались цветовые маски, построенные путем выделения хорошо различимых, однородных областей, представляющих каждый класс объектов природного и антропогенного происхождения [13]: 1 – «почва», 2 – «трава», 3 – «вода», 4 – «строения», 5 – «кусты»; классы 3 и 4 содержали как площадные, так и линейные объекты: класс «вода» = {озеро, река}, класс «строения» = {здания, дороги}.

Результаты распознавания классов на исходном снимке (отсутствие шума условно обозначено как $\sigma = 0$) и снимках, искаженных АБГШ для различных значений СКО шума σ показаны на рис. 3.




Рис. 3. Результаты распознавания классов по критерию максимального правдоподобия:
а – $\sigma = 0$; б – $\sigma = 4$; в – $\sigma = 10$; г – $\sigma = 16$

На этапе распознавания решение о классе наблюдаемого объекта принималось по критерию максимального правдоподобия, согласно которому контрольная выборка \bar{x} (измеренные значения сигнальных признаков в текущем пикселе изображения) относилась к тому классу a_u , $1 \leq u \leq K$, для которого функция правдоподобия максимальна:

$$f(\bar{x}|a_u) = \max_{1 \leq k \leq K} \{f(\bar{x}|a_k)\} \Rightarrow \bar{x} \in a_u. \quad (5)$$

Как видно из представленных результатов, даже при относительно небольшом уровне шума ($\sigma = 4$) возрастает количество ошибок распознавания, которые, преимущественно, проявляются в виде изолированных точек на выделенных сегментах (т.е., неправильно классифицированных пикселей); с увеличением СКО шума некоторые однородные по цвету области распадаются на группы несвязанных точек, что можно интерпретировать как неправильно классифицированные объекты.

3. Этап пост-обработки сегментированных изображений

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 ($K = 5$ – число классов). Ошибки распознавания при этом визуально проявляются в нарушении топологических свойств эталонных множеств (появление несвязных компонент, изолированных точек, незамкнутых контуров, дыр в объектах), что проявляется как эффект избыточной сегментации, когда однородные по цвету области (т.е., соответствующие определенному классу) оказываются разделенными на множество отдельных сегментов. Как было показано в [13], использование методов пост-классификационной обработки дает возможность включить в решающие правила не только спектральные значения отдельных пикселей изображения, но и яркостно-геометрические характеристики групп пикселей (сегментов) посредством учета признаков локальных окрестностей пикселей на границах сегментов; такой подход позволяет улучшить показатели достоверности распознавания классов.

В данной работе исследовались следующие методы пост-классификационной обработки:

– $M(w \times w)$ – 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):

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

Рассмотрим на примере, в чём состоит суть алгоритмов пост-обработки.

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 статистической классификации по критерию максимального правдоподобия (5).

При расширенной медианной фильтрации $M(w \times w)$ выборочное множество элементов в окне фильтра дополняется двумя элементами: значением центрального пиксела $S(i,j)$ и значением, определенным по «большинству представителей» некоторого класса в окне (т.е., результатом классификации методом $K(w \times w)$ – по k -ближайшим соседям, $k = 24$).

При использовании метода Φ – взвешенных k -ближайших соседей, выборочное множество модифицируется в соответствии с маской W_Φ , после чего определяется модальное значение, которое ассоциируется с центральным пикселем $S(i,j)$.

Вариационные ряды для данных методов, а также результаты фильтрации тестового изображения S приведены в табл. 2 (a_k – значения пикселей в окне, n – абсолютная частота соответствующего значения, $S^f(i,j)$ – новое значение текущего центрального пиксела в скользящем окне 5×5).

Как видно из табл. 2, различные методы локальной пространственной обработки сегментированного изображения приводят к различным результатам переопределения класса каждого пикселя, что, в конечном итоге, сказывается на общей вероятности правильной классификации.

Таблица 2

Результаты фильтрации тестового изображения S

a_k	1	2	3	4	5	$S^f(i,j)$
$n M$	2	5	6	4	10	4
$n K$	1	5	6	4	9	5
$n \Phi$	2	3	6	2	5	3

В качестве показателей достоверности распознавания объектов на зашумленных изображениях были приняты эмпирические вероятности правильной классификации P_{kk} класса (относительное количество решений в пользу k -го класса в серии тестовых распознаваний) и общая вероятность правильной классификации $P_{пр}$.

Эталонное изображение для проверки качества классификации показано на рис. 4. На рис. 4 условными цветами маркированы области эталонных пикселей – точек на классифицированном изображении, для которых известны фактические данные о классе объекта; т. о., путем попиксельного сравнения эталонного и классифицированного изображений находились статистические оценки вероятностей \hat{P}_{kl} , где k – номер класса, в пользу которого было принято решение, l – номер фактически наблюдаемого класса.

Оценка $P_{пр}$ вычислялась с учетом оценок априорных вероятностей классов $\hat{P}(a_k)$, определенных по эталонному изображению [3] (рис. 4):

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

$$P_{пр} = \sum_{k=1}^K \hat{P}(a_k) \hat{P}_{kk}.$$

Результаты оценок $P_{пр}$ на этапе пост-классификационной обработки исходного изображения ($\sigma = 0$) даны в табл. 3 (символами # n ($n = 1, 2, 3$)) обозначены номера итераций обработки (повторного выполнения указанного алгоритма фильтрации). Для сравнения там же приведены значения $P_{пр}$, полученные на этапе статистического распознавания по методу максимального правдоподобия (МП).




Рис. 4. Эталонное изображение для проверки качества классификации

Таблица 3

Оценки вероятностей правильной классификации исходного изображения для исследуемых методов

Оценка критерия	Метод обработки			
	МП	Ф#3	К(3×3)#3	М(5×5)#3
$P_{пр}$	0,83	0,849	0,862	0,862

Таблица 4

Оценки вероятностей правильной классификации зашумленного изображения ($\sigma = 4, 6 \dots 16$) для исследуемых методов обработки

Метод	МП						
	4	6	8	10	12	14	16
σ шума	4	6	8	10	12	14	16
P_{11}	0,629	0,555	0,497	0,45	0,403	0,378	0,364
P_{22}	0,701	0,625	0,547	0,495	0,454	0,422	0,407
P_{33}	0,933	0,875	0,819	0,77	0,734	0,719	0,696
P_{44}	0,986	0,979	0,971	0,958	0,947	0,939	0,931
P_{55}	0,726	0,691	0,65	0,632	0,59	0,577	0,556
$P_{пр}$	0,74	0,679	0,621	0,58	0,541	0,518	0,502
Метод	К(3×3)#1						
	4	6	8	10	12	14	16
σ шума	4	6	8	10	12	14	16
P_{11}	0,68	0,569	0,485	0,43	0,372	0,351	0,342
P_{22}	0,772	0,714	0,633	0,57	0,514	0,469	0,457
P_{33}	0,956	0,955	0,936	0,917	0,893	0,872	0,859
P_{44}	0,985	0,985	0,984	0,984	0,981	0,982	0,98
P_{55}	0,886	0,883	0,852	0,838	0,792	0,787	0,746
$P_{пр}$	0,808	0,758	0,698	0,655	0,609	0,582	0,567
Метод	К(5×5)#2						
	4	6	8	10	12	14	16
σ шума	4	6	8	10	12	14	16
P_{11}	0,705	0,568	0,465	0,419	0,365	0,362	0,354
P_{22}	0,796	0,75	0,669	0,605	0,526	0,495	0,482
P_{33}	0,937	0,931	0,922	0,919	0,896	0,889	0,894
P_{44}	0,967	0,97	0,976	0,978	0,975	0,983	0,98
P_{55}	0,957	0,964	0,955	0,947	0,925	0,917	0,895
$P_{пр}$	0,831	0,782	0,723	0,684	0,632	0,617	0,606
Метод	К(3×3)#3						
	4	6	8	10	12	14	16
σ шума	4	6	8	10	12	14	16
P_{11}	0,706	0,566	0,462	0,42	0,366	0,365	0,356
P_{22}	0,797	0,753	0,674	0,609	0,526	0,497	0,483
P_{33}	0,933	0,929	0,918	0,917	0,892	0,886	0,89
P_{44}	0,966	0,971	0,974	0,978	0,973	0,982	0,98
P_{55}	0,964	0,971	0,962	0,953	0,935	0,929	0,908
P_{11}	0,832	0,784	0,725	0,686	0,633	0,62	0,609
Метод	М(3×3)#1						
	4	6	8	10	12	14	16
σ шума	4	6	8	10	12	14	16
P_{11}	0,676	0,562	0,477	0,419	0,361	0,337	0,324
P_{22}	0,776	0,723	0,653	0,604	0,568	0,546	0,552
P_{33}	0,957	0,955	0,938	0,918	0,895	0,873	0,861
P_{44}	0,986	0,985	0,985	0,984	0,982	0,983	0,982
P_{55}	0,871	0,859	0,814	0,791	0,73	0,711	0,664
P_{11}	0,807	0,757	0,7	0,66	0,621	0,601	0,593

Продолжение табл. 4

Окончание табл. 4

Метод	M(3×3)#2						
σ шума	4	6	8	10	12	14	16
P ₁₁	0,686	0,559	0,456	0,412	0,354	0,335	0,326
P ₂₂	0,789	0,743	0,672	0,629	0,586	0,575	0,59
P ₃₃	0,952	0,951	0,941	0,931	0,916	0,901	0,9
P ₄₄	0,987	0,987	0,987	0,988	0,985	0,988	0,987
P ₅₅	0,904	0,904	0,859	0,847	0,782	0,782	0,711
P_{пр}	0,819	0,772	0,712	0,68	0,637	0,624	0,62
Метод	M(3×3)#3						
σ шума	4	6	8	10	12	14	16
P ₁₁	0,688	0,558	0,46	0,41	0,353	0,338	0,326
P ₂₂	0,794	0,752	0,679	0,641	0,592	0,588	0,609
P ₃₃	0,948	0,946	0,938	0,933	0,918	0,915	0,907
P ₄₄	0,985	0,986	0,987	0,989	0,986	0,99	0,988
P ₅₅	0,915	0,926	0,883	0,872	0,809	0,775	0,739
P_{пр}	0,823	0,778	0,718	0,688	0,644	0,634	0,634
Метод	M(5×5)#1						
σ шума	4	6	8	10	12	14	16
P ₁₁	0,688	0,552	0,449	0,384	0,338	0,32	0,305
P ₂₂	0,801	0,759	0,695	0,697	0,63	0,646	0,677
P ₃₃	0,944	0,939	0,931	0,91	0,911	0,9	0,903
P ₄₄	0,978	0,978	0,985	0,98	0,988	0,99	0,991
P ₅₅	0,909	0,917	0,867	0,91	0,767	0,742	0,689
P_{пр}	0,825	0,777	0,719	0,71	0,65	0,649	0,652
Метод	M(5×5)#2						
σ шума	4	6	8	10	12	14	16
P ₁₁	0,692	0,544	0,44	0,385	0,338	0,326	0,306
P ₂₂	0,811	0,773	0,71	0,686	0,647	0,675	0,714
P ₃₃	0,936	0,931	0,929	0,918	0,902	0,895	0,91
P ₄₄	0,976	0,973	0,982	0,986	0,987	0,992	0,994
P ₅₅	0,937	0,955	0,889	0,887	0,817	0,785	0,747
P_{пр}	0,833	0,786	0,726	0,704	0,664	0,669	0,678
Метод	M(5×5)#3						
σ шума	4	6	8	10	12	14	16
P ₁₁	0,693	0,534	0,436	0,384	0,34	0,328	0,312
P ₂₂	0,816	0,78	0,713	0,695	0,705	0,686	0,678
P ₃₃	0,933	0,926	0,927	0,91	0,892	0,90	0,909
P ₄₄	0,968	0,967	0,979	0,981	0,982	0,99	0,991
P ₅₅	0,952	0,969	0,917	0,907	0,836	0,803	0,794
P_{пр}	0,836	0,788	0,731	0,709	0,691	0,677	0,67
Метод	Φ#1						
σ шума	4	6	8	10	12	14	16
P ₁₁	0,679	0,57	0,485	0,428	0,37	0,346	0,331
P ₂₂	0,771	0,706	0,619	0,553	0,494	0,448	0,43
P ₃₃	0,956	0,947	0,932	0,914	0,884	0,87	0,846
P ₄₄	0,992	0,991	0,988	0,988	0,982	0,979	0,978
P ₅₅	0,887	0,877	0,835	0,821	0,769	0,753	0,713
P_{пр}	0,808	0,754	0,69	0,645	0,595	0,566	0,546

Метод	Φ#2						
σ шума	4	6	8	10	12	14	16
P ₁₁	0,695	0,569	0,471	0,419	0,361	0,346	0,334
P ₂₂	0,786	0,731	0,646	0,581	0,513	0,466	0,445
P ₃₃	0,949	0,941	0,933	0,924	0,91	0,898	0,893
P ₄₄	0,991	0,99	0,989	0,99	0,986	0,984	0,984
P ₅₅	0,933	0,936	0,905	0,902	0,863	0,843	0,809
P_{пр}	0,825	0,773	0,709	0,669	0,619	0,59	0,573
Метод	Φ#3						
σ шума	4	6	8	10	12	14	16
P ₁₁	0,701	0,567	0,463	0,416	0,36	0,349	0,337
P ₂₂	0,791	0,743	0,659	0,596	0,52	0,477	0,455
P ₃₃	0,943	0,934	0,924	0,921	0,906	0,896	0,895
P ₄₄	0,99	0,989	0,988	0,99	0,986	0,987	0,987
P ₅₅	0,952	0,959	0,935	0,936	0,908	0,885	0,864
P_{пр}	0,83	0,78	0,717	0,679	0,628	0,602	0,587

Для всех исследуемых методов пост-обработки увеличение количества итераций γ до четырех (и более), независимо от величины СКО шума, практически не оказывает влияния на достоверность классификации; при $\sigma = 16$ максимальный выигрыш по величине $P_{пр}$ (по сравнению с контрольным значением при $\gamma = 3$) составляет не более 3 % (для случая $\sigma = 0 - 0,23\%$), что объясняется случайным характером влияния шумовой компоненты на полученные результаты оценки качества классификации. Таким образом, рекомендуемое число итераций процедур пост-обработки $\gamma = 3$, поскольку увеличение γ не приводит к такому значимому повышению $P_{пр}$, чтобы это оправдывало увеличение затрат времени на постобработку.

По результатам исследований, выполненных в [13], классы 1 – «почва», 2 – «трава» и 5 – «кусты» на исходном (незашумленном) изображении различаются между собой по признакам R, G, B недостаточно надежно; это обусловлено существенным пересечением областей, занимаемых классами в признаковом пространстве. Данные области описываются N-мерными ($N = 3$) плотностями S_B -распределения Джонсона (4) $f(\bar{x}|a_k)$ и ограничиваются порогами принятия решения в соответствии с критерием максимального правдоподобия.

Расчет теоретических значений вероятностей ошибочного распознавания классов P_{ij} ($i \neq j$), по сути, сводится к интегрированию условных по классам распределений (точнее, их эмпирических оценок, полученных на этапе обучения классификатора) в N-мерном признаковом пространстве \bar{x} :

$$P_{ij} = \int_{\Gamma_j} f(\bar{x}|a_j) d\bar{x},$$

где область интегрирования Γ_j – это область принятия неправильных решений, соответствующая всем случаям, когда контрольная выборка, принадлежащая классу a_j , ошибочно относится к любому другому классу:

$$\Gamma_j : \{ \bar{x} \mid f(\bar{x}|a_i) > f(\bar{x}|a_j) \}, i, j = 1 \dots K, i \neq j.$$

Если множество Γ_j – не пустое, то существуют ненулевые вероятности ошибок попиксельной классификации P_{ij} , при этом пиксели образов j -го класса будут помечены маркерами других классов, что особенно заметно для классов 1 – «почва», 2 – «трава» и 5 – «кусты» (см. рис. 5 – 7).

При повышении уровня шумовой компоненты количество неправильно классифицированных пикселей возрастает. Так, вероятность правильного распознавания класса 1 – «почва» на исходном изображении $P_{11} = 0,75$ (вероятность ошибки $P_{51} = 0,19$ соответствует относительной частоте принятия решений о принадлежности пикселя образа класса 1 классу 5 – «кусты»). Для класса «трава» $P_{22} = 0,81$ (вероятность ошибочного решения в пользу класса 1 – «почва» $P_{12} = 0,19$), для класса «кусты» $P_{55} = 0,82$ (вероятности ошибок $P_{15} = 0,1$ и $P_{25} = 0,07$). В то же время, классы 3 – «вода» и 4 – «строения» на изображении без шума распознаются практически безошибочно: $P_{33} = 0,97$, $P_{44} = 0,99$.




Рис. 5. Результаты пост-обработки изображения по методу $K(3 \times 3)\#3$:
а – $\sigma = 0$; б – $\sigma = 4$; в – $\sigma = 10$; г – $\sigma = 16$

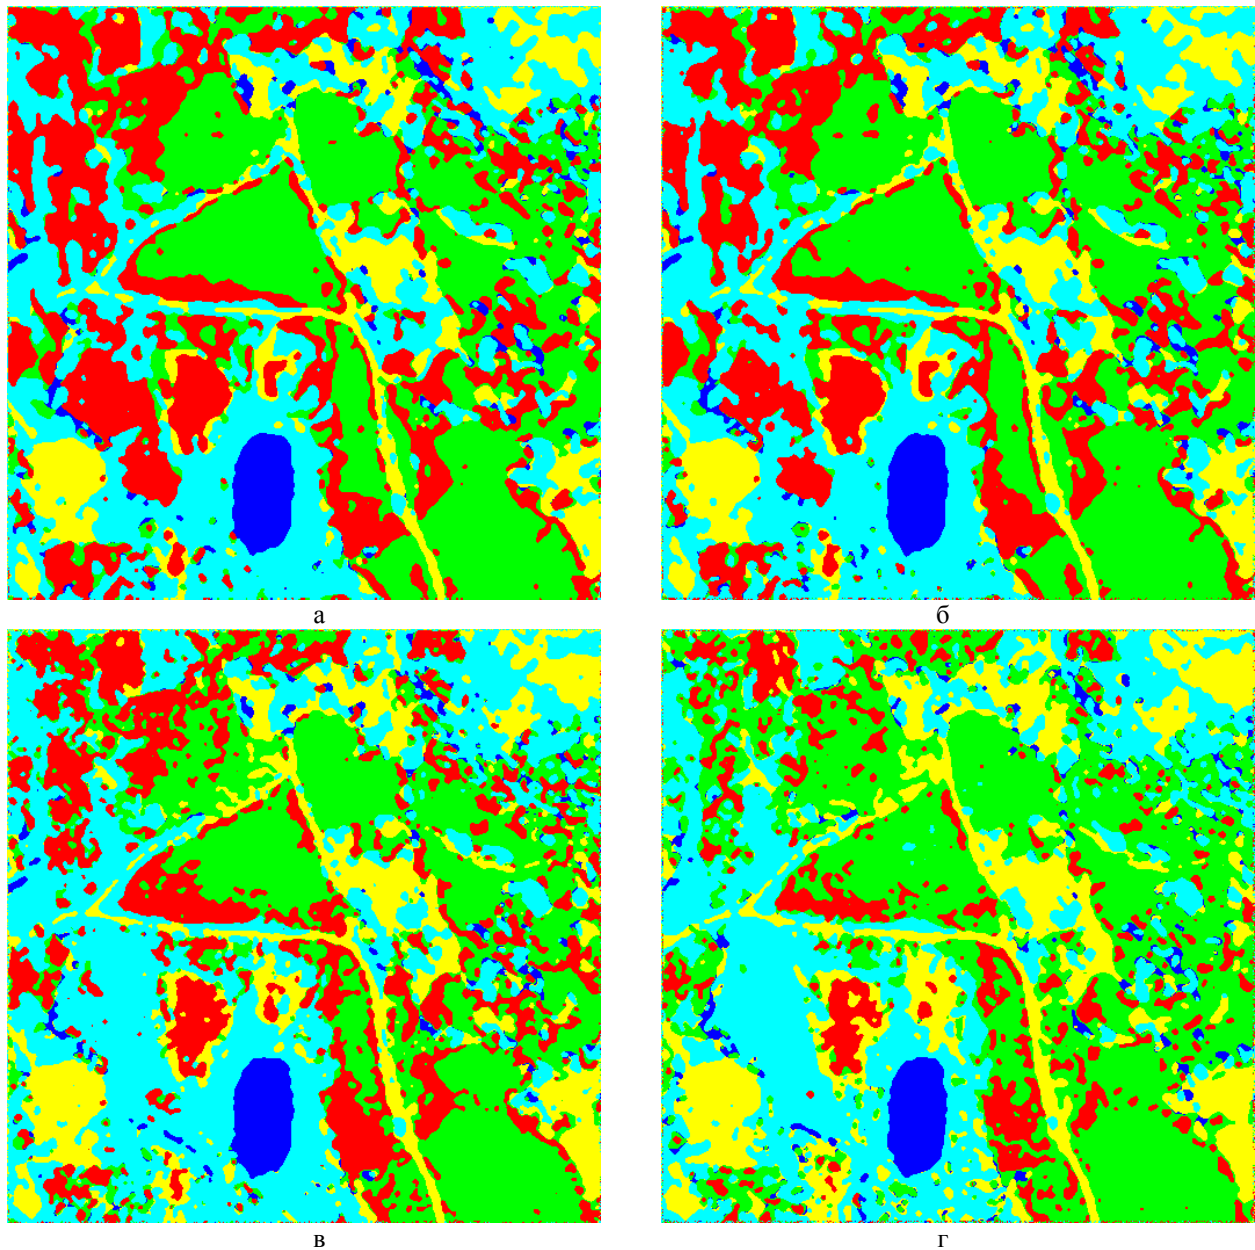


Рис. 6. Результаты пост-обработки изображения по методу $M(5 \times 5) \# 3$:
 а – $\sigma = 0$; б – $\sigma = 4$; в – $\sigma = 10$; г – $\sigma = 16$

При классификации изображений, зашумленных АБГШ, увеличение уровня шума приводит к существенному ухудшению показателей достоверности распознавания объектов, что демонстрируют результаты пост-обработки сегментированных изображений (см. рис. 5 – 7, табл. 4).

Например, при СКО шума $\sigma = 4$ для класса 1 – «почва» $P_{11} = 0,63$ (снизилась на 16 %), а при $\sigma = 16$ – $P_{11} = 0,36$ (снизилась на 52 %). Аналогично, при $\sigma = 16$ вероятность правильного распознавания класса 2 – «трава» уменьшилась на 50 %, классов 3 – «вода» и 5 – «кусты» – на 30 %. Меньшее воздействие шумовая компонента оказала на результаты распознавания класса 4 – «строения»: при $\sigma = 16$ $P_{44} = 0,93$ (т.е. снизилась всего на 6 %).

Таким образом, увеличение СКО шума приводит к резкому снижению вероятности правильной классификации по критерию максимального правдоподобия: если для незашумленного изображения $P_{пр} = 0,83$ (см. табл. 3), то при $\sigma = 16$ оценка $P_{пр}$ снижается до 0,5 (см. табл. 4).

При отсутствии шума локальная итеративная пост-обработка сегментированного изображения приводит к повышению правильной классификации площадных объектов классов 1 – «почва», 2 – «трава», 5 – «кусты» на 5–16 %; в то же время для классов 3 – «вода» и 4 – «строения», содержащих как площадные (озеро, здания), так и линейные объекты (река, дорога), вероятность правильного распознавания снижается на 1–4 %.




Рис. 7. Результаты пост-обработки изображения по методу $\Phi\#3$:
а – $\sigma = 0$; б – $\sigma = 4$; в – $\sigma = 10$; г – $\sigma = 16$

Общая вероятность правильного распознавания классов объектов $P_{пр}$ на исходном изображении возрастает от 0,83 (для метода максимального правдоподобия) до 0,862 (после трех итераций метода расширенной медианной фильтрации в окне (5×5) либо метода k -ближайших соседей с последовательным применением скользящих окон (3×3) , (5×5) и (3×3)).

Анализ результатов, полученных для зашумленных изображений, показал, что с увеличением СКО АБГШ на изображении эффективность методов пост-классификационной обработки (по сравнению с результатами, полученными на этапе статистического распознавания по критерию МП, $P_{ij}|МП$) проявляется сильнее: при $\sigma = 4$ $P_{пр}$ возрастает на

12–14 %, а при $\sigma = 16$ – на 20–34 %. При этом наибольшее улучшение достоверности распознавания получено для класса 2 – «трава» при использовании метода $M(5 \times 5)\#3$ (при $\sigma = 16$ $P_{22} = 0,68$, что на 70 % больше, чем контрольное значение $P_{22}|МП$). Однако для класса 5 – «кусты» метод $M(5 \times 5)\#3$ показывает результаты хуже, чем другие процедуры: при $\sigma = 16$ $P_{55} = 0,78$ (на 40 % больше, чем $P_{55}|МП$), в то время как для методов $\Phi\#3$ и $K(3 \times 3)\#3$ $P_{55} = 0,86$ – $0,91$ (соответственно, на 54–63 % больше, чем $P_{55}|МП$). Вероятность правильного распознавания класса 3 – «вода» после пост-обработки увеличивается на 27–30 % (практически независимо от используемого метода), $P_{33} = 0,89$ – $0,91$.

Класс 4 – «строения» оказался наименее восприимчивым к воздействию аддитивной шумовой компоненты (в принятом диапазоне варьирования σ): если при распознавании по методу МП $P_{44} = 0,99$ при $\sigma = 4$ и $P_{44} = 0,93$ при $\sigma = 16$, то после пост-обработки $P_{44} = 0,97-0,99$ при $\sigma = 4$ (т.е., в худшем случае, может уменьшиться на 2%), $P_{44} = 0,98-0,99$ при $\sigma = 16$ (увеличивается на 6–7 %).

Наихудшие результаты распознавания получены для класса 1 – «почва»; если в отсутствии шума на изображении $P_{11} = 0,75$ (удовлетворительная оценка), то с увеличением СКО шума P_{11} резко снижается и при $\sigma = 16$ составляет всего 0,37, причем ни один из исследуемых методов пост-обработки не позволяет улучшить значение P_{11} , напротив, вероятность правильного распознавания класса 1 снижается еще на 3–16 % (при $\sigma = 16$ $P_{11} = 0,36$ – для метода $K(3 \times 3)\#3$ и $P_{11} = 0,31$ – для метода $M(5 \times 5)\#3$).

В целом, можно делать вывод, что использование методов пост-классификационной обработки позволяет существенно повысить общую вероятность правильного распознавания объектов на изображениях, искаженных АБГШ, несмотря на то, что достоверность распознавания отдельных классов (в данном случае, класса 1 – «почва») может несколько снизиться. Наиболее эффективным с точки зрения критерия $P_{пр}$ оказался метод $M(w \times w)$ – расширенная медианная фильтрация; при реализации этого метода в виде итерационной процедуры $M(5 \times 5)\#3$ оценка $P_{пр} = 0,67$ (при $\sigma = 16$), что на 34 % больше, чем его контрольное значение ($P_{пр}|МП = 0,50$). При этом следует отметить, что при значениях СКО шума $\sigma \leq 8$ все исследуемые методы пост-обработки ($K(w \times w)$, $M(w \times w)$, Φ) демонстрируют практически идентичные результирующие величины $P_{пр}$, однако с увеличением СКО шума лучшая эффективность метода $M(w \times w)$ становится очевидной (см. рис. 8, на котором изображены экспериментально полученные зависимости оценок $P_{пр}$ от СКО шума для разных процедур обработки, включая процедуру статистической классификации по критерию МП).

На рис. 9 показаны зависимости оценок общей вероятности ошибок распознавания $P_{ош}$ от дисперсии шума σ^2 ; точками показаны результаты расчетов, линиями – функции $g_F(\sigma^2)$, аппроксимирующие точечные оценки $P_{ош}$. Анализ поведения зависимостей (рис. 9) позволил выбрать в качестве $g_F(\sigma^2)$ функции вида

$$g_F(\sigma^2) = b_1 P_{ош}^0 |F \cdot \ln(\sigma^2 + b_2) + b_3,$$

где F – идентификатор метода обработки (МП, $\Phi\#3$, $K(3 \times 3)\#3$, $M(5 \times 5)\#3$; для упрощения записи далее в выражениях будем использовать следующие обозначения: П, Φ , К, М, соответственно);

$P_{ош}^0 |F$ – минимальная общая вероятность ошибки распознавания (при отсутствии шума), которую может обеспечить метод обработки F ;

\vec{b} – вектор неизвестных коэффициентов (параметров аппроксимирующей функции).

Оценки коэффициентов \vec{b} были найдены с помощью метода наименьших квадратов.




Рис. 8. Зависимости оценок $P_{пр}$ от СКО шума для разных процедур обработки:
1 – МП; 2 – $\Phi\#3$; 3 – $K(3 \times 3)\#3$; 4 – $M(5 \times 5)\#3$




Рис. 9. Зависимости оценок $P_{ош}$ от дисперсии шума для разных процедур обработки:
1 – МП; 2 – $\Phi\#3$; 3 – $K(3 \times 3)\#3$; 4 – $M(5 \times 5)\#3$

Эмпирические зависимости оценок $P_{\text{ош}}$ от дисперсии шума σ^2 для исследуемых методов можно представить как

$$\begin{aligned} g_{\Pi}(\sigma^2) &= 0,615 \cdot P_{\text{ош}}^0 |\Pi \cdot \ln(\sigma^2 + 10,324) - 0,076; \\ g_{\text{K}}(\sigma^2) &= 0,873 \cdot P_{\text{ош}}^0 |\text{K} \cdot \ln(\sigma^2 + 38,221) - 0,341; \\ g_{\text{M}}(\sigma^2) &= 0,538 \cdot P_{\text{ош}}^0 |\text{M} \cdot \ln(\sigma^2 + 15,550) - 0,073; \\ g_{\Phi}(\sigma^2) &= 0,980 \cdot P_{\text{ош}}^0 |\Phi \cdot \ln(\sigma^2 + 42,780) - 0,416. \end{aligned}$$

Максимальная относительная погрешность аппроксимации зависимостей $P_{\text{ош}}(\sigma^2)$ δ_{max} не превышает 12 % (при $\sigma^2 = 16$), с увеличением дисперсии шума погрешность аппроксимации снижается, и в диапазоне значений $16 < \sigma^2 \leq 256$ $\delta_{\text{max}} \leq 6$ %. Это означает, что выражения $g_{\text{F}}(\sigma^2)$ можно использовать для приближенной оценки (прогнозирования) значений показателей достоверности распознавания объектов $P_{\text{ош}}$ и $P_{\text{пр}}$ (где $P_{\text{пр}} = 1 - P_{\text{ош}}$) на изображениях, искаженных АБГШ; при этом требуется предварительно оценить приемлемость модели аддитивного шума и найти оценку его дисперсии, что можно сделать в автоматическом режиме [7, 8].

Исследования показали, что алгоритмы, основанные лишь на спектральных признаках, позволяют надежно распознавать классы объектов только при наличии хороших эталонных участков, используемых для обучения, и при условии достаточной статистической разделимости классов в пространстве признаков [17]. Присутствие шума в данных ДЗ усложняет задачи распознавания, поэтому при попиксельной классификации образов возникает большое количество ошибок, когда объекты либо не выделяются, либо относятся к другому классу. Улучшить показатели достоверности распознавания классов на изображениях, искаженных АБГШ, можно путем пост-обработки сегментированных изображений; процедуры пост-классификационной обработки, по сути, являются алгоритмами локальной пространственной фильтрации изображения в псевдоцветах и позволяют корректировать решение о классе каждого пиксела посредством учета классов пикселов его окрестности. Дестабилизирующее влияние шума проявляется в нарушении статистических связей пикселов, характеризующих пространственное расположение деталей объекта, в результате при больших уровнях шума статистически однородные области, соответствующие образу некоторого класса, распадаются на несвязанные группы точек. Пост-обработка позволяет сгладить проявления этого эффекта, при этом пиксели, принадлежащие определенному классу, группируются более компактным образом, и достоверность классификации площадных объектов возрастает.

Заключение

Применение методов пространственной фильтрации к сегментированному изображению позволяет существенно снизить эффекты избыточной сегментации и повысить достоверность классификации площадных объектов на зашумленных изображениях. Эффективность различных процедур пост-классификационной обработки исследовалась на реальном спутниковом изображении, к которому был добавлен пространственно некоррелированный белый гауссов шум; для формирования шумовой компоненты использовался метод стохастического моделирования, значение СКО шума σ варьировалось в диапазоне 4...16. В качестве критериев эффективности исследуемых процедур были приняты статистические оценки общей вероятности правильного распознавания $P_{\text{пр}}$ и вероятности правильного распознавания k -го класса; анализ полученных критериев выполнялся в сравнении с их контрольными значениями, полученными по результатам серии статистических распознаваний по критерию максимального правдоподобия. Для обучения (построения эталонных описаний классов) использовались незашумленные выборки исходного многоканального изображения. Показано, что пост-обработка сегментированных изображений приводит к увеличению $P_{\text{пр}}$ на 20–34 % по сравнению с попиксельной классификацией изображений с шумом.

Для повышения эффективности процедур пост-обработки необходимо комплексно учитывать цветовые, геометрические и структурные характеристики образов объектов, что позволит включить в процедуры принятия решения описания основных связей и закономерностей пространственной структуры изображения [11, 12, 18].

Прикладное значение результатов состоит в том, что предлагаемый подход позволяет снизить количество точечных ошибок поэлементной классификации, обусловленных как недостаточной информативностью признаков классов, так и воздействием случайного шума; получены зависимости оценок общей вероятности ошибок распознавания $P_{\text{ош}}$ от дисперсии аддитивного шума, которые можно использовать для прогнозирования степени снижения достоверности распознавания и принятия решения о целесообразности использования дополнительных методов шумоподавления. Направление дальнейших исследований – оценка и прогноз эффективности методов локальной пространственной обработки многоканальных изображений, искаженных шумами различных типов (как сигнално-зависимых, так и сигнално-независимых) и процедур пост-обработки сегментированных изображений в задачах автоматического распознавания образов.

Литература

1. 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.

2. Adaptive DCT-based filtering of images corrupted by spatially correlated noise [Text] / V. Lukin, N. Ponomarenko, K. Egiazarian, J. Astola // Proc. SPIE Conference Image Processing : Algorithms and Systems VI. – 2008. – Vol. 6812. – 12 p.

3. Image denoising by sparse 3D transform-domain collaborative filtering [Text] / K. Dabov, A. Foi, V. Katkovnik, and K. Egiazarian // J. IEEE Transactions on Image Processing. – 2007. – Vol. 16(8). – P. 2080 – 2095.

4. Zhong, P. Multiple-Spectral-Band CRFs for Denoising Junk Bands of Hyperspectral Imagery [Text] / P. Zhong, R. Wang // IEEE Transactions on Geoscience and Remote Sensing. – 2013. – Vol. 51(4). – P. 2269 – 2275.

5. 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.

6. Yuan, Q. Hyperspectral Image Denoising With a Spatial-Spectral View Fusion Strategy [Text] / Q. Yuan, L. Zhang, H. Shen // IEEE Trans. Geosci. Remote Sens. – 2014. – Vol. 52. – P. 2314 – 2325.

7. Image Informative Maps for Estimating Noise Standard Deviation and Texture Parameters [Text] / M. Uss, B. Vozel, V. Lukin et al. // EURASIP Journal on Advances in Signal Processing. – 2011. – Vol. 2011. – 12 p. doi:10.1155/2011/806516.

8. Modeling and estimation of signal-dependent noise in hyperspectral imagery [Text] / J. Meola, M. T. Eismann, R. L. Moses, J. N. Ash // J. Appl. Opt. – 2011. – Vol. 50. – P. 3829 – 3846.

9. 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.

10. 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.

11. 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. Игнатев // Вестн. МГТУ им. Н. Э. Баумана. Серия Естественные науки. – 2017. – № 3. – С. 135 – 146. doi: 10.18698/1812-3368-2017-3-135-146.

12. Афанасьев, А. А. Гибридные методы автоматизированной идентификации изменений ландшафтного покрова по данным дистанционного зондирования 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.

13. Васильева, И. К. Анализ методов постклассификационной обработки многоканальных изображений [Текст] / И. К. Васильева, В. В. Лукин // Радіоелектронні і комп'ютерні системи. – 2019. – № 1 (89). – С. 17 – 28. doi: 10.32620/reks.2019.1.00.

14. 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.

15. Хан, Г. Статистические модели в инженерных задачах [Текст] / Г. Хан, С. Шапиро. – М. : Мир, 1969. – 369 с.

16. 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.

17. 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.

18. 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.

References

1. Abramov, N. S., Makarov, D. A., Talalae, A. A., Fralenko, V. P. Sovremennye metody intellektual'noi obrabotki dannykh DZZ [Modern methods for intelligent processing of Earth remote sensing data]. Programmye 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.

2. Lukin, V., Ponomarenko, N., Egiazarian, K., Astola, J. Adaptive DCT-based filtering of images corrupted by spatially correlated noise. Proc. SPIE Conference Image Processing: Algorithms and Systems VI, 2008, vol. 6812. 12 p.

3. Dabov, K., Foi, A., Katkovnik, V., Egiazarian, K. Image denoising by sparse 3D transform-domain collaborative filtering. *J. IEEE Transactions on Image Processing*, 2007, vol. 16(8), pp. 2080 – 2095.
4. Zhong, P., Wang, R. Multiple-Spectral-Band CRFs for Denoising Junk Bands of Hyperspectral Imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, vol. 51(4), pp. 2269 – 2275.
5. 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.
6. Yuan, Q., Zhang, L., Shen, H. Hyperspectral Image Denoising With a Spatial-Spectral View Fusion Strategy. *IEEE Trans. Geosci. Remote Sens.*, 2014, vol. 52, pp. 2314 – 2325.
7. Uss, M., Vozel, B., Lukin, V., Abramov, S., Baryshev, I., Chehdi, K. Image Informative Maps for Estimating Noise Standard Deviation and Texture Parameters. *EURASIP Journal on Advances in Signal Processing*, 2011, vol. 2011, 12 p. doi:10.1155/2011/806516.
8. Meola, J., Eismann, M. T., Moses, R. L., Ash, J. N. Modeling and estimation of signal-dependent noise in hyperspectral imagery. *J. Appl. Opt.*, 2011, vol. 50, pp. 3829 – 3846.
9. 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.
10. 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.
11. Gurchenkov, A. A., Murynin, A. B., Trekin, A. N., Ignat'ev V. Yu. Metod ob'ektno-orientovannoi 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.
12. 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.
13. Vasil'eva, I. K., Lukin, V. V. Analiz metodov postklassifikatsionnoi obrabotki mnogokanal'nykh izobrazhenii [Multichannel images post-classification processing techniques analysis]. *Radioelektronni i komp'yuterni systemy – Radioelectronic and computer systems*, 2019, no. 1 (89), pp. 17 – 28. (In Russian). doi: 10.32620/reks.2019.1.00.
14. 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.
15. Khan, G., Shapiro, S. *Statisticheskie modeli v inzhenernykh zadachakh* [Statistical models in engineering problems]. Moscow, Mir Publ., 1969. 369 p.
16. Babakov, M. F. Ob odnom sposobe aproksimatsii raspredeleniy mnogomernykh polyarimetricheskikh 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).
17. 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.
18. 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.

Поступила в редакцію 15.05.2019, рассмотрена на редколлегии 12.06.2019

ДОСЛІДЖЕННЯ ЕФЕКТИВНОСТІ МЕТОДІВ ПОСТ-КЛАСИФІКАЦІЙНОЇ ОБРОБКИ ЗАШУМЛЕНИХ БАГАТОКАНАЛЬНИХ ЗОБРАЖЕНЬ

І. К. Васильєва, В. В. Лукін

Предметом вивчення в статті є методи локальної просторової пост-обробки зображень, отриманих в результаті статистичної попиксельної класифікації багатоканальних супутникових знімків, спотворених адитивним гаусовим шумом. **Метою** є дослідження ефективності різних варіантів методів пост-класифікаційної обробки зображень у широкому діапазоні значень відношення сигнал-шум; у якості критерію ефективності прийнято показники достовірності класифікації об'єктів спостереження. **Завдання:** згенерувати випадкові значення яскравостей шумових компонент, забезпечивши їх відповідність прийнятій ймовірнісній моделі; реалізувати процедуру статистичної контрольованої класифікації за методом максимальної правдоподібнос-

ті для зображень, спотворених шумом; оцінити результати визначення об'єктів на зашумлених зображеннях за критерієм емпіричної ймовірності правильного розпізнавання; реалізувати процедури локальної об'єктно-орієнтованої пост-обробки зображень; дослідити вплив дисперсії шуму на ефективність процедур пост-обробки. Використовуваними **методами** є: методи стохастичного моделювання, методи апроксимації емпіричних залежностей, статистичні методи розпізнавання, методи теорії ймовірностей і математичної статистики, методи локальної просторової фільтрації. Отримані наступні **результати**. Реалізовано алгоритми рангової і зваженої медіанної пост-обробки з урахуванням результатів класифікації за k-найближчими сусідами у вікні фільтра. Виконано аналіз ефективності розроблених алгоритмів на підставі оцінок ймовірностей правильного розпізнавання об'єктів на зашумлених зображеннях. Отримано емпіричні залежності оцінок загальної ймовірності помилок розпізнавання від дисперсії адитивного шуму. **Висновки**. Наукова новизна отриманих результатів полягає в наступному: отримали подальший розвиток комплексні підходи до побудови вирішальних правил з урахуванням дестабілізуючих факторів – показано, що використання методів локальної об'єктно-орієнтованої фільтрації сегментованих зображень дозволяє зменшити кількість точкових помилок поелементної класифікації об'єктів, і частково відновити зв'язність і просторовий розподіл елементів структури зображення.

Ключові слова: класифікація; апроксимація; адитивний гаусів шум; просторова фільтрація; ймовірність вірного розпізнавання.

INVESTIGATION OF THE EFFICIENCY OF THE POST-CLASSIFICATION TECHNIQUES FOR NOISY MULTI-CHANNEL IMAGES

I. K. Vasilyeva, V. V. Lukin

The subject matter of the article are the methods of local spatial post-processing of images obtained as a result of statistical per-pixel classification of multichannel satellite images distorted by additive Gaussian noise. The aim is to investigate the effectiveness of some variants of post-classification image processing methods over a wide range of signal-to-noise ratio; as a criterion of effectiveness, observed objects classification reliability indicators have been taken. The tasks to be solved are: to generate random values of the noise components brightness, ensuring that they coincide with the adopted probabilistic model; to implement a procedure of statistical controlled classification by the maximum likelihood method for images distorted by noise; to evaluate the results of the objects selection in noisy images by the criterion of the empirical probability of correct recognition; to implement procedures for local object-oriented post-processing of images; to investigate the effect of noise variance on the effectiveness of post-processing procedures. The methods used are: methods of stochastic simulation, methods of approximation of empirical dependencies, statistical methods of recognition, methods of probability theory and mathematical statistics, methods of local spatial filtering. The following results have been obtained. Algorithms of rank and weighted median post-processing with considering the results of classification by k-nearest neighbors in the filter window were implemented. The developed algorithms efficiency analysis that based on estimates of the correct recognition probability for objects on noisy images was carried out. Empirical dependences of the estimates of the overall recognition errors probability versus the additive noise variance were obtained. Conclusions. The scientific novelty of the results obtained is as follows: combined approaches to building decision rules, taking into account destabilizing factors, have been further developed – it has been shown that the use of methods of local object-oriented filtering of segmented images reduces the number of point errors in the element-based classification of objects, as well as partially restores the connectedness and spatial distribution of image structure elements.

Keywords: classification; approximation; additive Gaussian noise; spatial filtering; probability of correct recognition.

Васильєва Ирина 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.