

УДК 528.85/.87(15)

Л.В. Орешкина

## СРАВНЕНИЕ И ОЦЕНКА ТОЧНОСТИ МЕТОДОВ КЛАССИФИКАЦИИ МНОГОЗОНАЛЬНЫХ СПУТНИКОВЫХ ИЗОБРАЖЕНИЙ

*Рассматривается общий подход к классификации многозональных спутниковых изображений. Даются сравнение, оценка точности и анализ методов классификации (с обучением и без) многозональных спутниковых изображений применительно к представительским классам землепользования на территории Республики Беларусь. Анализ проводится с использованием программного продукта ERDAS Imagine 8.7 компании Leica Geosystems.*

### Введение

Несмотря на то, что многие исследователи по-прежнему отдают предпочтение традиционной методике визуального дешифрирования, где высок субъективизм результатов, зависящих от опыта и модельных представлений дешифровщика, на сегодняшний день классификация облегчает дешифрирование наибольшей части информации, содержащейся в изображении, и является одним из важных этапов автоматизированного дешифрирования.

Классификация спутниковых изображений подразумевает распознавание природных объектов местности по тону, цвету, текстуре рисунка, его размерам, спектральным характеристикам в процессе отнесения пикселей изображения в конечное число классов. Классы могут быть связаны с известными особенностями ландшафта или представлять области, которые отличаются на изображении. Классификация может быть выполнена методами с обучением и без или их комбинацией. В зависимости от рассматриваемой задачи различные методы классификации могут давать хорошие результаты. Результатом классифицированного изображения является тематическая карта, показывающая растительность, землю, пастбища, населенные пункты и т. д. Эти внешние характеристики присущи компонентам ландшафта, которые отличаются на снимке благодаря различным спектральным яркостям [1].

В последнее время возросла потребность в современной и достоверной информации по земельному покрову и использованию земель как для обеспечения сельскохозяйственных задач, так и для целей охраны окружающей среды. Поэтому, чтобы выделить на спутниковом изображении площадные структуры, обнаружить изменения, необходимо провести анализ характеристик пространственного распределения пикселей изображения. В настоящее время одним из наиболее разработанных методов такого анализа является классификация [2, 3]. В связи с этим с помощью программного продукта ERDAS Imagine 8.7 [4, 5] была изучена возможность использования данных, полученных со спутника Landsat в ряде областей Беларуси, для различных методов классификации с целью сравнения их результатов и оценки точности. Сделан вывод о принципиальной возможности применения данных спутника для изучения представительских классов территории Республики Беларусь.

### 1. Общий подход к классификации многозональных спутниковых изображений

Под классификацией понимают принятие решения о принадлежности каждого пикселя спутникового изображения тому или иному классу [6]. Различают два вида классификации: с обучением и без.

*Классификация с обучением* является наиболее эффективным методом. Для его реализации на изображении выделяются обучающие участки, отождествляемые с выбранными классами. Классификация с обучением осуществляется с помощью некоторого решающего правила (математического алгоритма, который выполняет фактическую сортировку пикселей по классам).

Классификация с обучением применяется, когда необходимо идентифицировать относительно немного классов, когда участки обучения могут быть проверены с достоверными наземными данными или когда на изображении можно идентифицировать однородные области, которые представляют каждый класс. Достоверные наземные данные (полученные в результате полевых работ, анализа аэрофотосъемки, карты местности, личного опыта и т. д.) являются наиболее точными данными, доступными об области исследования. Эти данные должны быть получены в то же время, что и многозональные спутниковые изображения, чтобы обеспечить их максимальное соответствие.

*Классификация без обучения* требует минимального количества начальных входных данных, однако возникает необходимость интерпретировать созданные классы. В классификации без обучения реализуются методы кластерного анализа, заключающиеся в разбиении анализируемого пространства признаков на однородные кластеры. Основная сложность здесь состоит в выборе числа кластеров: при небольшом их числе увеличивается вероятность ложной классификации пикселя, а при большом числе существенно усложняется отождествление кластера с классом поверхности земли.

Классификация с обучением может использовать набор классов, созданный классификацией без обучения. Применение комбинации классификации с обучением и без может привести к приемлемым результатам, особенно с большими наборами данных. Например, классификация без обучения может быть полезна для создания основного набора классов, после чего может использоваться классификация с обучением для дальнейшего определения классов.

## 2. Выбор представительских классов

*Выбор представительских классов* (количества и характера) производится исходя из решаемой задачи, их наличия на изображении, внутренней неоднородности, близости между собой и различимости в пространстве признаков. Схожесть классов приводит к наличию в пространстве признаков областей наложения. Чтобы учесть эту особенность, дополнительно можно использовать *смешанный класс*.

В настоящей работе использовались данные съемки со спутника Landsat от 6 мая 1986 г., 21 июля 1999 г. и 5 июня 2000 г. на территории Республики Беларусь (спектральные зоны 0,45–0,52; 0,52–0,60; 0,63–0,69; 0,76–0,90; 1,55–1,74; 2,08–2,35 мкм; пространственное разрешение 28,5 м).

При выборе представительских классов были использованы цифровая карта местности за 2005 г. масштабом 1 : 200 000, данные съемки со спутника Landsat, учитывалось распределение земельного фонда Республики Беларусь по данным Государственного земельного кадастра на 01.01.2005 г. По отношению к общей земельной площади, которая составляет 207,6 тыс. км<sup>2</sup> (100 %), площадь сельскохозяйственных земель составляет 90,76 тыс. км<sup>2</sup> (43,72 %), лесных земель – 88,22 тыс. км<sup>2</sup> (42,49 %), земель под болотами и водными объектами – 13,95 тыс. км<sup>2</sup> (6,72 %), земель под застройками и иными местами общего пользования – 4,81 тыс. км<sup>2</sup> (2,32 %), земель под дорогами и других земель – 9,86 тыс. км<sup>2</sup> (4,75 %). Сельскохозяйственные земли, в свою очередь, включают: пахотные – 56,16 тыс. км<sup>2</sup> (27,1 %), используемые под постоянные культуры – 1,71 тыс. км<sup>2</sup> (0,8 %), сенокосные и пастбищные – 32,89 тыс. км<sup>2</sup> (15,82 %). Исходя из того, что существует множество классов объектов, которые могут иметь очень схожий вид на изображении с пространственным разрешением 28,5 м (например, промышленные зоны, жилые зоны, зоны смешанного использования и др.), для классификации не применялись многие классы землепользования [7]. Вместо этого все классы объектов были разделены на пять основных групп землепользования: растительный покров, почва, лес, населенные пункты и водоемы. На снимках за 1999 и 2000 гг. были введены дополнительные классы «облачность» и «тени» из-за присутствия облачности. Также пришлось ввести смешанный класс «деревья», характеризующий перекрытие близких тематических категорий, например пересечение классов «хвойный лес» и «широколиственный лес».

Таблица 1

Представительские классы землепользования

Номер класса	1	2	3	4	5	6
Наименов. класса	Поля	Посевы	Пастбища	Пашня	Речной песок	Широколиственный лес
Номер класса	7	8	9	10	11	12
Наименов. класса	Хвойный лес	Деревья	Облака	Тени	Насел. пункт	Водоемы

В качестве полигона для классификации был выбран фрагмент, затрагивающий Минскую, Могилевскую и Гомельскую области. Общая площадь фрагмента составила 41,568 тыс. км<sup>2</sup>. Выбор района обусловлен наличием оцифрованной информации для данного района, а также основными представительскими классами землепользования.

### 3. Обучающие участки

*Обучающие участки* – области на изображении, выявленные как представители классов (например, типы растительного покрова), имеющие определенный интерес. Поскольку точность классификации спутниковых изображений зависит от правильности выбора обучающих участков, важно, чтобы они были представительскими для идентифицируемых классов. Это не обязательно подразумевает, что обучающие участки должны содержать большое количество пикселей, важно обеспечить как можно большее значение отношения числа пикселей из соответствующего класса и ему не принадлежащих. Выбор обучающих участков является, как правило, итерационным процессом [8].

Распределение значений в пределах каждой выборки должно быть нормальным или близким к нормальному и иметь минимально возможную дисперсию для успешной работы статистических алгоритмов. Для этого выполнялась проверка на нормальность распределения значений яркости по каждому классу с использованием критерия Хи-квадрат в пакете STATISTICA. Проверка показала, что значение яркостей для каждого класса соответствует нормальному закону распределения. Ввиду того, что из всех классов наибольшая дисперсия наблюдалась в классе «поля», на рис. 1 для этого класса показана гистограмма статистического распределения значений яркости.

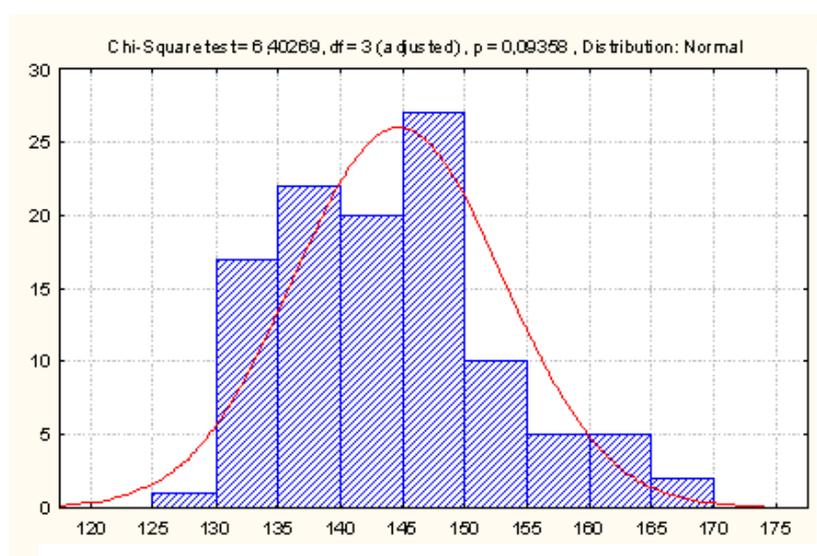


Рис. 1. Гистограмма статистического распределения значений яркости для класса «поля»

В результате проверки для класса «поля» гипотеза о нормальном законе распределения принимается, так как уровень значимости  $p = 0,094$ .

#### 4. Выбор и формирование обучающих участков

Важными этапами классификации спутникового изображения являются выбор и формирование обучающих участков для представительских классов землепользования.

При выборе обучающих участков необходимо определить наиболее информативные спектральные каналы. Спектральные отражательные характеристики каждого канала зависят от условий съемки: угла сканирования, высоты Солнца и состояния атмосферы. Поэтому окончательный выбор требуемых спектральных каналов осуществляется на основе спектральных отражательных характеристик классов и их различий между собой по каждому каналу.

Для анализа информативности шести спектральных каналов изображения со спутника Landsat была проведена ручную сегментацию 12 классов землепользования, для которых были посчитаны средние значения яркости и дисперсии. Графики характеристик средних значений и дисперсии в различных каналах длин волн для каждого представительского класса землепользования показаны на рис. 2.

На рис. 2 видны заметные различия по средним значениям яркости и дисперсии в третьем (0,63–0,69), четвертом (0,76–0,90) и пятом (1,55–1,74) каналах для многих представительских классов землепользования. Очень большое значение дисперсии наблюдается в шестом канале для класса «поля». Поэтому шестой канал не использовался для классификации. Классы «пашня», «речной песок», «деревья» и «населенный пункт» имеют среднюю по величине дисперсию, класс «хвойный лес» – самую низкую. В частности, для дисперсии значений яркости водной поверхности тоже характерны весьма малые значения. Это позволяет достаточно четко проводить различие между водой и сушей. В целом комбинация из третьего, четвертого и пятого каналов отображает растительность в различных оттенках и тонах оранжевого, голубого, зеленого и коричневого цветов, а также дает возможность анализа влажности почвы. Чем выше влажность почв, тем темнее она выглядит, что обусловлено поглощением водой излучения ИК-диапазона.

Формирование обучающих участков представительских классов землепользования производится на основе информации, извлеченной из многозонального изображения дистанционного зондирования с учетом двухмерного изображения признакового пространства (рис. 3).

Изображение признакового пространства (рис. 3, б) имеет размерность  $255 \times 255$  и показывает взаимное распределение интенсивностей пикселей в третьем и пятом каналах исходного многозонального изображения. Каждый пиксель этого изображения с координатами  $(i, j)$  имеет значение, равное частоте встречаемости пикселей исходного многозонального изображения с интенсивностью  $i$  в третьем канале и  $j$  в пятом канале. Для удобства визуализации изображения признакового пространства используется цветовая палитра, в которой цвет и его насыщенность характеризуют взаимное распределение интенсивностей пикселей в третьем и пятом каналах. Чем выше частота встречаемости пары интенсивностей  $(i, j)$ , тем ярче выглядит соответствующий пиксель изображения признакового пространства. При связывании многозонального снимка и изображения признакового пространства все пиксели исходного изображения, имеющие одинаковую пару интенсивностей  $(i, j)$ , соответствуют одному пикселю  $(i, j)$  изображения признакового пространства. Поэтому, выбирая компактную область на изображении признакового пространства, можно сегментировать соответствующий класс объектов на многозональном изображении. При этом контроль правильной сегментации класса осуществляется визуально. Если сегментация происходит корректно, то выбранная компактная область на изображении признакового пространства используется в качестве эталона данного класса. Для эталона вычисляются характерные признаки класса, применяемые в дальнейшей классификации.

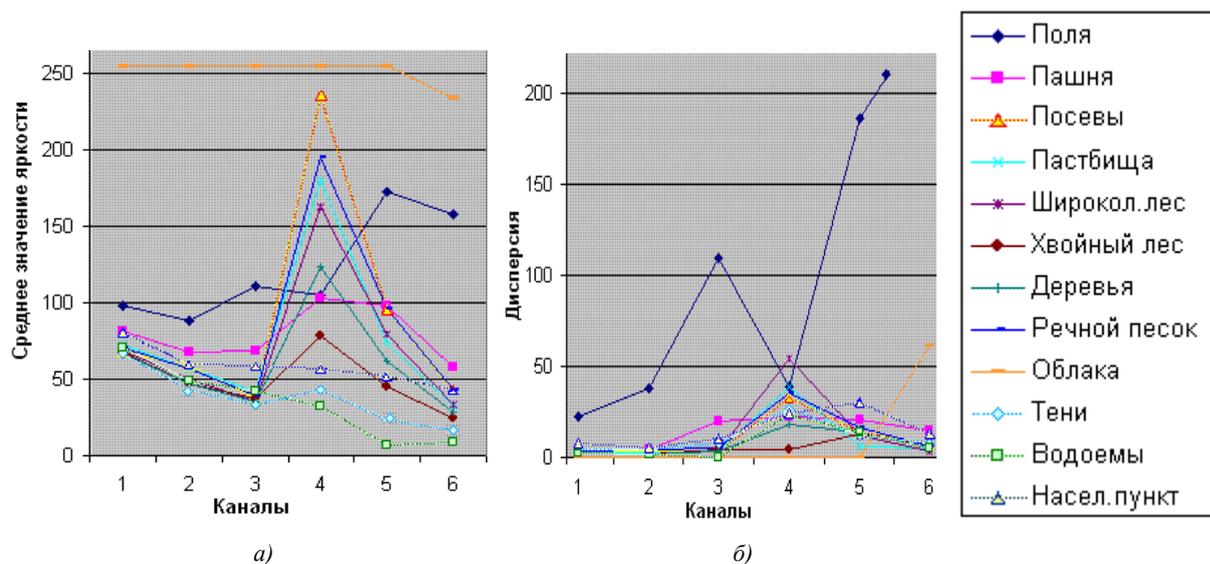


Рис. 2. Статистические параметры для классов землепользования космического изображения со спутника Landsat: а) среднее значение; б) дисперсия

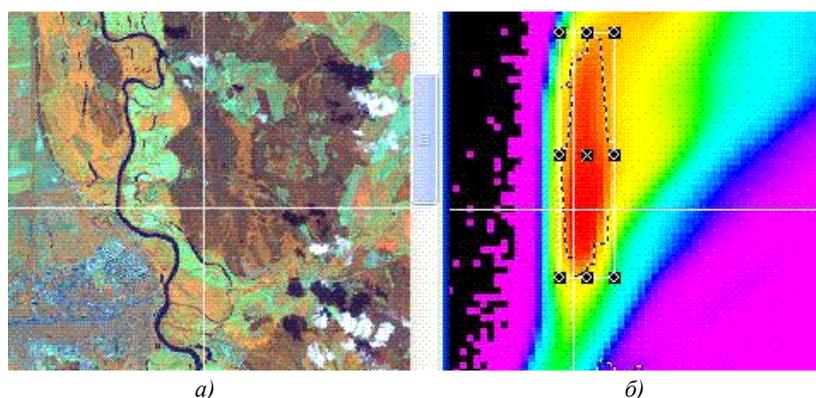


Рис. 3. Пример выбора из признакового пространства обучающего участка:  
а) фрагмент многозонального снимка, содержащий класс «хвойный лес» (темная область);  
б) формирование обучающего участка для класса «хвойный лес»

## 5. Методы классификации

В настоящей работе были использованы следующие методы классификации изображений со спутника Landsat [9–11]:

- итерационный алгоритм ISODATA. Этот алгоритм применяется для более точной, многошаговой кластеризации, при которой первоначально сгруппированные пиксели итеративно перемещаются из одного кластера в другой, пока не достигается оптимальная (в соответствии с заданными параметрами) кластеризация;

- метод параллелепипеда, в котором значения признаков каждого пикселя сравниваются с верхними и нижними пределами (их задание основано на знании классов);

- метод минимального расстояния. В этом методе для отнесения пикселя к классу используется минимальное евклидово расстояние между центрами (средними значениями яркости) обучающих выборок, корреляция между значениями яркости в разных спектральных зонах (описывающая форму кривой спектрального образа) не учитывается;

- классификация с использованием расстояния Махаланобиса. Здесь применяется корреляция между значениями яркости в разных спектральных зонах, решающее правило подобно классификатору «минимального расстояния», за исключением того, что дополнительно используется общая матрица ковариации. Это позволяет учесть изменчивость признаков классов;

– метод максимального правдоподобия (Байеса). Здесь определяется распределение яркостных величин в спектральных полосах для каждого класса, а встречаемый неизвестный пиксель затем назначается какому-либо классу на основе гауссовой вероятности с использованием матрицы ковариации. Метод предполагает, что значения яркости пикселей в каждом канале имеют нормальные распределения. В противном случае можно получить лучшие результаты, используя другие методы («параллелепипед» или «минимальное расстояние»).

### 6. Сравнение и оценка результатов экспериментов классификации

*Визуальное сравнение результатов классификаций между собой.* Результаты применения различных методов классификации на космических изображениях со спутника Landsat показаны на рис. 4. Здесь каждый класс землепользования соответствует своему индивидуальному цвету.

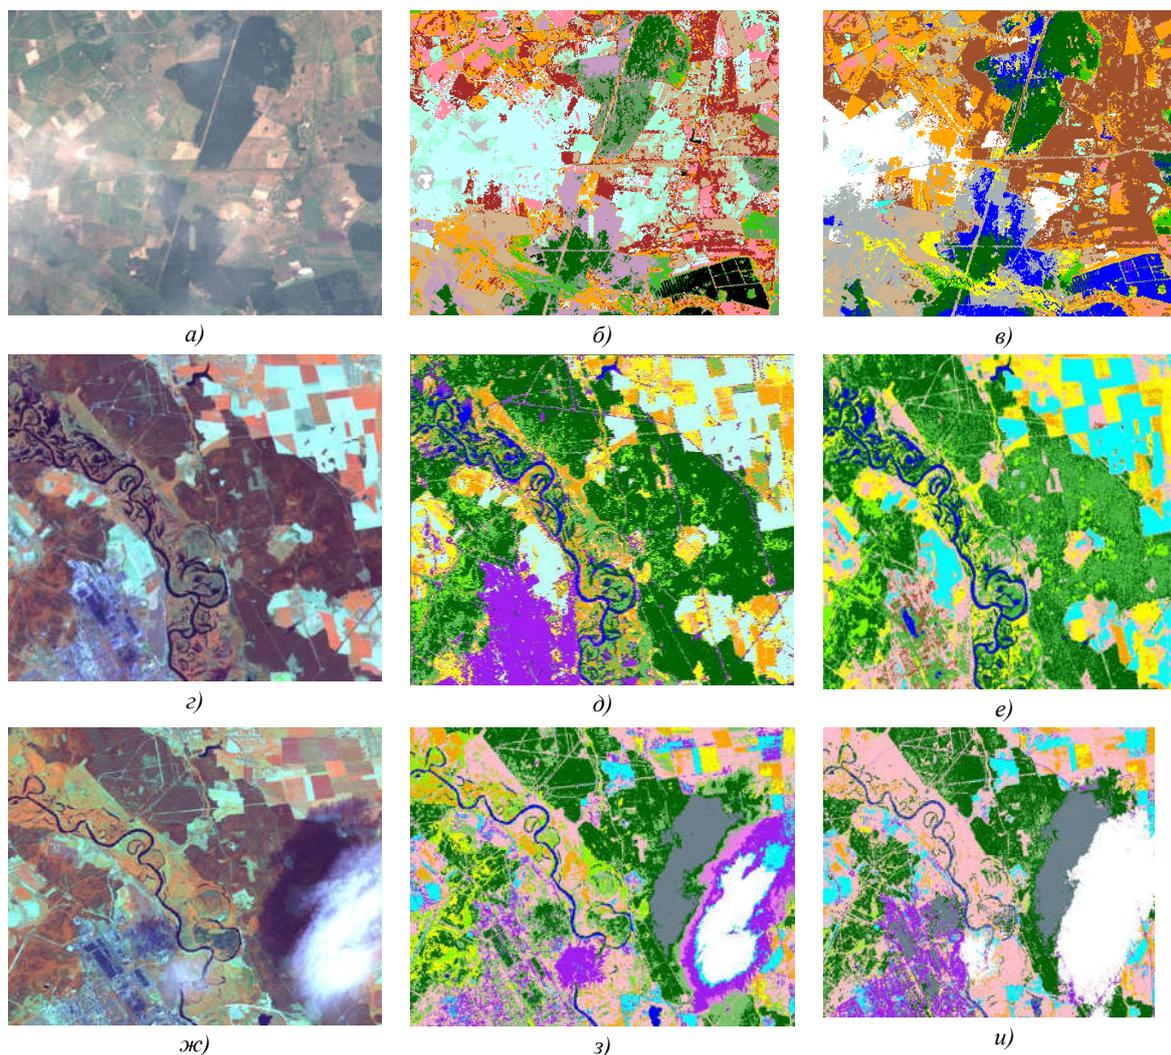


Рис. 4. Результаты классификации фрагмента снимка одной и той же территории различными методами:  
 а) исходное изображение 1999 г.; б) ISODATA; в) максимальное правдоподобие;  
 г) исходное изображение 1986 г.; д) расстояние Махаланобиса; е) максимальное правдоподобие;  
 ж) исходное изображение 2000 г.; з) минимальное расстояние; и) максимальное правдоподобие

В верхнем ряду (рис. 4, а–в) продемонстрирован фрагмент лесного массива на снимке Landsat 1999 г. На рис. 4, в видно, что крупные однородные области классифицируются более четко методом максимального правдоподобия. Дороги тоже были классифицированы корректно, хотя цель данного исследования не заключалась в классификации дорог ввиду невысокого пространственного разрешения.

Второй (рис. 4, *г–е*) и третий (рис. 4, *ж–и*) ряды показывают один и тот же участок местности, но за разные года (1986 и 2000 гг.). Классификация растительности на снимках второго и третьего рядов достаточно четко разделяет классы землепользования, несмотря на отличия между собой сезонных особенностей снимков (весна/лето). При этом также четко отражается динамика полноводности реки, естественной растительности и пастбищной нагрузки. Класс «населенные пункты» классифицировался как неоднородная область только расстоянием Махаланобиса, остальные методы показали плохой результат классификации. Тем не менее, во всех случаях методом максимального правдоподобия контуры и границы классов выделились более отчетливо. По результатам классификации снимков 1986 и 2000 гг. можно обнаружить объекты, в которых произошли изменения на местности, в частности, можно судить о полноводности реки и менее густонаселенном пункте на снимке 1986 г.

**Оценка результатов экспериментов.** Экспериментальная обработка изображений выполнялась в программной среде ERDAS IMAGINE 8.7 с помощью стандартных процедур классификации с обучением и без. Утилита точности оценки классификации позволила сравнить определенные пиксели тематического растрового слоя с эталонными пикселями, для которых класс был заранее известен (табл. 2).

Таблица 2

Значения оценки точности методов классификации многозонального изображения

Название класса	Метод максим. правдоподобия		Метод Махаланобиса		Метод миним. расстояния		Метод Isodata	
	Точн. классиф., %	Индекс Каппа	Точн. классиф., %	Индекс Каппа	Точн. классиф., %	Индекс Каппа	Точн. классиф., %	Индекс Каппа
Поля	100	1,000	100	1,000	100	1,0	66,67	0,66
Пашня	90	0,89	95,37	0,94	83,33	0,82	25	0,22
Посевы	83,33	0,82	85,25	0,84	100	1,0	53,33	0,51
Пастбища	100	1,0	97,17	0,96	100	1,0	25	0,21
Широколиств. лес	88,24	0,87	85,31	0,85	82,14	0,79	80	0,79
Деревья	68,75	0,66	68,29	0,65	88,89	0,88	80,95	0,79
Хвойный лес	100	1,0	100	1,0	100	1,0	85,71	0,85
Речной песок	100	1,0	90	0,89	44,44	0,42	57,14	0,55
Облака	51,72	0,48	83,1	0,83	100	1,0	100	1,0
Тени	100	1,0	75,16	0,75	0	0	0	0
Водоемы	100	1,0	100	1,0	100	1,0	100	1,0
Населенный пункт	63	0,58	59	0,54	75	0,75		
Дымка	100	1,0	92	0,89	44,44	0,42	33,33	0,32
Общая точность классификации	89,7		88,5		84,1		64,45	
Общая каппа-статистика	0,89		0,87		0,77		0,63	

Попиксельное сравнение этих результатов приводит к матрице ошибок. По матрице ошибок определяется ряд показателей ошибки и точности, каждый из которых характеризует результаты классификации. Матрица ошибок формируется следующим образом: элемент  $x_{kl}$  матрицы ошибок равен числу пикселей класса  $k$ , распознанных как класс  $l$ . Элемент матрицы  $x_{kk}$  равен числу пикселей класса  $k$ , распознанных как класс  $k$ . Число правильно классифицированных пикселей располагается на диагонали матрицы.

На основе матрицы ошибок при обобщении результатов правильно классифицированных точек был использован так называемый индекс каппа-статистики, вносящий поправку на случайность. Он вычисляется по формуле [4]

$$K = \frac{N \sum_{i=1}^m \sum_{j=1}^m x_{ij} - \sum_{i=1, j=1}^m S_i \cdot T_j}{N^2 - \sum_{i=1, j=1}^m S_i \cdot T_j}, \quad (1)$$

где  $N$  – общее число тестовых пикселей;

$m$  – число классов;

$S_i = \sum_{j=1}^m x_{ij}$  – сумма элементов  $i$ -й строки;

$T_j = \sum_{i=1}^m x_{ij}$  – сумма элементов  $j$ -го столбца.

Для абсолютно точных результатов индекс Каппа равен 1, а при наличии ошибок классификации принимает значения между 0 и 1.

Дополнительно точность классификации определялась путем сравнения ее результатов с данными, которые считаются верными (обычно это достоверные наземные данные) [12, 13]. В нашем случае результаты классификации сравнивались с цифровой картой местности за 2005 г., масштаб 1 : 200 000 (рис. 5).



Рис. 5. Сравнение результатов классификации с наземными данными:  
а) классификация фрагмента снимка за 1999 г.; б) фрагмент цифровой карты

Используемые в работе методы классификации выбранных представительских классов землепользования показали неоднозначные результаты. Так, класс «населенный пункт» плохо классифицировался при обработке в связи с тем, что крыши зданий малы по сравнению с пикселем спутникового изображения и имеют множество цветов и оттенков по отношению к солнечному свету. Классы «поля», «посевы» и «лес» одинаково хорошо классифицируются всеми методами, так как спектральные характеристики представляют однородный тип растительности и обеспечивают относительно несложный ландшафт. Из-за невысокого пространственного разрешения снимков и большой ширины спектральных диапазонов трудно отделить по спектральной яркости класс «посевы» от классов «пашня» и «речной песок». Классификация растительности позволила значительно детализировать контуры и площади посевных территорий, а в группе «лес» ввести дополнительный класс «деревья».

## Заключение

Существенное влияние на классификацию оказывают пространственное разрешение спутникового изображения и объединение при классификации (без обучения) близких тематических категорий. В частности, при выделении водных объектов методом классификации без обучения в класс «водоемы» могут попадать переувлажненные почвы, тени от облаков и т. п. В этом случае целесообразно проводить классификацию с обучением, используя в качестве тестовых те объекты, состояние которых точно известно. Это особенно важно в случае, когда требуется выделить зоны затопления малой площади, которые при классификации без обучения могут не выделяться.

Сравнительный анализ методов классификации многозональных спутниковых изображений показал, что метод максимального правдоподобия целесообразно использовать для изучения представительских классов территории Республики Беларусь. Метод ISODATA может быть применен в качестве первого приближения, чтобы облегчить оператору выбор классов при классификации с обучением.

### Список литературы

1. Caprioli, M. Urban features recognition from VHR satellite data with an object-oriented approach / M. Caprioli, E. Tarantino // Proc. of Commission IV Joint Workshop, Challenges in Geospatial Analysis, Integration and Visualization II. – Stuttgart, Germany, 2003.
2. Любимова, А.В. Применение данных дистанционного зондирования в геологии и природопользовании / А.В. Любимова [Электронный ресурс]. – М., 2001. – Режим доступа: <http://astra.geosys.ru/pageslab/articles/>
3. Дешифрирование космических снимков по структурным признакам при классификации ландшафтных зон / А.Д. Федоровский [и др.] // Доповіді Національної академії наук України. – 2001. – № 4. – С. 120–123.
4. ERDAS IMAGINE Tour Guides™. Leica Geosystems GIS & Mapping, LLC. – Atlanta, Georgia, 2003. – 670 p.
5. ERDAS Field Guide™. Seventh Edition, Revised and Expanded. Leica Geosystems GIS & Mapping, LLC. – Atlanta, Georgia, 2003. – 698 p.
6. Орешкина, Л.В. Обнаружение и распознавание класса объектов на многозональных изображениях дистанционного зондирования / Л.В. Орешкина // Информатика. – № 2. – 2005. – С. 79–85.
7. Мониторинг сельскохозяйственных земель на базе разномасштабных спутниковых данных / Н.В. Вандышева [и др.] // Исследование земли из космоса. – 2003. – № 3. – С. 72–84.
8. Орешкина, Л.В. Сравнение методов классификации многозональных спутниковых изображений / Л.В. Орешкина, А.В. Шидловский, В.Г. Коваленок // Материалы Второго Белорусского космического конгресса, 25–27 октября 2005 г., Минск, Беларусь. – Минск: ОИПИ НАН Беларуси, 2005. – С. 205–208.
9. Land Cover classification of Landsat-7 ETM+ data for forestry mapping / M.N. Ripa [et al.] // Proc. of XXX CIOSTA-CIGR V. – Torino, 2003.
10. Whiteside, T. A comparison of object-oriented and pixel-based classification methods for mapping land cover in northern Australia / T. Whiteside, W. Ahmad [Electronic resource]. – Mode of access: <http://www.definiens-imaging.com/documents>.
11. Remote Sensing Image Analysis including the Spatial Domain / R. Sluiter [et al.]. – New York: Kluwer Academic Publishers, 2005. – P. 271–280.
12. Morisette, J.T. Accuracy assessment curves for satellite-based change detection / J.T. Morisette, S. Khorram // Photogrammetric Engineering and Remote Sensing. – 2000. – № 66 (7). – P. 875–880.
13. Foody, G.M. Status of land cover classification accuracy assessment / G.M. Foody // Remote Sensing of Environment. – 2002. – № 80. – P. 185–201.

Поступила 31.05.06

*информатики НАН Беларуси,  
Минск, Сурганова, 6  
e-mail: ola@newman.bas-net.by*

**L.V. Areshkina**

**COMPARISON AND ACCURACY ASSESSMENT OF CLASSIFICATION  
METHODS ON MULTISPECTRAL SATELLITE IMAGES**

A general approach to classification of multispectral satellite images is considered. The comparison, accuracy assessment and analysis of classification methods (supervised and unsupervised) for multispectral satellite images on the territory of Belarus is made. The analysis was carried out by the software product «ERDAS IMAGINE 8.7» of Leica Geosystems.