

Министерство науки и высшего образования Российской Федерации
Федеральное государственное бюджетное образовательное учреждение
высшего образования
«Сибирский государственный университет геосистем и технологий»
(СГУГиТ)

А. П. Гук, Е. П. Хлебникова

МЕТОДЫ И ТЕХНОЛОГИИ РАСПОЗНАВАНИЯ ОБЪЕКТОВ ПО ИХ ИЗОБРАЖЕНИЮ

Утверждено редакционно-издательским советом университета в качестве
учебно-методического пособия для обучающихся по направлению подготовки
21.03.03 Геодезия и дистанционное зондирование (уровень бакалавриата)

Новосибирск
СГУГиТ
2019

УДК 528.7
Г939

Рецензенты: кандидат физико-математических наук, доцент, ведущий научный сотрудник, и. о. зав. лабораторией аэрокосмического мониторинга и обработки данных ИВТ СО РАН *И. А. Пестунов*
доктор технических наук, доцент СГУГиТ *А. В. Комиссаров*

Гук, А. П.

Г939 Методы и технологии распознавания объектов по их изображению [Текст] : учеб.-метод. пособие / А. П. Гук, Е. П. Хлебникова. – Новосибирск : СГУГиТ, 2019. – 138 с.
ISBN 978-5-907052-39-0

Учебно-методическое пособие подготовлено доктором технических наук, профессором А. П. Гуком и кандидатом технических наук, доцентом Е. П. Хлебниковой на кафедре фотограмметрии и дистанционного зондирования.

В учебно-методическом пособии изложены теоретические основы методов автоматизации дешифрирования, рассмотрены яркостные и структурные дешифровочные признаки, методы распознавания объектов по их изображениям на снимках, технологические схемы автоматизированного дешифрирования снимков. Для практического освоения курса приведено описание лабораторных работ, иллюстрирующих теоретические положения автоматизированного дешифрирования.

Учебно-методическое пособие по дисциплине «Методы и технологии распознавания объектов по их изображению» предназначено для обучающихся по направлению подготовки 21.03.03 Геодезия и дистанционное зондирование (уровень бакалавриата), а также может быть использовано для обучающихся по направлениям подготовки 21.03.02 Землеустройство и кадастры (уровень бакалавриата), 21.04.03 Геодезия и дистанционное зондирование (уровень магистратуры), 05.06.01 Науки о Земле (уровень подготовки кадров высшей квалификации).

Рекомендовано к изданию кафедрой фотограмметрии и дистанционного зондирования и Ученым советом Института геодезии и менеджмента СГУГиТ.

Печатается по решению редакционно-издательского совета СГУГиТ

УДК 528.7

ISBN 978-5-907052-39-0

© СГУГиТ, 2019

ОГЛАВЛЕНИЕ

Введение	4
1. Методы и технологии распознавания объектов по их изобра- жению	6
1.1. Дешифрирование снимков	6
1.2. Яркостные преобразования изображений.....	11
1.3. Автоматизация дешифрирования снимков.....	27
1.4. Методы распознавания, основанные на использовании структурных свойств изображений.....	45
1.5. Структура алгоритмов распознавания образов	51
1.6. Выявление изменений по разновременным снимкам.....	53
1.7. Области применения методов и технологий распознавания объектов по их изображению	57
2. Лабораторные работы.....	60
2.1. Лабораторная работа № 1. Получение базовых навыков рабо- ты в программе ERDAS Imagine 2010	61
2.2. Лабораторная работа № 2. Яркостные преобразования изобра- жений.....	73
2.3. Лабораторная работа № 3. Автономная классификация	86
2.4. Лабораторная работа № 4. Классификация с обучением	92
2.5. Лабораторная работа № 5. Преобразование Фурье.....	111
2.6. Лабораторная работа № 6. Использование геометрических параметров при распознавании объектов	117
2.7. Лабораторная работа № 7. Выявление изменений по разно- временным снимкам	129
Заключение	135

ВВЕДЕНИЕ

За последние несколько лет в развитии дистанционных методов произошли кардинальные изменения.

Появились космические съемочные системы высокого и сверхвысокого пространственного разрешения (0,2 м в панхроматическом и 1,2 м в основных многоспектральных каналах), также увеличилось количество каналов SWIR, повысилось разрешение тепловых каналов. Пример – космическая съемочная система WorldView 3. Повысилась точность геометрического построения изображений космическими и другими сканерными системами. Разработаны кадровые цифровые камеры большого формата (например, PhaseOne 1900). Стали широко применяться для аэросъемки беспилотные летательные аппараты, для которых разработаны специальные съемочные камеры, в том числе многоспектральные камеры и даже лазерные съемочные системы.

Таким образом, технические средства опережают методы анализа и обработки данных. Следовательно, основная задача в развитии методов дистанционного зондирования состоит в том, чтобы существенно повысить надежность и эффективность методов автоматического дешифрирования снимков.

Данное учебно-методическое пособие является введением в методы автоматизированного дешифрирования снимков, распознавания объектов по их изображениям на снимках. Рассматриваются вопросы, связанные с яркостной обработкой изображений: сглаживание, выделение границ, индексные преобразования. Большое внимание уделено преобразованиям, уменьшающим статистическую зависимость между многоспектральными измерениями: преобразованию главных компонент, преобразованию независимых компонент и преобразованию Tessaled Cap.

В учебно-методическом пособии рассматриваются методы частотного анализа изображения на основе преобразования Фурье и вейвлет-преобразования. Рассмотрены основные методы классификации изображе-

ний: кластерный анализ и статистический подход на основе Байесовского классификатора. Представлено описание лабораторных работ с использованием программного комплекса обработки изображений ERDAS Imaging. Приведены основные этапы алгоритмов распознавания образов.

1. МЕТОДЫ И ТЕХНОЛОГИИ РАСПОЗНАВАНИЯ ОБЪЕКТОВ ПО ИХ ИЗОБРАЖЕНИЮ

1.1. Дешифрирование снимков

Классификация методов дешифрирования снимков

Дешифрирование – процесс распознавания объектов или состояния объектов по их изображениям на снимках. Можно выделить следующие виды дешифрирования снимков:

- визуальное – выполняет оператор путем просмотра изображения;
- интерактивное – оператором выполняется дешифрирование изображений, обработанных компьютером;
- автоматизированное – используются различные алгоритмы обработки изображений, осуществляющие преобразование изображений и предварительную классификацию образов, а окончательный анализ выполняет оператор;
- автоматическое дешифрирование – распознавание объектов выполняется полностью автоматически, без участия оператора.

Визуальное дешифрирование выполняется путем анализа прямых и косвенных дешифровочных признаков. К *прямым признакам* относятся: тон, цвет, форма, размер, текстура. К *косвенным признакам* – тень, месторасположения объекта и другие факторы, указывающие на наличие объекта.

Основным «инструментом» визуального анализа снимков является мозг человека, его опыт и интуиция. Для визуального дешифрирования снимков необходимо научить дешифровщика определенным приемам. При принятии решения наряду с дешифровочными признаками используют знания сотрудника, выполняющего дешифрирование, с учетом динамики развития состояния распознаваемых объектов и других данных об исследуемой территории. Большинство решений принимается интуитивно, за счет опыта. Дешифрирование – это весьма сложный процесс, который трудно формализовать и, соответственно, описать систему принятия решений с по-

мощью математических моделей. Вероятно, поэтому визуальное дешифрирование до сих пор является основным методом анализа снимков.

Однако появление многоспектральных снимков привело к необходимости разработки интерактивных, автоматизированных и автоматических методов анализа изображений.

Действительно, визуально возможно анализировать максимум три канала изображения (цветное изображение), формируя из изображений, полученных в различных каналах, цветные и псевдоцветные либо композитные изображения.

Однако для формирования таких изображений одновременно используются только три канала (по количеству основных цветов). Можно выполнять анализ композитных изображений и получать дополнительную информацию по сравнению с дешифрированием черно-белых или цветных снимков. Однако анализировать одновременно все изображения, полученные многоспектральной системой, невозможно, хотя именно совместный анализ всех получаемых данных – основное преимущество многоспектральной съемки. Таким образом, традиционными методами дешифрирования невозможно извлечь всю информацию, получаемую при многоспектральной съемке.

Это основная причина перехода к автоматизированным методам дешифрирования. Кроме того, методы цифровой обработки изображений позволили расширить возможности визуального дешифрирования, и появился новый вид дешифрирования – интерактивное дешифрирование.

Интерактивное дешифрирование основано на преобразовании исходного изображения с целью улучшения визуального качества, получении псевдоцветных и композитных изображений и т. п. Полученные изображения затем анализируются визуально, причем в процессе дешифрирования оператор может преобразовывать их с использованием доступных программных средств.

Автоматизированное дешифрирование отличается от интерактивного использованием алгоритмов распознавания образов для предварительной классификации изображений. Окончательное решение принимает оператор.

Автоматическое дешифрирование выполняется с помощью алгоритмов распознавания образов, решение принимается на основе критериев, заложенных в алгоритме без вмешательства оператора.

Дешифровочные признаки. Пространство признаков

Дешифровочные признаки визуального дешифрирования являются основой для нормирования признаков автоматизированного дешифрирования, однако, с учетом широких возможностей численного анализа изображений, набор этих признаков может быть существенно расширен. Исходной информацией при автоматизированном или автоматическом дешифрировании является цифровое многоспектральное изображение $P(x, y) = \{P^1(x, y), P^2(x, y), \dots, P^k(x, y)\}$. Здесь $P^j(x, y)$ – изображение, полученное в j -м канале съемочной системы.

Вся информация будет содержаться в пикселе многоспектрального изображения, где $p^j(x, y)$ – яркость элемента с координатами x, y изображения j -го канала. Таким образом, многоспектральное изображение несет информацию о яркости элементов и их взаимном расположении.

Пространство признаков. В соответствии с вышесказанным можно выделить несколько групп дешифровочных признаков:

1) поэлементные признаки (т. е. признаки, относящиеся к каждому отдельному элементу изображения):

- спектральные яркости элементов многоспектрального изображения;
- преобразованные спектральные яркости – яркости изображения, полученные после процедуры нормирования, индексного преобразования, или преобразования по методу главных компонент (PC), по методу независимых компонент (IC), или преобразования по методу Tasseled Cap (TC);

2) площадные (структурные) признаки – признаки, относящиеся к группе взаимосвязанных элементов:

- текстурные признаки $F(S)$, где S – участок изображения размером $m \times n$ элементов, для которого вычислены факторы, характеризующие текстуру участка и определяемые видом функции $F(S)$;

- собственно структурные признаки $\Phi(S)$ – признаки, характеризующие снимок или участок снимка и определяемые коэффициентами разложения по ортогональным базисным функциям, например, коэффициентов Фурье-преобразования или коэффициентов разложения по кратномасштабным базисным функциям – системе коэффициентов вейвлет-преобразования;

- статистические характеристики участка S , например, функция плотности распределения вероятностей;
- контекстуальные признаки – признаки, характеризующие отношения между объектами, а также смысловые или функциональные свойства объекта.

Пространство признаков может быть расширено за счет введения новых признаков. Например, в качестве признаков можно использовать базисные векторы преобразования по методу главных компонент или методу независимых компонент (этот факт используется в методе Tasseled Cap), а также использовать собственные значения этих преобразований и т. д.

Спектральные яркости в качестве дешифровочных признаков существенно зависят от внешних условий, в которых формировалось изображение (атмосфера, положение Солнца, положение носителя). Из-за влияния этих факторов яркостные признаки не являются достаточными при дешифрировании снимков. Поэлементная обработка изображений в ряде случаев малоэффективна, так как при данной методике информация о структуре объекта (взаимосвязи между однородными элементами) не используется.

Площадные признаки отражают в первую очередь структуру участка изображения и естественно, что этот фактор менее чувствителен к изменению внешних факторов, в частности, к изменению освещенности поверхности. Например, изменения освещенности не влияют на Фурье-образ участка до тех пор, пока изменение освещенности изображения не изменяет его структуру вследствие утраты мелких деталей. То же относится и к другим структурным признакам. Сложность применения структурных признаков заключается в трудности математической оценки соответствия признаков для различных объектов. Описание текстурных признаков – это набор матриц коэффициентов для различных объектов, получить численную оценку соответствия достаточно сложно.

Весьма интересный результат дает использование в качестве признаков коэффициентов вейвлет-разложения. В этом случае получается несколько наборов коэффициентов для каждого уровня разложения, что детально характеризует структуру изображения объекта в различных масштабах и позволяет локализовать границы изменений структуры изображения.

Вейвлет-преобразование объединяет два подхода – пространственное спектральное разложение и кратномасштабный анализ. Соответственно, совместный анализ коэффициентов на различных уровнях может служить самостоятельным дешифровочным признаком, позволяющим выделять границы однородных участков.

Геометрические признаки – форма, размеры, объем, рельеф. Эти признаки сложно формализовать, однако они являются весьма значимыми, так как обладают существенной устойчивостью (например, рельеф местности или цифровая модель поверхности). Однако алгоритмы получения этих признаков также достаточно сложны.

Топологические признаки описывают степень связанности объектов.

Семантические признаки – это обычно описательная информация об объекте, которая хранится в различных специализированных ГИС.

В табл. 1 приведены основные дешифровочные признаки, используемые при автоматизированном дешифрировании.

Таблица 1

Дешифровочные признаки для автоматического распознавания объектов по их изображениям на многоспектральных снимках

Спектральные признаки	Структурные признаки	Признаки описания (рельеф местности геометрия объектов и т. д.)
1. Вектор спектральных признаков: $\overline{P}_{ij}^k = \{P_{ij}^I, P_{ij}^{II} \dots P_{ij}^k\}, \quad P_{ij}^k$ – яркость элемента ij в канале k; k – количество каналов в съемочной системе	1. Коэффициенты разложения изображения k канала по ортогональным базисным функциям. Фурье-образ – разложение по гармоническому базису: $F(xy) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} e^{i2\pi(x+y)} dx$	1. Цифровая модель рельефа местности. Цифровая модель рельефа поверхности (объекта)
2. Преобразованные спектральные признаки – изображения, полученные после преобразований PCA, ICA, TC	2. Коэффициенты разложения изображения по базисным векторам Грамма Шмидта: $F_G = U^T P$	2. Геометрические признаки. Форма, размеры, объем, площадь, конфигурация
3. Индексные изображения NDVI, NDWI и т. д.	3. Вейвлет-разложение по базисным функциям Хаара, Дебоши и др.	3. Топологические признаки
4. Спектральные характеристики объектов местности	–	4. Семантические признаки

1.2. Яркостные преобразования изображений

Преобразования изображений является важной частью как интерактивного, так и автоматизированного дешифрирования. В первом случае применяются преобразования, которые улучшают визуальное восприятие изображения. Такие преобразования выполняются с использованием операторов сглаживания, выделения границ, контрастирования, изменения гистограммы яркости и т. п., путем пространственной или частотной фильтрации и других алгоритмов. Во втором случае – это предварительная обработка алгоритмов перед применением алгоритмов распознавания.

Методы улучшения изображений

Главная цель улучшения заключается в такой обработке изображений, чтобы результат оказался более подходящим для визуального анализа с точки зрения конкретного применения.

Так, например, метод, являющийся весьма полезным для улучшения рентгеновских снимков, необязательно окажется наилучшим для обработки спутниковых снимков земной поверхности.

Общей теории улучшения изображений не существует, так как результат обработки изображений оценивает дешифровщик с собственных позиций о качестве изображения. Очевидно, что такая оценка является субъективной.

Применяются поэлементное преобразование изображения и последовательное преобразование с учетом окрестности точки.

Окрестностью точки (x, y) цифрового изображения называется квадратная или прямоугольной область (подмножество изображения), размером $n \times n$ или $n \times m$, центрированная в точке (x, y) .

К поточечным преобразованиям относятся: операторы видоизменения гистограмм, изменение функции тонопередачи, контрастирование, инвертирование и т. п. В этом случае каждому элементу изображения присваивается новое значение в соответствии с некоторой заданной функцией

$$g(x, y) = F_t[x, y, f(x, y)], \quad (1)$$

где $f(x, y)$ – яркость элемента x, y исходного изображения;

$g(x, y)$ – яркость элемента x, y преобразованного изображения.

Преобразование окрестности точки выполняется линейным оператором типа свертки (пространственная фильтрация). Фильтрация изображения f размером $M \times N$ с помощью фильтра размером $m \times n$ выполняется операцией дискретной свертки вида

$$g(x, y) = \sum_{i=1}^n \sum_{j=1}^m w(i, j) f(x + i, y + j), \quad (2)$$

где $w(i, j)$ – коэффициент.

При фильтрации всего изображения данная формула должна быть вычислена для всех сочетаний $x = 0, 1, 2, \dots, M-1$ и $y = 0, 1, 2, \dots, N-1$. Фильтр – матрица размером $n \times m$, называемая маской.

Как правило, маска представляет собой небольшой ($3 \times 3, 5 \times 5$ элементов) двумерный массив (матрицу), значения элементов которого определяют сущность процесса (подавление шумов, повышение контрастности, подчеркивание границ и т. п.). Значения элементов этой матрицы называются коэффициентами пространственной фильтрации и задаются в соответствии с типом преобразования.

Процесс пространственной фильтрации основан на простом перемещении маски фильтра от точки к точке; в каждой точке отклик фильтра вычисляется с использованием предварительно заданных связей.

Наиболее часто используются следующие виды преобразований:

- 1) сглаживающие пространственные фильтры – низкочастотная фильтрация;
- 2) дифференцирующие пространственные фильтры – подчеркивание контуров;
- 3) смешанные операторы, объединяющие сглаживающие и дифференцирующие операторы;
- 4) медианные и другие типы нелинейной фильтрации.

Отклик простейшего линейного сглаживающего пространственного фильтра есть среднее значение элементов по окрестности, покрытой маской фильтра. Такие фильтры называют усредняющими, сглаживающими или низкочастотными. Идея применения низкочастотных фильтров заключается в том, что с помощью замены исходных значений элементов

изображения на средние значения по маске фильтра достигается уменьшение резких переходов уровней яркости. Такие фильтры используют для подавления случайных шумов. Главное использование сглаживающих фильтров состоит в подавлении несущественных деталей на изображении, под которыми понимаются совокупности пикселей, которые малы по сравнению с размерами маски фильтра. Для маски размером 3×3 функция вида (1) вычисляется следующим образом:

$$g(x, y) = \frac{1}{9}(w_1 z_1 + w_1 z_1 + w_1 z_1 + w_1 z_1 + w_2 z_2 + w_3 z_3 + w_4 z_4 + w_6 z_6 + w_7 z_7 + w_8 z_8 + w_9 z_9), \quad (3)$$

где z_i – элементы матрицы изображения в окрестности точки (x, y) .

На рис. 1 показано расположение коэффициентов в маске. Аналогичное расположение элементов изображения и в окрестности точки (x, y) .

w_1	w_2	w_3
w_4	w_5	w_6
w_7	w_8	w_9

Рис. 1. Расположение коэффициентов в маске

Примеры масок:

$$\frac{1}{9} \times \begin{vmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{vmatrix} - \text{обычное среднее значение по маске. Это однородный}$$

усредняющий фильтр;

$$\frac{1}{16} \times \begin{vmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{vmatrix} - \text{средневзвешенное значение.}$$

При медианной фильтрации значению пикселя присваивается значение медианы яркостей элементов окрестности, включая центральный элемент элементов. Оператор T_M создает последовательность из значений яркости элементов окрестности, и элементам с координатами (x, y) присваивается медианное значение последовательности. Такой подход к сглаживанию позволяет исключить большие отклонения в точках окрестности (устранить случайные выбросы).

Общим недостатком сглаживающих фильтров является эффект размывания границ. Поэтому сглаживающие фильтры применяются совместно с операторами выделения границ (высокочастотными фильтрами).

Подчеркивание контуров. Высокочастотная фильтрация. Высокочастотные фильтры повышают резкость изображения. Высокочастотная фильтрация основана на использовании численного дифференцирования. Операторы подчеркивания контуров называются также дифференцирующими операторами.

Лапласиан.

Оператор Лапласа определяется как

$$\text{grad}^2 f = \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2}. \quad (4)$$

В дискретном виде производные вычисляются:

– 1-я производная:

$$\frac{\partial f}{\partial x} = f(x+1) - f(x); \quad (5)$$

– 2-я производная:

$$\frac{\partial^2 f}{\partial x^2} = f(x+1) + f(x-1) - 2f(x). \quad (6)$$

Поскольку изображение – функция двух переменных, то вторые частные производные будут иметь вид:

$$\begin{aligned}\frac{\partial^2 f}{\partial x^2} &= f(x+1, y) + f(x-1, y) - 2f(x, y); \\ \frac{\partial^2 f}{\partial y^2} &= f(x, y+1) + f(x, y-1) - 2f(x, y).\end{aligned}\tag{7}$$

Тогда полная вторая производная:

$$\text{grad}^2 f = [f(x+1, y) + f(x-1, y) + f(x, y+1) + f(x, y-1)] - 4f(x, y).\tag{8}$$

Примеры:

$$\begin{vmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{vmatrix}; \quad \begin{vmatrix} 1 & 1 & 1 \\ 1 & -8 & 1 \\ 1 & 1 & 1 \end{vmatrix}; \quad \begin{vmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{vmatrix}; \quad \begin{vmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{vmatrix}.$$

Обобщенный алгоритм использования лапласиана сводится к следующему:

$$g(x, y) = \begin{cases} f(x, y) - \text{grad}^2 f(x, y), & \text{если } w(0, 0) < 0 \\ f(x, y) + \text{grad}^2 f(x, y), & \text{если } w(0, 0) > 0 \end{cases}.\tag{9}$$

Фильтр Робертса и фильтр Собела. В этих фильтрах используются первые производные. Для функции $f(x, y)$ градиент в точке (x, y) определяется как двумерный вектор-столбец:

$$\text{grad } f = \begin{bmatrix} G_x \\ G_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix}.\tag{10}$$

Модуль этого вектора определяется как:

$$|\text{grad } f| = \sqrt{[G]_x^2 + [G]_y^2} = \sqrt{\left(\frac{\partial f}{\partial x}\right)^2 + \left(\frac{\partial f}{\partial y}\right)^2}.\tag{11}$$

На практике, как правило, используют приближённую формулу:

$$\text{grad } f \approx |G_x| + |G_y|. \quad (12)$$

На рис. 2 показано расположение коэффициентов в маске.

0	-1	0
-1	A + 4	-1
0	-1	0

-1	-1	-1
-1	A + 8	-1
-1	-1	-1

Рис. 2. Расположение коэффициентов в маске

Аналогично лапласиану первоначально будут определены дискретные приближения приведенных выше уравнений, а затем по ним будут сформированы соответствующие маски фильтров.

Для маски размером 3×3 фильтр Робертса будет иметь вид:

$$\begin{aligned} \text{grad } f \approx & |(z_7 + 2z_8 + z_9) - (z_1 + 2z_2 + z_3)| + \\ & + |(z_3 + 2z_6 + z_9) - (z_1 + 2z_4 + z_7)|. \end{aligned} \quad (13)$$

Очевидно, что по этой формуле вычисляется значение для точки z_5 .

Фильтр Собела используется, чтобы достичь большей гладкости изображения за счет того, что центральным точкам строк и столбцом присвоены большие весовые коэффициенты:

$$\begin{vmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{vmatrix}; \quad \begin{vmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{vmatrix}. \quad (14)$$

Эти маски используют в алгоритмах фильтрации (2).

Частотные методы яркостных преобразований изображений.

Рассмотренные выше яркостные преобразования изображений можно выполнить в частотной области используя известную теорему о свертке.

Если $F(u, v)$ и $H(u, v)$ обозначают соответственно Фурье-образы функций $f(x, y)$ и $h(x, y)$, то теорема о свертке утверждает, что функции $f(x, y) \cdot h(x, y)$ и $F(u, v)H(u, v)$ образуют Фурье-пару:

$$f(x, y) \cdot h(x, y) \Leftrightarrow F(u, v)H(u, v). \quad (15)$$

Это означает, что выражение слева (пространственная свертка) может быть получено применением обратного преобразования Фурье к выражению справа (произведению $F(u, v)$ и $H(u, v)$ в частотной области), и, соответственно, выражение справа может быть получено применением прямого преобразования Фурье к выражению слева. Сходный результат заключается в том, что свертка в частотной области приводит к умножению в пространственной области, и наоборот, т. е.

$$f(x, y)h(x, y) \Leftrightarrow F(u, v) \cdot H(u, v). \quad (16)$$

При интерактивном дешифрировании преобразования изображения выполняются с целью улучшения работы алгоритмов распознавания или для непосредственного облегчения анализа изображений оператором. К таким преобразованиям относятся индексные преобразования, ортогональные преобразования (метод главных компонент, метод Tasseled Cap, метод главных компонент), а также разномасштабный анализ ортогональных изображений (типа вейвлет-анализа). Рассмотрим основные виды яркостных преобразований изображений.

Индексные изображения

Для выделения объектов определенных классов (растительности, водных объектов, почвы и т. д.) по многозональным изображениям формируют индексные изображения.

Получение индексных изображений основано на выборе каналов, для которых изображения заданного объекта имеют максимальные различия яркостей. По такому принципу построены индексы $NDVI$, $NDWI$, $SAVI$ и др.

Приведем наиболее широко используемые индексные изображения.

Вегетационные индексы. Для активно развивающегося растения характерна значительная разница в отражении света в красной и в ближней инфракрасной областях. При ослабленной вегетации эта разница сокращается. Соответственно, индексы, которые рассчитывают эту разницу, отражают общую активность вегетации. Также предполагается, что открытая почва на снимке будет формировать в спектральном пространстве прямую линию, так называемую почвенную линию.

Вегетационные индексы (ВИ) используют соотношение красного и ближнего инфракрасного каналов, с учетом того, что в ближней инфракрасной области лежит линия открытой почвы, на которой отсутствует растительность.

Для изображений территории с разреженным растительным покровом вегетационные индексы работают весьма плохо. Если растительный покров скудный, то спектр снимка в основном зависит от почвы. Различные виды почв могут значительно отличаться по отражательной способности, что сильно влияет на индексы.

Самый известный индекс растительности – нормализованный относительный индекс растительности (*Normalized Difference Vegetation Index*) – *NDVI*. Индекс использует наиболее стабильные (не зависящих от прочих факторов) участки спектральной кривой отражения растений. В красной области спектра (0,6–0,7 мкм) лежит максимум поглощения солнечной радиации хлорофиллом растений, а в инфракрасной области (0,7–1,0 мкм) находится область максимального отражения клеточных структур листа. Это значит, что высокая фотосинтетическая активность (связанная, как правило, с густой растительностью) ведет к меньшему отражению в красной области спектра и большему в инфракрасной. Отношение этих показателей позволяет анализировать растительность и отделять ее от прочих природных объектов.

NDVI вычисляется следующим образом:

$$NDVI = \frac{NIR - RED}{NIR + RED}, \quad (17)$$

где *NIR* – яркость элемента многоспектрального изображения в ближнем ИК-канале;

RED – яркость элемента в красном канале.

В результате получаются изображения $P_{NDWI}(x, y)$, элементы которого $p(x, y)$ – значения коэффициентов $NDVI$, вычисляемые по значениям элементов $p_{Red}(x, y)$ и $p_{NIR}(x, y)$ в красном и ИК-каналах соответственно.

Так как значения $NDVI$ для изображения растительности значительно больше, чем для других объектов, то растительность будет выделяться на индексном изображении $NDVI$.

$NDVI$ прост для вычисления, имеет самый широкий динамический диапазон из распространенных ВИ и лучшую чувствительность к изменениям в растительном покрове. Он умеренно чувствителен к изменениям почвенного и атмосферного фона, кроме случаев с бедной растительностью. Значения $NDVI$ изменяются от -1 до 1 .

Различным значениям коэффициентов $NDVI$ можно приписать различные цвета с изменяющейся интенсивностью. В результате индексное изображение будет отображаться в виде псевдоцветного изображения.

Определенный цвет будет соответствовать объекту определенного класса растительности, а интенсивность будет отражать свойства объектов.

Кроме $NDVI$ имеется достаточно большое количество вегетационных индексов, которые могут быть более эффективны для определенных типов растительности в различных природных зонах.

Например, разностный вегетационный индекс (DVI) имеет вид

$$DVI = NIR - RED. \quad (18)$$

Почвенный вегетационный индекс ($SAVI$) вычисляется по формуле

$$SAVI = \frac{NIR - REN}{NIR + REN + L}(1 + L), \quad (19)$$

где $L = [0; 1]$ и зависит от степени «густоты листового покрова».

Водный индекс ($NDWI$) основан на использовании яркостей изображений в среднем (MIR) и коротковолновом ($SWIR$) инфракрасном, а также в зеленом ($GREEN$) каналах съемочной системы. Существует пять разновидностей данного индекса, определяемых по формулам

$$\begin{aligned}
NDWI_1 &= \frac{SWIR - MIR}{SWIR + MIR}; & NDWI_2 &= \frac{NIR - GREEN}{NIR + GREEN}; \\
NDWI_3 &= \frac{MIR - NIR}{MIR + NIR}; \\
NDWI_4 &= \frac{MIR - GREEN}{MIR + GREEN}; & NDWI_5 &= \frac{SWIR - GREEN}{SWIR + GREEN}.
\end{aligned} \tag{20}$$

Индексы, устойчивые к влиянию атмосферы. Атмосфера может изменяться очень сильно на протяжении одной сцены, особенно на территории с высоким рельефом. Индексы позволяют уменьшить чувствительность к влиянию атмосферы ценой уменьшения динамического диапазона. В целом, они менее чувствительны к изменению растительного покрова, чем *NDVI*. Если растительность невысока, эти индексы подвержены сильному влиянию почвенного слоя.

ВИ, устойчивый к влиянию атмосферы (*Atmospherically Resistant VI*), вычисляется по формуле

$$ARVI = \frac{NIR - Rb}{NIR + Rb}, \tag{21}$$

где $Rb = RED - a(RED - BLUE)$.

Как правило, $a = 1$, при малом покрытии растительности и неизвестном типе атмосферы $a = 0,5$.

Устойчивость к атмосферному и почвенному шуму резко падает, если растительный покров низкий.

Почвенный ВИ, устойчивый к влиянию атмосферы (Soil Adjusted and Atmospherically Resistant VI) SARVI вычисляется по формуле

$$SARVI = \frac{NIR - Rb}{NIR + Rb} (1 + L). \tag{22}$$

Существуют индексные изображения, позволяющие учитывать влияние ряда внешних факторов, например, усовершенствованный вегетационный индекс (*Enhanced Vegetation Index*) *EVI*:

$$EVI = \left(\frac{NIR - RED}{NIR + C_1 \cdot RED - C_2 \cdot BLUE + L} \right) (1 + L), \tag{23}$$

где L – поправочный коэффициент, учитывающий влияние почвы,

$C_1 = 6$ и $C_2 = 7,5$ – коэффициенты контролируют вклад голубой зоны в атмосферное аэрозольное рассеяние (эти коэффициенты найдены эмпирически). Индекс EVI может принимать значения от -1 до 1 .

Индекс глобального мониторинга окружающей среды (*Global Environmental Monitoring Index*,) $GEMI$ вычисляется по формуле

$$GEMI = E \cdot (1 - 0,25 \cdot E) - \frac{RED - 0,125}{1 - RED}, \quad (24)$$

где

$$E = \frac{2(NIR^2 - RED^2 + 1,5 \cdot NIR + 0,5 \cdot RED)}{NIR + RED + 0,5}. \quad (25)$$

Чтобы не проводить детальную атмосферную коррекцию, в этом индексе сконструирована общая поправка E за влияние атмосферы.

Кроме вышеописанных, существует много других индексов:

- перпендикулярный вегетационный индекс (*Perpendicular Vegetation Index*) PVI ;
- взвешенный разностный вегетационный индекс (*Weighted Difference Vegetation Index*) $WDVI$;
- трансформированный вегетационный индекс (*Transformed Vegetation Index*,) TVI ;
- модифицированный почвенный вегетационный индекс (*Modified Soil Adjusted Vegetation Index*) $MSAVI$;
- трансформированный почвенный вегетационный индекс (*Transformed Soil Adjusted Vegetation Index*) $TSAVI$;
- вегетационный индекс зелености (*Green Vegetation Index*,) GVI ;
- водный индекс (*Water Band Index*) WBI ;
- индекс стресса влажности (*Moisture Stress Index*) MSI и т. д.

Индексные изображения достаточно эффективно используются при дешифрировании широкого класса объектов.

Метод главных компонент

Преобразование изображения по методу главных компонент основано на формировании из исходного многоспектрального изображения новых преобразованных изображений, не коррелированных между собой.

Для анализа квадратных матриц в линейной алгебре путем ортогональных преобразований определяют «естественный» ортогональный базис этой матрицы. Для этого находят базисные векторы и собственные значения матрицы путем решения характеристических уравнений вида.

Применения метода для цифровой обработки сигналов (обработки цифровых изображений) называется преобразованием Карунена – Лоэва. В этом случае исходные спектральные яркости элементов изображения $\bar{P}_{ij} = (p_{ij}^I, p_{ij}^{II} \dots p_{ij}^k)$ преобразуются в новый вектор, $\bar{P}_{ij}'$ элементы которого являются статистически независимыми в смысле корреляционной зависимости. Для этого путем разложения матрицы R с использованием преобразования Карунена – Лоэва находятся собственные векторы $\bar{U}_i$ и собственные значения λ_i этой матрицы.

Матрица R размерностью $k \times k$ вычисляется как ковариационная матрица векторов измерений $\bar{P}_{i,j}$:

$$R_{i,j} = P_{i,j} P_{i,j}^T. \quad (26)$$

Если найти собственные векторы и составить матрицы преобразований U из собственных векторов $U = \{\bar{U}_1, \bar{U}_2, \dots, \bar{U}_k\}$, то преобразованные векторы $\bar{P}_{ij}'$ будут иметь не коррелированные компоненты

$$\bar{P}_{ij}' = U^T \bar{P}_{ij}. \quad (27)$$

Тогда новая корреляционная матрица будет иметь вид

$$R'_{i,j} = P'_{i,j} P'^T_{i,j} = \begin{pmatrix} \lambda_1 & 0 & 0 \\ 0 & \lambda_2 & \dots & 0 \\ 0 & 0 & \lambda_n \end{pmatrix}. \quad (28)$$

В соответствии с теорией нужно для каждого вектора $\bar{P}_{ij}$ вычислить собственную матрицу преобразования, и тогда каждый элемент преобразованной матрицы будет иметь некоррелированные элементы. Однако на практике можно определить только некоторые средние значения и вычислить среднюю ковариационную матрицу для всех элементов матрицы изображения P :

$$R_{cp} = \frac{1}{NN} \sum_{i=1}^N \sum_{j=1}^N \bar{P}_{ij} \bar{P}_{ij}^T. \quad (29)$$

Тогда базисные векторы и собственные значения будут являться некоторыми усредненными значениями, и после выполнения преобразования не будет достигнута полная независимость элементов преобразованных векторов. Этот эффект иллюстрирует рис. 3.




Рис. 3. Новый базис $\bar{u}_1, \bar{u}_2$ для уменьшения корреляции между измерениями

Значения элементов преобразованного вектора будут являться проекцией вектора измерений $\bar{P}_{ij}$ на соответствующей оси нового базиса.

На рис. 3 показаны исходный и преобразованный базисы для двух канального многоспектрального изображения и распределение измерений в новом и старом базисах каналов. Измерения, показаны в виде массива точек. Из рисунка видно, что измерения «вытянуты» вдоль новой оси системы координат. Преобразованное изображение P' имеет почти некорре-

лированные значения яркостей в каждой компоненте преобразованного изображения.

Первые три компоненты несут основную информацию многоспектрального изображения и называются главными компонентами. Последние – незначительные изменения и шумы.

При преобразовании метода главных компонент происходит «растяжение» яркостей изображений различных классов в новом пространстве признаков. Преобразованным изображениям присваивают соответственно основные цвета: красный (R), зеленый (G), синий (B).

На рис. 4 показаны распределения измерений различных классов объектов в пространстве спектральных каналов и в пространстве признаков для двух спектральных каналов. Преобразование по методу главных компонент позволяет «растянуть» распределение яркостей и улучшить их разделимость.




Рис. 4. Графики распределения яркостей в пространстве спектральных яркостей после преобразования главных компонент:

а) исходный снимок; б) преобразованное изображение

Базисные векторы можно связать с определенными свойствами объекта, т. е. использовать значения элементов базисного собственного вектора как дополнительный дешифровочный признак, характеризующий со-

стояние объекта. На этом предположении основан метод преобразования исходных изображений – Tasseled Cap.

Преобразование Tasseled Cap

Преобразование Tasseled Cap (TC) выполняется при помощи матриц преобразований, уникальных для каждого типа сенсора. Изначально коэффициенты Tasseled Cap были рассчитаны для сенсора Landsat MSS, но сейчас они известны и для изображений, полученных другими сенсорами (Landsat TM, SPOT, MODIS, FORMOSAT-2, QuickBird и др.).

В этом методе векторы $\bar{U}_1, \bar{U}_2 \dots \bar{U}_K$ вычисляются как средние значения, базисных векторов, полученных в результате обработки большого количества снимков однотипной поверхности, зарегистрированных съемочной системой определенного типа. Базисные векторы получают путем преобразования Каруэна – Лоэва корреляционной матрицы R .

Tasseled Cap – преобразование исходного многоспектрального изображения методом главных компонент в изображение, базис которого определяется съемочной системой и набором типовых объектов. Коэффициенты преобразования зависят в первую очередь от типа датчика (съемочной системы), а также (существенно) и от набора объектов, формирующих сцену. Практически коэффициенты *Tasseled Cap* следует использовать только для определенного набора объектов.

В соответствии с этим определять коэффициенты *Tasseled Cap* целесообразнее по типовым участкам, включающим характерный набор объектов для исследуемой местности.

На рис. 5, 6 показаны графики распределения яркостей элементов изображения различных объектов в двух- и трехмерном представлении.

Из рис. 5, 6 видно, что яркости элементов различных классов лежат в достаточно узком диапазоне яркостей в пространстве спектральных признаков исходного изображения, и области распределения классов перекрываются. Преобразованные яркости после применения *Tasseled Cap* «растянуты» по пространству признаков и практически не перекрываются. Это показывает лучшую разделимость и, соответственно, дешифрируемость классов после преобразования *Tasseled Cap*.




Рис. 5. Графики распределения яркостей элементов изображения различных объектов в двухмерном представлении:

а) в пространстве спектральных яркостей; б) в пространстве *Tasseled Cap*




Рис. 6. Графики распределения яркостей элементов изображения различных объектов в трехмерном представлении:

а) в пространстве спектральных яркостей; б) в пространстве *Tasseled Cap*

По изображениям *Tasseled Cap* можно сформировать псевдоцветное изображение, окрасив каждую из компонент изображения в определенный цвет. В полученном псевдоцветном изображении каждому типу объектов соответствует определенный цвет. Зная, какой цвет соответствует определенному объекту, можно, не используя другие алгоритмы классификации,

произвести визуальное оперативное дешифрирование территории по космическим снимкам.

1.3. Автоматизация дешифрирования снимков

Сегментация изображений

Сегментация – выделение на изображении однородных в смысле заданного критерия областей, элементы которых связаны между собой в соответствии с критерием «близости». Сегмент обладает двумя свойствами: однородностью и связностью.

Ряд авторов считает кластеризацию одним из вариантов сегментации, хотя на самом деле это не так. Элементы кластера могут быть пространственно не связаны, что не соответствует условию сегментации. Сегмент изображения имеет более жесткие требования к формированию области, чем, например, различные методы классификации: кластерный анализ или байесовский классификатор, использующие яркостные признаки для выделения объектов, принадлежащих одному классу.

Сегментация и классификация снимков близки по используемым математическим моделям, однако это две принципиально разные задачи.

Сегментация заключается в выделении однородной связанной области по какому-либо признаку (группе признаков), а классификация (распознавание) – в отнесении объекта к заданному классу в соответствии с заданными признаками. В то же время сегментация является неотъемлемой частью процесса классификации – дешифрирования объектов по снимкам.

Сегментация – один из самых сложных процессов обработки изображений. Не смотря на то, что методы развиваются с середины 1970-х гг. и до настоящего времени, нет единого оптимального алгоритма сегментации и единого подхода к процессу сегментации.

Практически для объектов различных классов выбирается метод сегментации в соответствии с результатами детального изучения свойства изображений заданного класса объектов.

Альтернативный подход – использование комплексного иерархического алгоритма сегментации, настраиваемого на исследуемый класс объектов.

Обычно методы сегментации разделяют на две группы:

- методы, основанные на выделении границ;
- методы, основанные на выделении областей.

Однако целесообразно классифицировать методы сегментации по другому принципу – по способу *анализа изображения*.

В соответствии с этим признаком можно обозначить следующие методы выделения сегмента:

– *поэлементный анализ* – метод, основанный на использовании яркостей отдельных элементов изображений (метод выделения границ, метод водоразделов, метод наращивания областей);

– *площадной анализ* – метод, основанный на анализе свойств связанной группы элементов (это все методы, которые устанавливают однородность сегмента на основе анализа различных признаков изображений в пределах некоторой области изображения);

– *комплексный анализ* – метод, основанный на использовании как яркостного, так и площадного анализа изображения.

Первая группа к выделению сегментов использует свойства только отдельных яркостей элементов и не учитывает окрестность элемента, однако связность как характеристика структуры области принимается во внимание. К данной группе относятся: метод выделения границ и формирования контуров, метод наращивания областей, метод водоразделов и другие аналогичные методы.

Вторая группа включает в себя большую часть методов сегментации.

В первую очередь это алгоритмы, основанные на описании текстуры. Также сюда можно отнести алгоритмы, использующие разложение по ортогональным функциям – (Фурье- и вейвлет-анализ и т. п.), статистические алгоритмы, основанные на вероятностном описании фрагментов изображений.

К этой группе можно отнести и объектно-ориентированный подход, который заключается в том, что выделяется объект (эталон), имеющий определенную форму, размеры. Объект характеризуется совокупностью признаков, относящихся только к нему. Сегментация осуществляется на выборе участков, соответствующих всей совокупности признаков объекта–эталоны.

К третьей группе относятся алгоритмы, использующие комплексные подходы, например, совместное использование алгоритмов кратномасштабного анализа и выделения границ, формирование пирамид изображений и структурирование с использованием дерева решения.

Рассмотрим принципы работы некоторых алгоритмов.

Алгоритмы, основанные *на поэлементном анализе*. Это *стандартные алгоритмы* выделения границ, основанные на применении масочных операторов выделения линий, имеющих определенное направление, или выделения перепадов яркостей с использованием градиентных операторов (Собеля, Превита, Робертса, а также комплексных операторов типа Лапласиана – Гауссиана и т. п.).

Эти операторы выполняют последовательную свертку маски $G(x, y)$ с изображением $P(x, y)$

$$P(x, y)' = P(x, y) \cdot G(x, y). \quad (30)$$

Отличием методов алгоритмов сегментации, выполняемой таким образом, является необходимость применения операторов «замыкания границ».

Метод водоразделов основан на анализе яркостей путем представления их значений в виде «высот» условной модели, плоские координаты которой соответствуют координатам пикселя изображения. В этом случае граница определяется как линия заданной высоты (горизонтالي) в соответствующем пространстве модели. Точки горизонтали вычисляются в соответствии с условием пересечения плоскости и поверхности, отражающей значения яркостей точек изображений. Задавая определенное сечение «горизонталей», получают поверхности, лежащие в заданных границах изменения яркостей. Метод достаточно эффективен, так как почти всегда формирует замкнутые линии.

Метод (объект – фон). Сущность метода заключается в том, что вычисляется гистограмма фона, и все остальные объекты выделяются, путем сравнения гистограммы объекта и гистограммы фона.

Методы, основанные на анализе областей. Для анализа областей часто используется текстура изображения. К методам, основанным на выделении областей, относятся:

- текстурный анализ, кратномасштабный анализ, объектно-ориентированные методы, площадные статистические методы, нейронные сети;
- модели, основанные на марковских случайных процессах;
- фрактальные модели, кратномасштабные многоуровневные модели;
- модели, использующие вейвлет-преобразования, модели, использующие контекстуальные и геометрические признаки (форма, размеры).

Несомненно, текстура – один из наиболее важных признаков, используемых при сегментации. Описание текстуры выполняется различными методами. Широко применяется вероятностный подход. Так, например, используются статистические характеристики, вычисляемые по определенной области. Определяются такие статистические величины, как среднее, стандарт, скос, кurtosis, которые в общем случае характеризуют основные характеристики нормального распределения μ и σ , а также отклонение реальной функции распределения вероятностей яркости фрагмента изображения относительно нормальной кривой с заданным средним μ и стандартом σ . Формулы для вычисления статистических характеристик можно найти в любом учебнике по статистике, например, А. К. Митропольский «Техника статистических вычислений» [4].

Затем эти характеристики сравниваются и соответственно выделяются однородные области.

Однако такой подход не вполне соответствует реальной физической структуре процесса формирования текстуры и может давать непредвиденные значительные отклонения при их использовании для реального изображения.

Наиболее приближенный к реальности способ описания текстуры – это формирование матрицы смежности и последующая оценка этой матрицы с использованием различных дескрипторов: максимальная вероятность, момент K -го порядка, обратный разностный момент, энтропия и однородность.

Матрица смежности C_o дает информацию о взаимном расположении пикселей. Для этого требуется вычислить матрицу положения C размером

$K \times K$, каждый элемент которой $c_{i,l}$ есть число появления пикселей с интенсивностью d_l в заданной области, определяемым некоторым оператором положения, задающим расстояние и направление положения элементов имеющих значение яркости d_l относительно яркости элемента i, j исходной матрицы изображения P . Для получения матрицы S_0 приемлемого размера необходимо весь диапазон разбивать на несколько интервалов. Тогда матрица S_0 , элементы которой вычисляются как $c_{i,l} / n$ (где n – число уровней, соответствующих условию, задаваемому матрицей положения), будет характеризовать вероятность того, что яркость пары точек будет иметь разность d_l . Затем выполняется анализ матрицы. Для этого используются различные характеристики распределений функции вероятностей: среднее, разностный момент порядка K , обратный разностный момент, энтропия, однородность.

Комплексные методы. Методы разномасштабного или кратномасштабного анализа основаны на выделении границ на различных масштабах (уровнях) разложения изображения или применения моделей различного вида для каждого масштаба. Масштаб изображения обеспечивает уровень детальности изображения и соответственно выделение определенного типа границ на каждом уровне разложения. При этом выполняется переход от более грубого к детальному изображению и наоборот. Причем каждый уровень соответственно исследуется на однородность. К таким алгоритмам можно отнести вейвлет-анализ, основанный на последовательном разложении исходной функции, описывающей изображение по ортогональным базисным функциям, и последующем анализе коэффициентов различного уровня разложения.

Кластерный анализ. Общие сведения

Методы распознавания образов делятся на *методы с обучением* и *методы без обучения* (кластерный анализ).

В первом случае используются тестовые эталонные участки на изображении, для которых известно, что они принадлежат объектам заданного класса. Используя эталонные изображения, определяют характеристики признаков, используемых для дешифрирования объектов заданного клас-

са. Например, для многоспектральных снимков измеряются яркости элементов в каждом канале и строится многомерная гистограмма многоспектральных яркостей, которая затем используется для распознавания.

Методы без обучения основаны на вычислении «расстояния» между классами, заданного определенным образом, и использовании критериев принадлежности к заданному классу. Для работы алгоритмов не требуются эталонные участки, а следует лишь указать количество классов и «центр» класса. К этим методам относятся алгоритмы кластерного анализа.

Кластерный анализ – это разделение массива данных на классы, однородные в соответствии с каким-либо признаком (системой признаков). Сущность кластерного анализа заключается в выделении на снимках определенных классов объектов или групп объектов. Принадлежность к определенному классу определяется системой признаков. Для разделения совокупности измерений на классы задается критерий принадлежности элементов изображения к заданному классу в соответствии с заданным признаком. Критерий принадлежности – это, как правило, предельное расстояние $d_{\max}$ в пространстве спектральных признаков

Заметим, что признаки классификации могут быть совершенно различными. Изучая одни и те же снимки, исследователи из разных областей науки выделяют на этих снимках совершенно различные объекты, «однородные», по их мнению.

Наиболее яркий пример этому дает «Древняя китайская классификация животных».

Животные подразделяются:

- на принадлежащих императору;
- набальзамированных;
- дрессированных;
- молочных поросят;
- сказочных;
- бродячих собак;
- включенных в данную классификацию;
- дрожащих, как сумасшедшие;
- неисчислимых;
- нарисованных самой лучшей верблюжьей кисточкой;

- других;
- тех, которые только что разбили цветочную вазу;
- тех, которые издаleка напоминают мух (Борхес Хорхе Луис. Аналитический язык Джона Уилкинса [Электронный ресурс]. – Режим доступа : <https://dic.academic.ru/dic.nsf/ruwiki/120024>).

Вероятно, это самое исчерпывающее философское определение классификации, так как обычно, классифицируя объекты, мы выделяем те признаки объекта, которые «интересны для нас» и которые отдаленно напоминают сам объект и его свойства. Объект же существует сам по себе и ему нет никакого дела, к какому классу мы его относим.

Вооружившись таким емким описанием классификации, перейдем к рассмотрению метода неуправляемой классификации, который наиболее подходит к принципам вышеприведенной «классификации животных».

Рассмотрим применение кластерного анализа для классификации изображений.

На основе кластерного анализа работают алгоритмы K-Means, ISODATA и RGB.

Рассмотрим алгоритм ISODATA. Для его работы необходимо задать:

- признак (обычно это вектор многоспектральной яркости $\bar{P} = \{P^I, P^{II}, \dots, P^k\}$, однако могут быть выбраны и другие признаки);
- количество классов n , которые нужно выделить на изображении;
- центры классов $\bar{P}_{cl} = \{P_{C1}^I, P_{C1}^{II}, \dots, P_{C1}^k\}$;
- расстояние между признаками

$$d = \bar{P}_{cl} - \bar{P}_{i,j} = \sqrt{(P_{cl_1}^I - P_{i,j}^I)^2 + (P_{cl}^{II} - P_{i,j}^{II})^2 + \dots + (P_{cl}^k - P_{i,j}^k)^2}, \quad (31)$$

или

$$d = |P_{cl}^I - P_{i,j}^I| + |P_{cl}^{II} - P_{i,j}^{II}| + \dots + |P_{cl}^k - P_{i,j}^k|, \quad (32)$$

- где P_{cl} – центр класса C_1 ;
- критерий принадлежности к данному классу – $d_{\max}$,

$$\left. \begin{aligned} d_{ij} < d_{\max} &\Rightarrow i, j \in C_1 \\ d_{ij} \geq d_{\max} &\Rightarrow i, j \notin C_1 \end{aligned} \right\}. \quad (33)$$

По этому критерию все изображение делится на n классов.

Затем вычисляется новый центр класса как среднее значение векторов, которые принадлежат данному классу, и вся процедура повторяется. Процесс выполняется до тех пор, пока смещение каждого центра класса не будет меньше заданного порога.

При выполнении кластеризации по алгоритму ISODATA обеспечиваются условия:

- расстояния между новыми центрами классов должны быть минимальными;
- расстояния между центрами различных классов максимальные.

Можно использовать одновременно несколько признаков, устанавливать несколько порогов и правила для вычисления критерия принадлежности объекта заданному классу.

Статистический подход к распознаванию объектов на изображении.

Байесовская теория решений. Байесовский классификатор

При распознавании объектов по их изображениям большинство дешифровочных признаков являются случайными величинами, и для их описания применяются вероятностные методы. Таким образом, методы распознавания объектов связаны с исследованиями случайных функций и применением статистических методов. Например, один из основных дешифровочных признаков – спектральные яркости, являющиеся случайными функциями множества случайных факторов.

В теории вероятностей полагают, что случайная величина x полностью характеризуется функцией распределения вероятностей, соответственно для использования вероятностных моделей следует определить функцию распределения вероятностей исследуемой величины.

Практически существует два класса статистических задач:

- 1) вид функции $f(x)$ распределения известен и описывается конечным числом параметров (в этом случае нужно найти только параметры этого распределения);

2) альтернативный вариант – когда вид функции не известен и требуется найти эту функцию или, по крайней мере, получить ее оценку с соответствующим уровнем достоверности. Такая задача решается методами статистики.

В любом случае в статистических методах распознавания образов, в частности, при распознавании классов объектов по их изображениям, для определения функции распределений $f(x)$ выполняется «обучение». Процесс обучения сводится к следующему. Источником информации для получения оценки функции распределения являются выполненные измерения. Если рассматривать дешифрирование снимка, то измерениями в данном случае будут яркости изображения p_{ij} или яркости многоспектрального изображения $P_{ij}(p_{ij}^1, p_{ij}^2, \dots, p_{ij}^k)$. В общем случае на каждом снимке имеется $N \times N \times k$ измерений. Задача распознавания состоит в разделении всей совокупности измерений на K непересекающихся классов на основе статистических свойств этих измерений. Статистические свойства, как уже отмечалось, полностью характеризуются функцией распределения вероятностей. Оценка функции находится на основе некоторых совокупностей измерения, которые априорно считаются принадлежащим определенному классу объектов. Такая совокупность измерений называется обучающей выборкой. Если требуется распознать K классов объектов по некоторому признаку x , требуется создать K обучающих выборок $x_l^m(x_1, x_2, \dots, x_{ml})$ для каждого класса m размерностью l . Так, если признаком является элемента изображения, т. е. $x_{m_i} = p_{ij}$, то функция распределения $f(x)$ будет одномерной. Если же в качестве признака будет выбрана величина $\bar{x}_{m_i} = P_{ij}(p_{ij}^1, p_{ij}^2, \dots, p_{ij}^k)$, то для описания процесса используется многомерная функция плотности распределения вероятностей. Кроме обучающей функции используют дополнительную выборку, которую называют контрольной выборкой $x_l^n(x_1, x_2, \dots, x_{nl})$. Эта выборка служит для оценки достоверности выборки, полученной в результате обучения.

Принадлежность какого либо события к определенному классу путем вычисления отношения правдоподобия и сравнения с некоторым порогом

$$L = \frac{f(x_1, x_2, \dots, x_n / \omega_2)}{f(x_1, x_2, \dots, x_n / \omega_1)} \geq c. \quad (34)$$

В данном случае, если $L \geq c$, то событие ω_2 принадлежит к классу объектов ω_1 .

Заметим, что в большинстве практических методов используется не функция распределения, а интегральная функция плотности распределения вероятностей:

$$F(x) = \int f(x)dx. \quad (35)$$

При использовании вероятностных методов нужно определить функцию плотности распределения вероятностей. На практике получают оценку этой функции плотности вероятностей на основе обучения по выборке, полученной из реализации случайного процесса.

Различают параметрические и непараметрические методы. В первом случае вид распределения априорно известен, и при обучении определяются только параметры этого распределения. Во втором случае вид функции распределения не известен, и можно определить лишь некоторые статистики распределения – моменты распределения (среднее, дисперсия, скос, эксцесс и т. д.) и получить оценку функции распределения одним из известных статистических методов (гистограммный, метод Парзена, полигональные оценки и т. д.)

Если функция плотности распределения вероятностей не известна, то для получения оценки этой функции необходимо выполнить по реализациям этой функции большое число измерений. Качественная оценка функции распределения случайной величины становится особенно сложной проблемой для многомерных функций, например, при обработке данных многоспектральных снимков, описываемых многомерной функцией плотности распределения.

Классификатор изображений – это последовательность действий (алгоритм) вычисления, разделяющих функций и определение вектора решения в соответствии с наибольшей из них.

Байесовский классификатор является одним из основных статистических методов распознавания образов. Структура байесовского классификатора определяется функцией условных плотностей вероятностей $P(x / \omega_j)$, которая показывает вероятность появления события ω_j при появлении события x (т. е. если признак x имеет некоторое значение $x=a$).

Сущность метода заключается в вычислении апостериорной вероятности $P(\omega_j / x)$ по априорной вероятности $P(\omega_j)$ и условной вероятности $P(x / \omega_j)$ путем нахождения максимальной апостериорной вероятности $\max P(\omega_j / X)_{\forall j, j=1 \div n}$, которая и указывает на то, что объект принадлежит классу ω_j . Таким образом, в Байесовском классификаторе используются следующие величины:

- $P(\omega_j)$ – априорная вероятность появления события (объекта) ω_j (в нашем случае – вероятность того, что элемент изображения принадлежит классу ω_j);

- $P(x / \omega_j)$ – условная плотность вероятности – вероятность появления события ω_j , если значение признака равно x ;

- $P(\omega_j / x)$ – апостериорная вероятность – вероятность того, что при значении признаков x и априорной вероятности $P(\omega_j)$ произойдет событие ω_j .

Практически $P(x / \omega_j)$ получают в результате обучения. Для этого измеряется некоторая величина x (признак) и строится гистограмма распределения признака x . При распознавании объектов по их изображениям обычно измеряют яркости элементов p_{ij} в одном или нескольких каналах. Тогда условная плотность распределения случайной величины x будет $P(x / \omega_j)$, полученная гистограммным методом.

В соответствии с принятыми обозначениями, вероятность того, что объект принадлежит классу ω_j , можно вычислить как апостериорную вероятность, используя правило Байеса:

$$P(\omega_j / x) = \frac{P(\omega_j)P(x / \omega_j)}{P(x)}, \quad (36)$$

где

$$P(x) = \sum_{j=1}^n P(\omega_j)P(x / \omega_j). \quad (37)$$

После вычисления апостериорной вероятности появления каждого события принимается решение о принадлежности события данному классу (с использованием решающего правила Байеса) имеет место событие ω_j , если $p(\omega_j | x) > p(\omega_i | x)$ для всех $i \neq j$.

Для случая двух классов правило Байеса соответственно будет следующее: имеет место событие ω_1 , если $p(\omega_1 | x) > p(\omega_2 | x)$.

В данном случае вероятность ошибки будет:

$$P(\text{ошибки} / x) = \left\{ \begin{array}{l} P(\omega_1 / x), \text{ если } \omega_2 \\ P(\omega_2 / x), \text{ если } \omega_1 \end{array} \right\}. \quad (38)$$

Для байесовского классификатора можно определить разделяющие функции $g(X)$, которые разделяют область признаков на классы. Например, можно использовать следующие функции:

$$\begin{aligned} G_i(X) &= P(\omega_i / X); \\ G_i(X) &= P(X / \omega_i)P(\omega_i); \\ G_i(X) &= \log P(X / \omega_i) + \log P(\omega_i). \end{aligned} \quad (39)$$

Решающие правила, например (36), позволяют разделить исходное пространство изображений на n областей решения.

При наличии k классов и n признаков задача вычисления $\max p(\omega_j | x)$ становится весьма сложной как с точки зрения хранения многомерных гистограмм, так и с вычислительной точки зрения.

Для упрощения задачи и обеспечения возможности получения как аналитических, так и численных решений, предполагают, что случайные величины подчиняются нормальному закону распределения (рис. 7). В этом случае распределение одномерного признака x определяется средним значением μ и средним квадратическим отклонением σ .




Рис. 7. Нормальный закон распределения

Вычисляют среднее значение μ и стандарт σ , считая, что распределение подчиняется нормальному закону, получают функцию плотности распределения вероятностей:

$$P(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp \left[-\frac{1}{2} \frac{(x - \mu)^2}{\sigma^2} \right], \quad (40)$$

где μ – среднее значение величины x ,

$$\mu = \sum_{i=1}^N \frac{x}{N}, \quad (41)$$

σ – стандарт (в геодезии и фотограмметрии – среднее квадратическое отклонение),

$$\sigma = \sqrt{\frac{\sum_{i=1}^N (x - \mu)^2}{N - 1}}, \quad (42)$$

где N – количество измерений.

Для описания многомерной случайной величины используется многомерная функция плотности распределения вероятностей.

Нормальная многомерная плотность распределения вероятностей, определяется выражением

$$P(X) = \frac{1}{2\pi^{d/2} |R|^{1/2}} \exp \left[-\frac{1}{2} (X - \bar{\mu})^T R^{-1} (X - \bar{\mu}) \right], \quad (43)$$

где X – d -компонентный вектор столбец.

Таким образом, функция плотности распределения вероятностей $P(X)$ вектора признаков X размерности d полностью определяется двумя параметрами: вектором $\bar{\mu}$ размерности d и ковариационной матрицей R размером $k \times k$. Для вычисления принадлежности вектора измерений X_i заданному классу применяются решающие правила, использующие для вычисления принадлежности объекта заданному классу значения вектора $\bar{\mu}$ и ковариационной матрицы R :

$$R = XX^T. \quad (44)$$

При обработке многоспектральных изображений вектор $X = \bar{P}_{ij}$ – вектору измерений яркостей элемента i, j многоспектрального изображения, тогда ковариационная матрица будет иметь вид

$$R = \frac{1}{NN} \sum_{i=1}^N \sum_{j=1}^N P_{ij} P_{ij}^T, \quad (45)$$

где N – количество измерений.

Для многоспектрального изображения обычно используют многомерную функцию плотности распределения, которая определяется в пространстве признаков, затем вычисляются разделяющие функции, и принимается решение о принадлежности объекта заданному классу в соответствии с максимальной разделяющей функцией.

Разделяющая функция для нормального случая распределения, обеспечивающая минимальный уровень ошибки, будет иметь вид

$$g_i(\bar{x}) = \log p(\bar{x}|\omega_i)^T + \log p(\omega_i), \quad (46)$$

$$g_i(x) = -\frac{1}{2}(\bar{x} - \bar{\mu})^T \cdot R_i^{-1} \cdot (x - \mu_i) - \frac{d}{2} \log 2p - \frac{1}{2} \log |R_i| + \log p(\omega_i). \quad (47)$$

Для случая независимых признаков (т. е. когда $R_i = \sigma^2 I$) разделяющая функция примет вид

$$g_i(\bar{x}) = \frac{-\|\bar{x} - \bar{\mu}_i\|^2}{2\sigma^2} + \log p(\omega_i); \quad (48)$$

$$\|\bar{x} - \bar{\mu}_i\|^2 = (\bar{x} - \bar{\mu}_i)^T (\bar{x} - \bar{\mu}_i). \quad (49)$$

Разделяющую функцию можно упростить, преобразуя (47):

$$g_i(\bar{x}) = \left(\frac{1}{\sigma^2} \bar{\mu}_i\right)^T \cdot \bar{x} - \frac{1}{2\sigma^2} \mu_i^T \mu_j + \log p(\omega_i). \quad (50)$$

Разделимость. Для распознаваемых классов на основе определенных при обучении статистических характеристик для выбранных признаков $\bar{x}$ можно записать критерии разделимости классов. Наиболее простой вариант – вычислить **расстояние Махаланобиса**, которое является характеристикой нормальной плотности распределения вероятностей от X до $\bar{\mu}$.

$$D = (X - \bar{\mu})^T R^{-1} (X - \bar{\mu}). \quad (51)$$

Расстояние D определяет точки с одинаковой плотностью вероятностей, которые образуют гиперэллипсоиды в многомерном пространстве. Причем оси эллипсоидов – собственные векторы матрицы R , а собственные значения определяют длины осей гиперэллипсоидов. Тогда вычислив расстояния Махаланобиса в пространстве признаков для нескольких точек можно оценить степени их разделимости.

Существуют также и другие критерии разделимости.

Дивергенция (D_{ij}) – расхождение между классами, вычисляется в соответствии с соотношением

$$D_{ij} = \frac{1}{2} \text{tr} \left[(R_i - R_j)(R_i^{-1} - R_j^{-1}) \right] + \frac{1}{2} \text{tr} \left[(R_i - R_j)(\mu_i - \mu_j)(\mu_i - \mu_j)^T \right], \quad (52)$$

где i и j – номер распознаваемых классов;

R_i – ковариационная матрица для класса i ;

μ_i – среднее значение класса i ;

tr – след матрицы;

T – знак транспонирования.

Преобразованная дивергенция:

$$TD_{ij} = 2\,000(1 - \exp(\frac{-D_{ij}}{8})). \quad (53)$$

Здесь D_{ij} вычисляется из выражения (52). Значение TD в пределах от 1 700 до 1 900 показывает хорошую разделимость, ниже 1 700 – достаточно плохую разделимость классов.

Расстояние Джеффриса – Матусита (Jeffries–Matusita Distance) вычисляется по формуле

$$\alpha = \frac{1}{2}(\mu_i - \mu_j)^T \left(\frac{R_i + R_j}{2} \right)^{-1} (\mu_i - \mu_j) + \frac{1}{2} \ln \frac{|(R_i + R_j) / 2|^2}{\sqrt{|R_i| \cdot |R_j|}}; \quad (54)$$

$$JM_{ij} = \sqrt{2(1 - e^{-\alpha})}, \quad (55)$$

где $|R_i|$ – определитель матрицы R_i .

Расстояние Джеффриса – Матусита увеличивается с увеличением разделимости классов.

Численное значение критериев TD и JM , близкое к верхней границе, показывает хорошую разделимость классов, а близкое к 0 – неразделимость. Диапазон изменения параметров TD и JM лежит в пределах:

- TD изменяется от 0 до 2 000;
- JM – от 0 до 1 414.

Используя эти критерии, можно оценить степень разделимости классов в случае выбранного набора дешифровочных признаков. Далее можно изменить набор признаков или построить какой-либо новый алгоритм распознавания в соответствии с другой системой признаков.

Представим основные этапы классификации изображений на основе байесовского решающего правила.

1. Определение априорной вероятности нахождения класса ω_j на изображении $P(\omega_j)$. Практически вероятность $P(\omega_j)$ устанавливается оператором на основе знаний о местности, изображенной на снимке, или в результате визуального анализа изображения.

2. Выбор тестовых участков для классов, которые планируется распознать ($\omega_1, \dots, \omega_n$).

3. Выбор системы дешифровочных признаков, например вектор спектральных яркостей

$$\bar{x} = \{P^I, P^{II}, \dots, P^K\} \quad (56)$$

и определение $P(x / \bar{\omega}_j)$ функции плотности распределения признака $\bar{x}$ для класса ω_j на основе обучающей выборки – по участку изображения, выбранного для «обучения».

4. Аппроксимация функции распределения условной плотности вероятности $P(x / \omega)$ функции нормальной плотности распределения с параметрами $\bar{\mu}$ и Σ в соответствии с принципом максимального правдоподобия.

5. Определение степени разделимости классов ω_i и ω_j в случае необходимости корректировки системы признаков. Выбор разделяющей функции для принятия решения.

6. Классификация на основе использования одной из разделяющих функций. Визуализация классов и оценка оператором приемлемости результатов.

Простые методы распознавания

Метод параллелепипедов. Метод основан на обучении по выбранному участку, в результате которого определяют средние значения μ и средние квадратические отклонения σ_i для каждого признака (на основе измерения значений признака x на тестовом участке).

Известно, что для нормально распределенной случайной величины 95,4 % ее значений лежит в пределах отклонений от среднего значения, меньших 2σ . Тогда границы области, в которую могут попасть значения случайной величины, ограничены двойным значением стандарта, а центр распределения находится в точке μ .

В двухмерном случае области, выделяющие классы, получаются в виде прямоугольников, в трехмерном – в виде параллелепипедов и т. д.

Метод параллелепипедов относится к числу быстрых методов классификации, однако по качеству распознавания уступает большинству из существующих. Его целесообразнее всего использовать для предварительной классификации.

Метод спектрального угла (не параметрический) основан на сравнении вектора $\bar{P}_{ij}$ спектральных характеристик элемента изображения с вектором эталонов $P_{\text{эт}}$, взятым из спектральных библиотек. Вычисляется угол между векторами как их скалярное произведение

$$\alpha = \arccos \left(\frac{\bar{P}_{ij} \bar{P}_{\text{эт}}}{|\bar{P}_{ij}| |\bar{P}_{\text{эт}}|} \right), \quad (57)$$

где ij – номер пикселя, который сравнивается с эталоном $P_{\text{эт}}$.

По значению угла α определяют отличие исследуемого вектора от эталона.

Методом спектрального угла нельзя отличить объекты, имеющие схожий характер спектральной кривой, но имеющие различную интенсив-

ность, поскольку учитывается только направление спектральных векторов, а не их длина. Кроме того, сложность использования метода обусловлена отсутствием спектральных библиотек для большинства объектов исследований.

Метод спектральных расстояний. Алгоритм основан на вычислении спектрального расстояния между эталоном $P_{\text{эт}}$ и спектральной яркостью элемента $\bar{P}_{ij} = (p_{ij}^I, p_{ij}^{\text{II}}, \dots, p_{ij}^K)^T$

$$D = \sqrt{\sum_{l=1}^K (p_{ij}^l - p_{\text{эт}}^l)^2}. \quad (58)$$

Здесь $\bar{P}_{\text{эт}} = (p_{\text{эт}}^I, p_{\text{эт}}^{\text{II}}, \dots, p_{\text{эт}}^K)^T$ вычисляется как среднее значение спектральной яркости элементов эталона.

Чтобы найти условную вероятность, нужно знать функцию, описывающую изменение плотности вероятности в зависимости от x . Эту зависимость можно получить в процессе статистических испытаний на тестовых участках снимка, для которых точно определена их принадлежность к заданному объекту.

Для анализа изображений формальная теория классификаций применяется в совокупности со специальными приемами дешифрирования. На данный момент участие оператора в процессе автоматического анализа очень велико.

Представленные методы и алгоритмы реализованы в большинстве современных программных продуктов. Наиболее широкое применение для анализа изображений в настоящее время получили такие программные комплексы, как ERDAS Imagine, ENVI, ER MAPPER, EASI PACE, Descartes, Image Analyst.

1.4. Методы распознавания, основанные на использовании структурных свойств изображений

Преобразование Фурье

Методы частотного подхода базируются на преобразовании Фурье, которое позволяет представить функцию в виде набора гармонических

функций (синусов и косинусов), что позволяет рассматривать исходную функцию в пространственной (частотной) области и соответственно изучать ее пространственную структуру. С точки зрения анализа изображений, переход в частотную область позволяет определять «вклад», который вносят те или иные гармоники в изображение. Выполнив разложение Фурье, можно определить спектральный состав изображений, т. е. выявить, какие частоты ω_i вносят наибольший вклад в изображение. Так, например, изображение, на котором в основном имеются достаточно большие однородные поля, содержит низкие частоты, и, наоборот, мелкие детали изображения передаются высокими частотами.

Дискретное Фурье-преобразование исходного изображения $P(x, y)$, определяемое на интервале $[0; N - 1]$, может быть представлено в виде

$$P(u, v) = \frac{1}{NN} \sum \sum P(x, y) e^{-i2\pi \left(\frac{ux}{N} + \frac{vy}{N} \right)}; \quad (59)$$

$$P_i(x, y) = \frac{a_0}{2} + \sum_{n=0}^{\infty} \sum_{m=0}^{\infty} a_n \cos(n\omega_0 x + m\omega_0 y) + b_n \sin(n\omega_0 x + m\omega_0 y). \quad (60)$$

В результате Фурье-преобразования изображения размером $N \times N$ получается Фурье-образ, определяемый набором коэффициентов, описывающих структуру изображения (рис. 8).




Рис. 8. Фрагменты изображения и их Фурье-образ

Получив и проанализировав коэффициенты Фурье a_i , b_i можно выбрать те частоты, которые передают основное содержание изображений. Это важно при сжатии и передаче изображения по каналу связи, разработке алгоритмов автоматического дешифрирования снимков, алгоритмов идентификации точек на стереопаре и т. д.

Несмотря на большие возможности анализа функций методами Фурье, Фурье-анализ не позволяет заметить хорошо локализованные изменения сигнала по времени, так как отражает только поведение сигнала за все время его существования. Эту задачу решает вейвлет-анализ.

Вейвлет-преобразование

В отличие от Фурье-анализа, вейвлет-преобразование использует функции, которые локализованы как по частоте, так и по времени, что обеспечивает возможность анализа результата как в частотном, так и в физическом пространстве, что важно при работе с неоднородным сигналом, таким, например, как изображение поверхности Земли.

Вейвлет-преобразование сигнала состоит в разложении его по вейвлет-функциям. Общий принцип построения вейвлет-функций состоит в использовании масштабных преобразований и сдвигов. Такие функции обладают переменной частотой и конечной длительностью. Также возможно выполнять и обратное преобразование, которое является результатом свертки вейвлет-коэффициентов и вейвлет-функции.

Дискретное вейвлет-преобразование функции изображения $f(x, y)$ размером $M \times N$ выполняется в соответствии с формулами

$$\begin{aligned} W_{\varphi}(j_0, m, n) &= \frac{1}{\sqrt{MN}} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \varphi_{j_0, m, n}(x, y); \\ W_{\psi}^i(j, m, n) &= \frac{1}{\sqrt{MN}} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \psi_{j, m, n}^i(x, y), \end{aligned} \quad (61)$$

где j_0 – произвольный начальный масштаб;

$W_{\varphi}(j_0, m, n)$ – коэффициенты, определяющие приближение функции $f(x, y)$ в масштабе j_0 ;

$W_{\psi}^i(j_0, m, n)$ – коэффициенты, определяющие горизонтальные, вертикальные и диагональные детали для масштабов $j \geq j_0$;

$\psi_{j,m,n}^i$ – масштабирующая функция;

$\varphi_{j_0,m,n}(x, y)$ – вейвлет-функции.

Вейвлет-функции – это растянутые и сдвинутые копии вейвлета, вычисляемые по формуле

$$\psi_{j,m,n}^i(x, y) = 2^{j/2} \psi^i(2^j x - m, 2^j y - n). \quad (62)$$

Существует большое количество различных вейвлет-функций, наиболее распространенными из которых являются Хаара, Добеши, койфлеты, симлеты, Морле и др. (рис. 9).


Соответствующая вейвлет-функции масштабирующая функция вычисляется по формуле

$$\varphi_{j_0,m,n}(x, y) = 2^{j/2} \varphi(2^j x - m, 2^j y - n), \quad (63)$$


где m, n определяют положение функций в двумерном пространстве изображения, j – ширину функций, множитель $2^{j/2}$ регулирует амплитуду функций.

Анализируя коэффициенты вейвлет-функции, можно определить изменения в структуре изображения и локализовать «границу» изменений. Критерием изменений может служить коэффициент корреляции между различными уровнями вейвлет-преобразования соответствующих фрагментов разновременных изображений.


а)



б)



в)



г)




Рис. 9. Вейвлет-функции:

а) Хаара; б) Добеши; в) симлеты; г) койфлеты

Таким образом, вейвлет-анализ является эффективным инструментом выявления изменений. Он может использоваться при исследовании различных природно-территориальных комплексов. Основным преимуществом данной методики является независимость от изменений яркости, не являющихся следствием существенных изменений, что является значительным преимуществом по сравнению с традиционными методами.

Распознавание с использованием решающего метода дерева решений

Метод дерева решений можно рассматривать как с позиции теории графов, так и с позиций формальных языков грамматики.

В первом случае дерево решений – это граф, представляющий правила в иерархической последовательной структуре, где каждому объекту соответствует единственный узел, дающий решение. Дерево решений в таком случае строится следующим образом. Сначала берется весь набор данных, который представляется исходной, или корневой вершиной. Затем задают правила разбиения на ветви всего множества, соответствующего корневому узлу. Дерево образуют ветви, на них отмечают узлы, отвечающие подмножеству вариантов. На каждом узле вновь задают правила разбиения на ветви и т. д., до тех пор, пока процесс не дойдет до конечных узлов. Дерево решений часто применяется для создания процессов поэтапного принятия решений. Такое представление позволяет наглядно описать процесс принятия решений.

Правило разбиения множеств записей или вариантов называют решающим правилом a :

$$a_{ik} = \begin{cases} 1, & \text{если условие выполняется;} \\ 0 & \text{в противном случае,} \end{cases} \quad (64)$$

где $a_{ik} = 1$, если условие s_i для правила r_k выполняется;

$S\{s_i\} i = \overline{1, I}$ – множество условий, описывающих параметры выбранной предметной области;

$R = \{r_k\} - k = \overline{1, K}$ – множество решающих правил.

Это правило позволяет разделить множество на две группы. По мере спуска по дереву решений создаются однородные множества, удовлетворяющие определенному набору условий, которые заложены в узлах дерева.

С другой стороны, дерево решений относится к методам синтаксического распознавания образов, использующих относительно новый подход теории формальных языков. Иногда этот метод распознавания называется

методом формальных грамматик, или структурным синтаксическим методом распознавания. В качестве первого знакомства с методом синтаксического распознавания образов можно предложить книгу Дж. Ту, Р. Гонсалеса «Принципы распознавания образов» (с. 336–384) [6].

Все задачи, решаемые с помощью дерева решений, могут быть сведены к следующим трем типам:

- 1) описание данных, содержащее их характеристику;
- 2) классификация, т. е. отнесение объекта к одному из заранее известных классов;
- 3) регрессия, устанавливающая зависимость целевой переменной от независимых (входных) данных.

Часто алгоритмы построения дерева решений дают сложные деревья, переполненные данными, имеют много узлов и ветвей. В них трудно разобраться. В таких случаях бывает удобнее разбить дерево на несколько деревьев решений.

Деревья решений поддерживаются программными комплексами различных фирм: так система MiniSet содержит визуализатор деревьев (TreeVisualizer) и визуализатор правил (Rule Visualizer). Специально для работы с деревьями решений созданы программные системы Clementine (Integral Solution, Великобритания), SIPINA (Лионский университет, Франция) и др.

1.5. Структура алгоритмов распознавания образов

Конструирование алгоритмов распознавания

Методы автоматизированного или автоматического дешифрирования снимков включают следующие процессы:

- выбор системы дешифровочных признаков для распознавания объектов заданных классов;
- сегментация изображения;
- выбор метода распознавания;
- выбор функции, разделяющей пространство признаков на отдельные классы;

- выбор критериев соответствия объектов, позволяющих оценить принадлежность объекта к тому или иному классу;
- оценка достоверность классификации.

Распознавание по байесовскому критерию

Дешифровочный признак – вектор спектральных яркостей много-спектрального изображения.

Метод – обучение по изображениям эталонных объектов.

Метод распознавания – байесовский метод вычисления априорной вероятности.

Критерий принадлежности объектов к заданному классу – максимальное значение апостериорной вероятности.

Оценка результата – оценка количества правильно и не правильно распознанных объектов.

Основные этапы классификации изображений на основе байесовского классификатора.

Распознавание по цифровым моделям рельефа (ЦМР) и цифровым моделям поверхности (ЦМП)

Дешифровочный *признак* – пространственная модель рельефа и поверхности.

Метод-сравнение суперплотных моделей ЦМР и ЦМП, построенных по стереопарам снимков, путем создания разностных моделей.

Критерий принадлежности объектов к заданному классу – пороговое значение превышения в разностной модели.

Отображение разностной модели в виде псевдоцветного изображения и векторизация каждого уровня цвета.

Оперативное распознавание объектов путем использования преобразования ТС

Дешифровочный *признак* – спектральные яркости изображений, полученные путем преобразования ТС.

Метод – получение коэффициентов $ТС$ для заданной съемочной камеры и участка поверхности с заданным набором объектов и преобразование дешифрируемого изображения по методу $ТС$.

Представление полученного многоспектрального изображения в виде псевдо цветного изображения с заданным набором цветов.

Решающее правило – объекты различаются по псевдо цветному изображению с заданным порогом цвета. Полученное изображение векторизуется в автоматическом режиме.

Таким образом, алгоритм после определения коэффициентов преобразования $ТС$ – полностью автоматический алгоритм.

1.6. Выявление изменений по разновременным снимкам

Современные космические съемочные системы позволяют получить данные, обеспечивающие проведение мониторинга практически любого уровня, с различной детальностью и периодичностью. Основным элементом мониторинга по космическим снимкам является выявление произошедших изменений по материалам съемок, выполненных в разные даты.

Учитывая огромный поток информации, который должен быть разработан в ограниченное время, ясно, что нужны алгоритмы автоматического выделения изменений.

В связи с этим основной проблемой эффективного мониторинга по аэрокосмическим снимкам является разработка новых и оптимизация существующих алгоритмов выявления изменений по разновременным снимкам.

Задача выявления изменений по разновременным снимкам существенно отличается от задачи дешифрирования. В связи с изменением условий съемки могут измениться изображения одних и тех же объектов, что часто приводит к неправильному выделению действительных изменений объектов.

В настоящее время разработана целая группа алгоритмов и методов выделения изменений – change detection – по разновременным аэрокосмическим снимкам различного типа, однако до сих пор нет универсальных методов, рассчитанных на широкий класс объектов. Процесс выявления

изменений является основой ведения мониторинга по аэрокосмическим снимкам.

Методы выделения изменений на снимках можно условно разделить на несколько групп:

- методы, основанные на поэлементном анализе яркостей исходных изображений, полученных на различные даты, или же преобразованных нормированных или индексных изображений;

- методы, основанные на анализе разновременных изображений, предварительно преобразованных методами *PCA*, *ICA*, *TC* с целью уменьшения корреляционных связей между соответствующими элементами многоспектрального изображения;

- методы, основанные на использовании структурных свойств изображений;

- методы, основанные на сравнении результатов классификации изображений на разные даты;

- комплексные методы, использующие совместно *спектральные*, *структурные* и *геометрические* признаки и основанные на применении физической модели исследуемого процесса или модели объекта;

- методы, основанные на использовании *нейронных сетей*;

- методы, основанные на использовании *геоинформационных систем*;

- *визуальный анализ* исходных или преобразованных многоспектральных снимков;

- прочие методы.

Первая группа методов включает в себя методы дифференцирования изображений Image Differencing, регрессионные методы Image Regression, методы, основанные на индексных изображениях (Vegetation Index Differencing, анализ изменений вектора яркостей Change Vector Analysis – CVA), и метод вычитания фона – Background Subtraction.

Эти методы основаны на поэлементном вычитании яркостей исходных или преобразованных изображений $P(x, y, t_I)$ и $P(x, y, t_{II})$, полученных на разные даты (t_I и t_{II}). Для этого вычисляют разность

$$\Delta P_{ij} = P_{ij}(t_I) - P_{ij}(t_{II}) \quad (65)$$

или

$$\Delta P'_{ij} = P'_{ij}(t_I) - P'_{ij}(t_{II}), \quad (66)$$

где $P_{ij}(t_I)$ и $P'_{ij}(t_I)$ – исходное и преобразованное изображения на первую дату t_I ;

$P_{ij}(t_{II})$ и $P'_{ij}(t_{II})$ – соответственно на вторую дату t_{II} .

Затем сравниваются с порогом Δ и устанавливается наличие изменений, если $\Delta P'_{ij} > \Delta$.

В регрессионном методе элементы изображения на вторую дату преобразуются в соответствии с выражением

$$P'_{ij}(t_{II}) = a_0 + a_1 P_{ij}(t_I), \quad (69)$$

где a_0 и a_1 – коэффициенты, полученные путем решения уравнения вида

$$P'_{ij}(t_I) = a_0 + a_1 P_{ij}(t_{II}), \quad (70)$$

составляемого для характерных элементов i и j , выбранных на первом и втором изображениях.

В методах, основанных на вычислении отношения яркости элементов на разные даты, используется выражение

$$K_{ij} = \frac{P_{ij}(t_I)}{P_{ij}(t_{II})}. \quad (69)$$

Для неизменившихся элементов K_{ij} близко к единице.

При анализе векторов спектральных яркостей вычисляется

$$\Delta \bar{P}_{ij} = \sqrt{\Delta P_{ijI}^2 + \Delta P_{ijII}^2 + \Delta P_{ijk}^2} \quad (70)$$

и $\Delta \bar{P}_{ij}$ сравнивается с заданным интервалом Δ .

Аналогично вычисляются величины (65) и (69) для преобразованных изображений. Например, для индексных изображений $NDVI$ вычисляют

$$\Delta P_{ij} = NDVI_{ij}(t_I) - NDVI_{ij}(t_{II}). \quad (71)$$

Метод Background Subtraction основан на предварительной подготовке разновременных изображений путем вычитания фоновой составляющей каждого из них. Фоновые изображения получают путем низкочастотной фильтрации. Данный метод прост в использовании, но, как правило, обладает невысокой достоверностью.

Вторая группа алгоритмов Change Detection включает в себя методы преобразования изображений Principal Component Analysis (PCA), Tasseled Cap. Change Detection по методу главных компонент (PCA) может выполняться двумя способами:

- 1) разновременные изображения преобразуются по методу главных компонент, затем производится вычитание значений яркости соответствующих пикселей главных компонент;
- 2) разновременные изображения объединяются в один файл, который преобразуется при помощи PCA, затем анализируются меньшие компоненты, содержащие изменения.

При использовании метода главных компонент происходит исключение избыточной информации в изображениях. К недостаткам метода можно отнести сложность интерпретации данных.

Третья группа алгоритмов – методы Post-classification Comparison, Spectral-temporal Combined Analysis, EM Detection, Hybrid Change Detection, Artificial Neural Networks (ANN).

Метод Post-classification Comparison заключается в поэлементном сравнении разновременных классифицированных изображений. Данный метод устойчив к влиянию атмосферных искажений и позволяет получать информацию об изменениях в интересующих объектах. К недостаткам можно отнести зависимость от качества классификации.

Метод Artificial Neural Networks (ANN) использует при классификации нейронную сеть.

Нейронные сети – метод Artificial Neural Networks (ANN) использует при классификации нейронную сеть. В этом методе можно использовать несколько признаков при обучении нейронной сети, заключается в подборе весовых коэффициентов. Недостатком метода является длительный итеративный процесс обучения.

Метод, использующий ГИС, служит основой для анализа разновременных изображений и фактически является основой для обновления информации по разновременным снимкам. Это весьма перспективный метод, позволяющий наиболее эффективно использовать новую информацию, полученную по снимкам.

Визуальный метод до сих пор остается одним из основных методов анализа разновременных снимков и выявления изменений по снимкам. Это связано с большим количеством «мешающих» факторов, затрудняющих автоматический анализ снимков, а также сложностью формализации задачи «выявления изменений, произошедших на местности, по изображениям местности».

1.7. Области применения методов и технологий распознавания объектов по их изображению

Отметим некоторые направления и перспективы развития методов автоматизированного дешифрирования снимков.

Задача автоматического дешифрирования – одна из важных задач в создании методов искусственного интеллекта. С одной стороны, дешифрирование – это способ определить по изображениям свойства объекта, он аналогичен зрению, однако, с другой стороны, – автоматическое дешифрирование позволяет анализировать большее количество информации, чем при наблюдении объекта оператором-дешифровщиком и, соответственно, является новым инструментом для изучения объектов. Это расширение возможностей заключается в расширении спектра (многоспектральные снимки), а также в возможности использовать множество дополнительных данных, численных измерений. Казалось бы, что для однозначного распознавания объекта есть все необходимое, однако до сих пор автоматическое распознавание не может конкурировать с визуальным. Конечно есть мно-

жество примеров, когда автоматическое распознавание намного точнее и производительнее, но до сих пор не решена задача автоматического видения объекта, как это реализовано у человека или животных.

Таким образом, одно из направлений развития автоматического дешифрирования (распознавания образов по их изображениям) – создание эффективного зрения роботов. Однако существуют и более прозаические задачи развития автоматических методов дешифрирования.

Так, например, основная задача дешифрирования данных дистанционного зондирования состоит в распознавании объектов и их свойств, с использованием различных методов и алгоритмов.

В этом направлении достигнуты большие практические успехи, но в то же время существует множество нерешенных задач. Это связано с разнообразием явлений, объектов, а также факторов, влияющих на источник получения информации (электромагнитное излучение, отраженное или излучаемое исследуемым объектом).

Отметим лишь некоторые направления развития методов и алгоритмов автоматизированного и автоматического дешифрирования.

1. Разработка методов оптимального выбора дешифровочных признаков объектов и его свойств на основе данных дистанционного зондирования (определение методов и видов съемки объектов, сбор необходимой дополнительной информации, определение условий съемки).

2. Создание эталонов для различных классов, специализированных для решения задач определенного типа (например, сельского хозяйства, лесного хозяйства, исследования ледников ледовых пространств, городских территорий, инженерных территорий). Создание банков эталонных данных для различных отраслей.

3. Совершенствование методов распознавания по эталонам.

4. Разработка новых методов кратномасштабного анализа, в том числе с использованием различных типов вейвлет-разложений.

5. Совершенствование алгоритмов методов нейронных сетей.

6. Разработка новых моделей описания объектов с использованием пространственных и энергетических высокоточных измерений.

В связи с развитием средств получения информации (от космических снимков высокого разрешения до беспилотных летательных аппаратов),

а также средств, позволяющих повышать точность базовых измерений, с одной стороны, и совершенствование алгоритмов и вычислительной техники, с другой, можно надеяться на появление в ближайшее время технологий автоматического дешифрирования широкого класса объектов. Это, несомненно, приведет к принципиально новому развитию технологии решения разнообразных практических задач и повысит эффективность управления территориями и другими пространственно-распределенными процессами.

2. ЛАБОРАТОРНЫЕ РАБОТЫ

2.1. Лабораторная работа № 1

Получение базовых навыков работы в программе ERDAS Imagine 2010

Задание 1. Загрузить во Вьюер растровый файл IMAGINE и освоить управление каналами.

Запустите программу **ERDAS Imagine 2010**. Открыть файл можно несколькими способами. Можно нажать кнопку **Open** на панели быстрого доступа главного меню **IMAGINE** или сочетание клавиш **Ctrl+O** (рис. 10).




Рис. 10. Открытие файла с панели быстрого доступа

Также файл можно открыть, используя панель **Contents (Содержимое)**, щелкнув правой кнопкой мыши на «**2D View#1**» (рис. 11). Появится список категорий файлов, с которыми можно работать в ERDAS Imagine. Выберите **Open Raster Layer...** .




Рис. 11. Открытие файла с помощью панели **Contents**

После выбора категории появляется диалог **Select Layer to Add** для загрузки файлов этой категории во Вьюер. Выберите нужный файл (в соответствии с вариантом в данных указаниях для примера будет использоваться файл с именем **1.img**) в списке, но пока не нажимайте кнопку ОК. Узнать основные характеристики файла можно, щелкнув правой кнопкой мыши по имени файла в списке и открыв информационную табличку **Properties** (Свойства). Откройте вкладку **Raster Options** (Опции загрузки растра) (рис. 12).




Рис. 12. Опции загрузки растра

При помощи этой вкладки можно выбрать комбинацию спектральных каналов для отображения и прочие параметры открытия файла.

Ниже кратко описаны параметры отображения растра.



Orient Image to Map System (Ориентировать изображение согласно модели привязки) – этот параметр доступен, если в файле сохранена геометрическая калибровка (если ее нет, то параметр не доступен).

Если флажок включен, изображение выводится на экран с учетом калибровочной информации. В противном случае калибровка игнорируется.

Clear display (Очистка экрана) – если во время загрузки нового изображения флажок включен, текущее изображение, отображаемое во Вьюере, удаляется. Отключите данный параметр, если хотите наложить изображения друг на друга.

Fit to Frame (Вписать в окно) – если этот флажок включен, изображение увеличивается или уменьшается таким образом, чтобы оно целиком поместилось во Вьюер.

Data Scaling (Масштабирование значений пикселей) – данный параметр используется для приведения значений пикселей к стандартному диапазону (например, числа с плавающей точкой – к диапазону 0–255).

Zoom by (Изменение масштаба на) – если флажок **Fit to Frame** отключен, то вы можете ввести в этом поле коэффициент увеличения изображения.

Set View Extent (Установка области (экстента) отображения) – позволяет определять координаты верхнего левого и нижнего правого углов части изображения, выводимой на экран.

No stretch (Не растягивать) – включите данный флажок, чтобы визуализировать изображение без применения функции растяжки контраста.

Background Transparent (Прозрачный фон) – включите данный флажок для того, чтобы сделать фон прозрачным. Фоновые классы тематических слоев становятся прозрачными автоматически.

Using <Resampling> – использование указанного метода пересчета при масштабировании изображения. Выберите один из следующих методов: метод ближайшего соседа, метод билинейной интерполяции, метод кубической свертки.

Включите флажок **Fit to Frame** (вписать снимок в окно Вьюера) и нажмите **ОК**. Загруженное во Вьюер растровое изображение автоматически будет отображено с растяжкой гистограммы в два стандартных отклонения. При использовании опции **No Stretch** (Нет растяжки гистограммы) можно отобразить данные без изменения контраста, но в таком случае снимок обычно труднее интерпретировать. На рис. 13 показан пример загруженного файла при указанных выше параметрах.

Изменить комбинацию каналов уже загруженного растра можно, открыв вкладку **Multispectral** в главном меню **IMAGINE** при помощи вкладки **Bands** (рис. 14).

Вкладка **Multispectral** позволяет выбрать из списков съемочную систему и комбинацию спектральных каналов для отображения (как установленную в списке, так и произвольную) (рис. 15).




Рис. 13. Загруженный растр




Рис. 14. Вкладка управления каналами




Рис. 15. Выбор съемочной системы и отображаемых каналов

Измените комбинацию спектральных каналов синтеза изображения разными способами и оцените результаты.

Задание 2. Открыть два Вьюера, загрузить данные в каждый Вьюер, связать Вьюеры, использовать курсор запросов (**Inquire cursor**) для получения информации о пикселях связанных данных.

Откройте два Вьюера. Система обычно (по умолчанию) открывает один Вьюер при запуске, поэтому для открытия второго воспользуйтесь кнопкой **Add Views** на вкладке **Home** главного меню **IMAGINE** (рис. 16).




Рис. 16. Добавление Вьюера

Выпадающее меню (рис. 17) позволяет создавать новые Вьюеры разных типов, управлять их расположением, а также создавать Лупу (**Create Magnifier**) и Вьюер общего обзора (**Create Overview**). Выберите **Create New 2D View**.




Рис. 17. Управление Вьюерами

При активном Вьюере 1 щелкните кнопку **Open Layer**. Выберите файл, используемый в предыдущем задании. На вкладке **Raster Options** (Опции загрузки растра) установите комбинацию спектральных каналов синтеза изображения (**Layers to Colors**) **RGB=4,3,2**.

Для установки номера канала воспользуйтесь стрелками прокрутки справа от значения. Включите флажок **Fit to Frame** (Вписать изображение в окно Вьюера). Нажмите **OK**.

Сделайте то же самое во Вьюере 2. Когда во втором Вьюере появится снимок, во вкладке **Multispectral** выберите съемочную систему **IKONOS Multispectral** и комбинацию спектральных каналов **True Color** (Естественные цвета).

Вызовите **Контекстное меню** (Quickview Menu), поместив указатель мыши внутри Вьюера и нажав правую кнопку мыши.

Спуститесь вниз по контекстному меню (рис. 18) до пункта **Zoom Options** (Масштабирование) и в открывшемся подменю выберите **Rotate and Magnify Area** (Повернуть и увеличить область).




Рис. 18. Масштабирование

Появится рамка для выбора области изображения, которую нужно увеличить. Дважды щелкните первой (левой) кнопкой мыши внутри рамки для увеличения изображения.

Свяжите два Вьюера географически. Для этого в **контекстном меню** Вьюера 1 выберите **Spatial Link/Unlink**. Перед вами появится окно сообщения, а курсор примет форму значка связывания (рис. 19).




Рис. 19. Пространственное связывание Вьюеров

Поместите курсор во второй Вьюер и щелкните первой кнопкой мыши. Теперь Вьюер 1 географически связан с Вьюером 2 (рис. 20).




Рис. 20. Связанные Вьюеры

В контекстном меню Вьюера 2 выберите пункт **Inquire Cursor** (Курсор запросов). Теперь у вас есть связанный курсор в двух Вьюерах. В этот момент на дисплее отображается информация о пикселях изображения из Вьюера 2. Для получения информации о пикселях Вьюера 1 (рис. 21) щелкните кнопку **Goto Next Linked Viewer** (Перейти к следующему связанному Вьюеру) в правом верхнем углу диалога Inquire Cursor.




Рис. 21. Информация о пикселях

Проанализируйте полученные данные.

Задание 3. Загрузить два слоя в один Вьюер, использовать инструменты **Swipe** (Шторка) и **Blend** (Изменение прозрачности слоев).

Во Вьюере откройте нужное изображение, во вкладке **Multispectral** выберите съемочную систему **IKONOS Multispectral** и комбинацию спектральных каналов **True Color** (Естественные цвета).

Чтобы открыть поверх еще один растровый слой в том же самом окне Вьюера, нужно сбросить флажок **Clear Display** (очистить Вьюер перед загрузкой) на вкладке **Raster Options** диалога **Open Layer**. Выберите тот же файл как новый слой, указав только один 4-й канал для отображения. Установите опции, указанные на рис. 22 и нажмите **OK**.




Рис. 22. Загрузка одного канала изображения

Теперь установите порядок слоев при помощи панели **Contents** (Содержимое). Чтобы поменять слои местами, щелкните левой кнопкой мыши по слою, и, не отпуская кнопки, перетащите его в новое место (рис. 23).




Рис. 23. Управление слоями

Поместите многоканальное изображение поверх одноканального.

Для использования инструментария совместного просмотра слоев необходимо воспользоваться опцией **View** на вкладке **Home** главного меню **IMAGINE** (рис. 24). выпадающее меню предлагает инструменты **Swipe** (Шторка), **Blend** (Изменение прозрачности слоев) и **Flicker** (Мерцание).




Рис. 24. Инструментарий совместного просмотра слоев

Управление Шторкой осуществляется с помощью шкалы с бегунком. Используя этот бегунок, вы можете закрыть верхним снимком весь нижний или, наоборот, оставить изображения перекрывающимися лишь частично (рис. 25).




Рис. 25. Управление Шторкой

Измените направление движения шторки с вертикального (**Vertical**) на горизонтальное (**Horizontal**). Во время работы с инструментом Шторка масштаб изображения может быть изменен – попробуйте использовать инструмент **Zoom**. Когда закончите, нажмите **Cancel** (Отменить).

Выберите **Blend** (Управление прозрачностью). Здесь с помощью шкалы с бегунком можно изменять степень прозрачности верхнего слоя. На-

жмите **Auto Mode** (Автоматический режим), и два «верхних» изображения будут постепенно переходить друг в друга в автоматическом режиме. Выключите автоматический режим и верните бегунок к значению 100 %. Нажмите **OK**.

Самостоятельно ознакомьтесь с работой инструмента **Flicker** (Мерцание).

На панели **Contents** (Содержимое) щелкните правой кнопкой мыши по одноканальному изображению и выберите **Remove Layer** – этим вы удалите из Вьюера выбранный слой.

Задание 4. Вырезать часть изображения.

В ERDAS Imagine есть несколько путей для задания границ вырезаемого фрагмента изображения:

- ввести заранее известные координаты границ вырезки в диалоге **Subset**;
- графически очертить прямоугольник фрагмента изображения, используя **Inquire Box**;
- оцифровать (digitize) во Вьюере границы области интереса (**AOI**) произвольной формы, по которым будет вырезан фрагмент.

В данном задании используется 3-й метод.

После выполнения предыдущего задания во Вьюере остался открытым рабочий файл съемочной системы **IKONOS Multispectral** с комбинацией спектральных каналов **True Color** (Естественные цвета).

На вкладке **Drawing** (Рисование) главного меню **IMAGINE** (рис. 26) из набора инструментов **Insert Geometry** (Вставить геометрию) выберите инструмент **Polygon** (Создать полигон).




Рис. 26. Выбор инструмента

Вернитесь в окно Вьюера и очертите область интереса (**АОИ**), которая приблизительно соответствует границам интересующего вас объекта (рис. 27). Обратите внимание, что на панели **Contents** (Содержимое) в списке слоев появился новый слой области интереса (**АОИ**).




Рис. 27. Задание границ полигона

Используйте правую кнопку мыши для вызова Контекстного меню и выберите из него **Inquire Box** (Рамка запроса). В появившемся диалоге выберите **Fit to AOI** (Вписать в область интереса).

В главном меню **IMAGINE** (рис. 28) выберите вкладку **Raster/Subset & Chip/Create Subset Image** (Растр/Вырезать & Фрагмент/Создать фрагмент изображения).




Рис. 28. Выбор инструмента

Выберите рабочий файл **1.img** как входной файл (**Input file**). Выберите директорию выходного файла (**Output file**) назовите его **1_subset.img**. Нажмите на кнопку **From Inquire Box** (Из Рамки запросов) и вы увидите, что значения координат вырезаемого фрагмента изменятся.

Нажмите **Ignore Zero in Output Stats** (Игнорировать нули в выходной статистике). Укажите **1, 3, 4** спектральные каналы в строке **Select Layers** (Выбрать слои). Выбрав только три слоя фрагмента изображения, вы, конечно, уменьшите его размер и сможете использовать только эти слои при дальнейшем анализе фрагмента изображения. Нажмите на кнопку **AOI** (Область интереса) и в появившемся окне **Choose AOI** (Выбор области интереса) включите опцию **Viewer** (Из Вьюера). Нажмите **OK** в окне выбора области интереса. Чтобы запустить процесс, нажмите **OK** в диалоге **Subset** (рис. 29).




Рис. 29. Пример заполнения диалога **Subset**

Откройте в существующем Вьюере созданный Вами в данном упражнении растровый файл **1subset.img** поверх **1.img**, чтобы убедиться, что фрагмент был вырезан корректно. Через контекстное меню панели **Contents** (Содержимое) включите флажок **Background Transparent** (Прозрачный фон) для того, чтобы сделать для снимка **1subset.img** фон прозрачным (рис. 30).




Рис. 30. Результат наложения вырезанного фрагмента на исходное изображение

Контрольные вопросы по лабораторной работе № 1

1. Как определить, сколько строк, столбцов и спектральных каналов имеет снимок?
2. Как изменить комбинацию каналов изображения?
3. Сколько каналов может быть отображено одновременно в рабочем окне?
4. Что такое область интереса?
5. Как будет выглядеть фрагмент изображения, если при его создании использовалась Область интереса, но не были указаны размеры и положение рамки запросов к размерам и положению области интереса?
6. Если необходимо вырезать фрагмент изображения в пределах векторного покрытия, чем будет отличаться процесс вырезки фрагмента?

2.2. Лабораторная работа № 2

Яркостные преобразования изображений

Задание 1. Регулировка контрастирования.

При выводе изображения на экран в ERDAS IMAGINE по умолчанию применяется линейное усиление контраста («растягивание» яркостной

гистограммы); в дальнейшем вы можете улучшать отображение и другими способами.

Файл **1.img** должен быть открыт во Вьюере.

Простое преобразование контраста

Через контекстное меню панели **Contents** (Содержимое) выберите **Brightness/Contrast** (Яркость/Контраст). Откроется диалог **Contrast Tool** (Инструмент работы с контрастом) (рис. 31).




Рис. 31. Управление контрастом

В диалоге **Contrast Tool** измените яркость и/или контрастность изображения. Нажмите кнопку **Apply** (Применить).

Изображение во Вьюере будет перерисовано с новыми значениями яркости/контраста.

В диалоге **Contrast Tool** нажмите кнопки **Reset** и **Apply**, чтобы отменить сделанные изменения.

В диалоге **Contrast Tool** нажмите кнопку **Close**.

Кусочно-линейное преобразование контраста

Через контекстное меню панели **Contents** (Содержимое) выберите **Piecewise Contrast** (Кусочно-линейное преобразование контраста). Откро-

ется диалог **Contrast Tool** для кусочно-линейного преобразования контраста (рис. 32).




Рис. 32. Кусочно-линейное преобразование контраста

NB

Инструменты работы с контрастом позволяют улучшить видимость отдельных участков изображения с помощью разбиения диапазона спектральных яркостей на три интервала: низкие, средние и высокие значения. Вы можете изменить яркость или контрастность любой части изображения для одной цветовой компоненты за один раз. Этот метод очень полезен при улучшении темных областей изображения или областей с низкой контрастностью.

Значение яркости каждого интервала представляет собой среднюю точку этого интервала. Значение контрастности каждого интервала представляет собой отношение преобразованного интервала к исходному.

По мере перемещения одного регулятора, второй автоматически регулируется таким образом, чтобы в таблице перекодировки не было разрывов между интервалами. Этот инструмент предполагает, что в каждом изображении всегда есть пиксели со значениями от 0 до 255. Вы можете управлять процентом пикселей в каждом интервале, но не можете устранить какой-либо интервал значений.

Поместите курсор на изображении во Вьюере и, щелкнув правой кнопкой мыши, в контекстном меню выберите пункт **Inquire Cursor**.

Откроется диалог **Inquire Cursor** и во Вьюере появится курсор запросов.

Переместите перекрестие курсора запросов па озеро. Перемещайте курсор запросов по поверхности воды, не выпуская из виду значения в таблице для синей цветовой компоненты, которые отображаются в диалоге **Inquire Cursor**.

Это даст вам представление об интервале спектральных яркостей, соответствующих водной поверхности. Вы можете растянуть этот интервал яркостей, чтобы выявить больше деталей на волной поверхности.

В диалоге **Contrast Tool**, в секции **Select Color** (Выбор цвета), выберите **Blue** (Синий).

В разделе **Range Specifications** (Определение интервала) установите границы нижнюю интервала (Low) равными новым значениям.

Переместите регулятор яркости (верхний) на значение 50.

Нажмите кнопку **Apply** в диалоге **Contrast Tool**.

Теперь область воды имеет большую контрастность.

В диалоге **Contrast Tool** нажмите кнопку **Reset** и затем кнопку **Apply**, чтобы вернуть изображение к исходным значениям яркости и контрастности.

Нажмите кнопку **Close** в диалогах **Contrast Tool** и **Inquire Cursor**.

Управление гистограммой

Через контекстное меню панели **Contents** (Содержимое) выберите **Breakpoints** (Точки перегиба). Откроется диалог **Breakpoints Editor** для редактирования гистограмм (рис. 33). Щелкните ниспадающий список в верхней части диалога **Breakpoint Editor** и выберите **RGB** (посмотрите, какие еще есть варианты).

Все три гистограммы отобразятся в окне Breakpoint Editor.

Поэкспериментируйте, передвигая точки перегиба графика таблицы перекодировки для разных цветовых компонент (**Red, Green, Blue**).

Обратите внимание, что преобразования можно применять как к отображению на экране (**LUT**), так и к файлу (**Image File**) или области интереса (**AOI**).




Рис. 33. Диалог редактирования гистограмм

Нажмите кнопку **Apply All** (Применить все) в диалоге **Breakpoint Editor**, чтобы увидеть результаты ваших изменений на изображении.

Чтобы отменить редактирование, которое вы только что сделали, можно нажать кнопку **Undo** на панели быстрого доступа главного меню **IMAGINE** или сочетание клавиш **Ctrl+Z** (рис. 34).




Рис. 34. Отмена действий

Общее управление контрастностью

Как уже было показано выше, увеличить информативность изображения можно различными путями, применив разнообразные функции преобразования контраста. Выбрать способ преобразования также можно, открыв вкладку **Multispectral** в главном меню **IMAGINE** при помощи

вкладки **General Contrast** (Общее управление контрастностью). В выпадающем меню представлены как уже рассмотренные способы, так и многие другие (рис. 35). Выберите **General Contrast** (Общее управление контрастностью).




Рис. 35. Общее управление контрастностью

В выпадающем меню диалога **Contrast Adjust** (Регулировка контрастности) представлены различные методы преобразования контраста. Выберите метод изменения контраста **Histogram Equalization** (Выравнивание гистограммы). Заметьте, что еще до применения функции к изображению во Вьюере результат этого преобразования показывается на предварительном изображении (**preview**) (рис. 36). Нажмите **Apply** (Применить), и преобразование контраста будет применено к изображению во Вьюере.

Выравнивание гистограммы перераспределяет данные таким образом, что приблизительно одно и то же количество пикселей изображения будет попадать в каждый интервал гистограммы (в одинаковые диапазоны значений).

Отмените редактирование, которое вы только что сделали, нажав кнопку **Undo** на панели быстрого доступа главного меню **IMAGINE** или сочетание клавиш **Ctrl+Z**.

Исследуйте оставшиеся методы преобразования контраста.




Рис. 36. Регулировка контрастности

Задание 2. Улучшение пространственного разрешения изображения.

Откройте два Вьюера. Система обычно (по умолчанию) открывает один Вьюер при запуске, поэтому для открытия второго воспользуйтесь кнопкой **Add Views** на вкладке **Home** главного меню **IMAGINE** (рис. 37).




Рис. 37. Добавление Вьюера

В первом Вьюере откройте многоканальное изображение (в примере 1.img), во втором – панхроматическое (в примере po_201905_pan_0000000.img, покрывающее большую территорию). Свяжите Вьюеры пространственно. Можно сделать так, как было описано ранее либо воспользоваться кнопкой **Link All Views** на вкладке **Home** главного меню **IMAGINE** (рис. 38).

В результате слияния этих двух снимков мы получим изображение с разрешением панхроматического снимка и спектральными характеристиками многозонального снимка.




Рис. 38. Исходные снимки

Для каждого Вьюера щелкните кнопку **Layer Info** на вкладке **Home** главного меню **IMAGINE** (рис. 39).




Рис. 39. Вызов информации

Сравните информацию о снимках (рис. 40). Закройте информационные окна.




Рис. 40. Сравнение информации

Нажмите кнопку **Pan Sharpen** (Повышение пространственного разрешения) на вкладке **Raster** главного меню **IMAGINE** и выберите **Resolution Merge** (Слияние изображений) в выпадающем меню (рис. 41).




Рис. 41. Выбор технологии пространственного улучшения

Выберите входной файл с высоким разрешением, как **High Resolution Input File** (в данном примере **po_201905_pan_0000000.img**). Как многозональный входной файл (**Multispectral Input File**) используйте **1.img**. Введите имя выходного файла **Output file** (в данном примере – **pansharp.img**)

В секции **Method** (Метод слияния) выберите **Brovvey Transform** (преобразование Бровея). В секции **Resampling Technique** (Алгоритм пере-

дискретизации) выберите **Bilinear Interpolation** (Билинейная интерполяция). В секции **Output Options** включите флажок **Ignore Zero in Stats** (Игнорировать нулевые данные при расчете статистики) (рис. 42).




Рис. 42. Выбор метода и параметров пространственного улучшения



Преобразование Бровея – один из методов слияния изображений с различным разрешением (resolution merge), в котором произведение яркостей панхроматического и многозонального снимков делится на сумму яркостей многозонального; отличается хорошей цветопередачей и стабильностью результатов.

В **IMAGINE** хранятся отдельные пространственные модели для каждой из функций **Image Interpreter** (Интерпретатора изображений). Для того, чтобы ознакомиться с моделью **Resolution Merge**, нажмите кнопку **View** (рис. 43).




Рис. 43. Модель слияния снимков с разным разрешением

Просмотрев модель слияния снимков с разным разрешением, закройте окно **Modeler** (Создание и работа с графическими моделями). Запустите процесс слияния снимков, нажав **OK** в диалоге **Resolution Merge**.

Следите за выполнением задания по строке состояния процесса (рис. 44).

Process List					
Row	Process Title	File	State	Progress	
1	ewkspace				
2	MODELMAKER				
3	Modeler - running model: mergeall.pmdl		Processing points	15%	

Рис. 44. Строка состояния процесса

После окончания выполнения задания можно закрыть все диалоги.

В первом Вьюере оставьте изображение **1.img.**, а во второй Вьюер загрузите изображение **pansharp.img** (рис. 45).




Рис. 45. Результат слияния снимков с разным разрешением

Оцените результат визуально и сравните информацию о снимках при помощи кнопки **Layer Info**.

Экспериментально исследуйте остальные технологии и методы слияния снимков с разным пространственным разрешением.

Задание 3. Работа с преобразованными изображениями.

Сделайте преобразование исходного снимка либо с улучшенным пространственным разрешением методами главных компонент и/или Tasseled Cap (рис. 46).




Рис. 46. Выбор метода преобразования

Сравните результаты и сделайте выводы.

Задание 4. Работа с индексными изображениями.

Получите вегетационные индексы, воспользовавшись предложенными программой (рис. 47).




Рис. 47. Выбор функции расчета индексов

При помощи функции Model Maker (рис. 48) вычислите индексы $NDWI_2$, $ARVI$, $GEMI$.



Рис. 48. Выбор функции Model Maker

Проанализируйте полученные результаты и сделайте выводы.

Контрольные вопросы по лабораторной работе № 2

1. Что такое значение Look Up Table?
2. Почему нет значений LUT для некоторых каналов?
3. Какие алгоритмы могут помочь сгладить шумы?
4. Какие алгоритмы могут подчеркнуть границы объектов?
5. Как узнать пространственное разрешение снимка?
6. Почему некоторые файлы загружаются во Вьюер как одноканальное изображение, тогда как другие представляется в виде синтезированного изображения из трех слоев?
7. Какие преимущества есть у полученных изображений по сравнению с исходным снимком?

2.3. Лабораторная работа № 3

Автономная классификация

Задание 1. На примере учебных данных выполнить безэталонную классификацию, используя метод автономной классификации ISODATA.

Загрузите во Вьюер изображение с именем **1.img**, вписав его в окно Вьюера (**Fit to Frame**).

В главном меню **IMAGINE** выберите вкладки **Raster/Unsupervised**. В выпадающем меню выберите пункт **Unsupervised Classification** (Автономная классификация) (рис. 49).




Рис. 49. Выбор метода классификации

Появится диалог **Unsupervised Classification (ISODATA)**.

Выберите имя входного файла (Input Raster File) **1.img**. Для выходного тематического изображения (**Output Cluster Layer**) введите **1_unclass_15.img**. Для выходного файла эталонов (**Output Signature Set**) введите **1_unclass_15.sig**.

Задайте желаемое число классов (**Number of Classes**) – **15**. Щелкните кнопку **Initializing Options** (Начальные параметры). Выберите **Principal Axis** (Ось первой главной компоненты), чтобы устранить влияние корреляции данных в разных спектральных зонах. Установите значение **2** в строке **Standard Deviations** (Множитель стандартного отклонения). Нажмите **Close** (Заккрыть).

Нажмите кнопку **Color Scheme Options** (Выбор цветовой схемы). Этот диалог позволит раскрасить классы не в градациях серого, а в цветах, близких к исходному изображению. Выберите **Approximate True Color**. Закройте диалог.

Задайте число итераций (**Maximum Iterations**) **25**. При задании такого большого числа итераций, процесс займет несколько больше времени, но зато это не ограничит процесс по сходимости.

Порог сходимости (**Convergence Threshold**) – это количество пикселей (в процентах), которые не изменяют своей принадлежности к классу при переходе к следующей итерации. Установка значения 0.950 значит, что если 95 % пикселей изображения не изменили принадлежности к классу при переходе к следующей итерации, то процесс можно завершить. Оставьте значение **Skip Factors** (Коэффициенты прореживания), предложенное по умолчанию (рис. 50).




Рис. 50. Выбор параметров

Нажмите кнопку **ОК**. На экране появится диалог состояния процесса, показывающий номер выполняемой итерации, и достигнутый порог сходимости.

Откройте во Вьюере получившееся изображение **1_unclass_15.img**.

Щелкните кнопку **Layer Info** (Информация о слое). Скажите, какой тип данных загружен во Вьюер: тематический растр или непрерывный? Из скольких слоев состоит данное изображение?

Задание 2. Назначение цветов, имен и дополнительных характеристик полученным классам.

Загрузить во Вьюер изображение с именем **1_unclass_15.img**, вписав его в окно Вьюера (**Fit to Frame**). Это изображение должно быть создано в предыдущем задании и может быть уже загружено во Вьюер.

В главном меню **IMAGINE** выберите вкладки **Table/Show Attributes/Show Attributes** (Таблица/Показать Атрибуты) (рис. 51).




Рис. 51. Выбор инструмента Атрибуты

На панели вкладки **Table** нажмите кнопку **Column Properties** (Свойства столбцов), рис. 52.




Рис. 52. Свойства столбцов

Измените порядок следования столбцов в таблице атрибутов, выбрав в списке **Class_Names** (Имя класса) и нажав кнопку **Top** (Первый в списке). Измените Отображаемую ширину столбца (**Display Width**) со 100 на **10**.

Теперь выберите столбец **Color** (Цвет) и нажмите кнопку **Up** (Вверх, выше), чтобы он переместился на вторую позицию в списке. Обратите внимание, что опции **Editable** (Редактировать) и **Show RGB** (Показать значения RGB) сейчас доступны.

Теперь создайте столбец для временного переопределения цветов классов. Для этого нажмите кнопку **New** (Новый столбец). Введите название (**Title**) – **Backup Color** (Сохраненный цвет). Нажмите кнопку **Up** (Вверх), чтобы поместить этот столбец на третье место в таблице. В списке **Type** (Тип) выберите строку **Color** (Цвет) (рис. 53).




Рис. 53. Редактирование свойств столбцов

Нажмите **OK**, чтобы закрыть диалог свойств столбцов (**Column Properties**).

Теперь нужно скопировать цвета из 2-й колонки цвета классов (**Color**) в третью колонку дубль-цвета (**Backup Color**). Этот шаг нужен для того, чтобы всегда оставалась возможность возвращения к исходному цвету классов, несмотря на любые изменения цвета в ходе работы. В редакторе атрибутов (**Attribute Editor**) выберите колонку цвет (**Color**). Затем в выпадающем по стрелочке меню нажмите **Copy** (Копировать). Затем выберите колонку дубль-цвета (**Backup color**) и нажмите на **Paste** (Вставить) (рис. 54).

Измените размер и местоположение диалога редактора атрибутов так, чтобы он не закрывал Вьюер с классифицированным изображением, а находился рядом с ним. Начните редактировать значения в столбцах **Class_Names** и **Color**. Те изменения цветов, которые вы вносите, не изменят оригинальное изображение до тех пор, пока вы не используете команду Сохранить.

Row	Class_Names	Color	Backup Color	Red	Green	Blue	Histogram	Opacity
0	Unclassified			0	0	0	2490	1
1	Class 1			96078	0.576471	0.666667	50136	1
2	Class 2			29412	0.439216	0.337255	18547	1
3	Class 3			27451	0.317647	0.227451	41204	1
4	Class 4				0.4902	0.266667	67963	1
5	Class 5				0.8235	0.729412	29892	1
6	Class 6				0.8627	0.309804	51094	1
7	Class 7				1	1	24438	1
8	Class 8				0.9216	0.419608	44606	1
9	Class 9				0.7059	0.858824	14940	1
10	Class 10				0.7059	0.466667	48199	1
11	Class 11				0.47059	0.466667	52661	1
12	Class 12				0.09804	0.447059	57520	1
13	Class 13				0.68627	0.447059	55617	1
14	Class 14				0.27451	0.447059	51152	1
15	Class 15				0.09804	0.447059	22151	1

Рис. 54. Создание резервного столбца цвета

Чтобы легче идентифицировать пиксели, принадлежащие к какому-либо классу, временно измените цвет этого класса. Щелкните по ячейке цвета для 1-го класса (Class 1) и выберите из палитры синий цвет. Это класс воды, и он выделен теперь на изображении синим цветом. Чтобы восстановить исходный цвет, воспользуйтесь командой **Edit/Copy (Paste)** из резервной колонки цвета. В поле имени 1-го класса введите **Water** (Вода).

Повторите этот процесс для остальных 14 классов. Вероятно, вы сможете распознать и подписать такие классы (рис. 55), учитывая, что в данном задании мы не ставим целью распознать конкретные типы растительности.

Row	Class_Names	Color	Backup Color	Red	Green	Blue	Histogram	Opacity
0	Unclassified			0	0	0	2490	1
1	Чистая вода			0.00392157	0.301961	0.47451	50136	1
2	Затененная вода			0.129412	0.439216	0.337255	18547	1
3	Лес (тени)			0.227451	0.317647	0.227451	41204	1
4	Лес			0.309804	0.34902	0.266667	67963	1
5	Дороги			0.309804	0.788235	0.729412	29892	1
6	Лес 2			0.4	0.368627	0.309804	51094	1
7	Строения			0.419608	1	1	24438	1
8	Растительность 1			0.509804	0.439216	0.419608	44606	1
9	Открытая почва			0.529412	0.847059	0.858824	14940	1
10	Растительность 2			0.588235	0.447059	0.466667	48199	1
11	Растительность 3			0.647059	0.466667	0.517647	52661	1
12	Растительность 4			0.709804	0.447059	0.509804	57520	1
13	Растительность 5			0.768627	0.447059	0.498039	55617	1
14	Растительность 6			0.827451	0.447059	0.486275	51152	1
15	Растительность 7			0.909804	0.447059	0.486275	22151	1

Рис. 55. Результат задания имен классов

Вполне возможно, что в вашей классификации есть смешанные или дублирующиеся классы. Их можно разделить и переобозначить позднее, используя иные методы.

Смешанный класс (confused class) – это класс, содержащий больше чем один тип объектов.

Когда вы присвоите имена всем 15 классам, сохраните изменения (**Save**), а затем закройте Редактор атрибутов.

Задание 3. Перекодировка тематических данных.

Загрузите в окно Вьюера изображение **1_unclass_15.img**, используя опцию **Fit to Frame** (Вписать изображение в окно Вьюера). Это изображение было создано и отредактировано в предыдущих заданиях и может быть уже загружено во Вьюер.

В главном меню **IMAGINE** выберите вкладки **Thematic/Recode** (Тематическая обработка/Перекодировать) (рис. 56).




Рис. 56. Вызов диалога перекодировки данных

На экране появится диалог **Recode** для загруженного во Вьюер растрового изображения. Измените размер окна так, чтобы можно было видеть все колонки. Теперь вы можете объединить некоторые классы в более общие группы. Для этого левой клавишей мыши с зажатой клавишей **Shift** выберите все классы, относящиеся к классам воды. В нижней части диалога введите значение **1** в поле **New Value** и нажмите **Change Selected Rows** (Изменить для выбранных строк). Такая операция позволит объединить выбранные классы в один общий класс – Вода. Повторите аналогичную операцию для залесенных территорий – Леса и Растительности. Введите значения новых классов (**New Class Values**). Закончив, нажмите **Apply** (Применить).

Во Вьюере появилась строка состояния процесса (процент выполнения задания). После завершения процесса изображение во Вьюере обновиться. Это преобразование перекодировки не сохраняется в исходный файл до тех пор, пока вы не используете команду Сохранить (Save). Сохраните измененное изображение как новый файл с именем **1_unclass_15_recode.img**, выбрав в главном меню **Save As/Top Layer As...** (Сохранить как/Верхний слой как...).

Теперь необходимо окончательно подобрать цвета для созданной растровой карты. Сначала заново загрузите файл **1_unclass_15_recode.img** во Вьюер. Определите цвет и окончательное название каждого класса.

Загрузите поверх полученного классифицированного изображения исходный снимок **1.img**. Используйте инструмент **Blend** (Шторка), чтобы проверить соответствие исходного снимка и полученной растровой карты.

Контрольные вопросы по лабораторной работе № 3

1. Сколько классов задается при классификации? Что представляет класс «0»?
2. Что такое порог сходимости?
3. Для чего используются средние значения эталонов?
4. Как влияет фактор прореживания на скорость и точность выполнения классификации?
5. Почему во время выполнения второй итерации порог сходимости равен нулю?
6. Почему классы созданного изображения имеют неяркие цвета?
7. Если установить значение Skip Factor равным 2, будет ли выходной классифицированный файл такого же размера, как и исходный?

2.4. Лабораторная работа № 4

Классификация с обучением

Задание 1. Создать набор эталонов.

Создать набор эталонов (иначе – «обучающей выборки») можно несколькими способами. В данном задании рассмотрим основные варианты.

1-й вариант – используя инструмент *AOI* (Область интереса) – **Полигон**.

Загрузите во Вьюер изображение с именем **1.img**, вписав его в окно Вьюера (**Fit to Frame**). Комбинацию каналов выбирать по своему усмотрению, учитывая предыдущие эксперименты.

В главном меню **IMAGINE** выберите вкладки **Raster/Supervised**. В выпадающем меню выберите пункт **Signature Editor** (Редактор эталонов) (рис. 57).




Рис. 57. Вызов редактора эталонов

Появится инструмент работы с эталонами **Signature Editor** (рис. 58), пока пустой.




Рис. 58. Редактор эталонов

В главном меню **IMAGINE** выберите вкладки **Drawing/Insert Geometry**, инструмент **Poligone** (рис. 59), определяющий границы в заданной области **AOI** (Область интереса).




Рис. 59. Выбор инструмента АОІ

С помощью появившегося инструментария, используя рабочие области (АОІ), вы сможете создать ваши эталоны. *Области могут быть любой формы, используем в данном задании произвольную.*

Внутри Вьюера визуальнo выберите часть озера, которую можно считать примером (эталонoм) водных объектов. Выберите кнопку **Polygon** из набора инструментов Рабочей области. Как только вы переместите курсор на изображение во Вьюере, обычный курсор превратится в крестообразный.

Установите курсор на центральную часть большого озера и начните оцифровывать полигон, щелкая левой кнопкой мыши. Каждый щелчок левой кнопки мыши будет соответствовать формирующей контур точке. Чтобы закончить оцифровку полигона, дважды щелкните левой кнопкой мыши (рис. 60).



Рис. 60. Создание полигона АОІ

Для использования в качестве эталона в классификации нужно выделить одну или несколько рабочих областей. Вы выделили пример водной поверхности. В редакторе эталонов (**Signature Editor**) выберите кнопку

 **Create New Signature(s) from AOI** (Создать новый эталон из рабочей области) или используйте пункт меню **Edit/Add** (Редактировать/Добавить). Таким образом, область снимка, выделенная с помощью **AOI**, и спектральные характеристики пикселей этой рабочей области будут добавлены в редактор эталонов. Задайте имя эталону (в данном примере – «Озеро» (рис. 61).




Рис. 61. Один эталон класса в редакторе

*2-й вариант – используя инструмент **AOI** (Область интереса) – **Выращивание**.*

Из набора инструментов работы с **Insert Geometry** выберите кнопку **Region Grow AOI** (Выращивание «из затравки») (рис. 62). Теперь, если вы переместите курсор на изображение во Вьюере, то увидите, что он имеет крестообразный вид. Переместите этот крестообразный курсор в центр одного из малых озер. Щелкните по клавише, чтобы запустить процесс «выращивания полигона из пикселя-затравки».




Рис. 62. Выбор инструмента «Выращивание»

Область, только что «выращенная из затравки», оказалась достаточно мала. Чтобы изменить параметры «затравки», вызовите диалог **Region Growing Properties** (рис. 63).




Рис. 63. Настройка параметров

Нажмите кнопку **Neighborhood** (Сосед) в окне Region Growing Properties.

Этот параметр определяет, что поиск будет осуществляться по четырем либо восьми соседним пикселям, выберите . Таким образом, в качестве смежных к исходному пикселей рассматриваются только пиксели, лежащие непосредственно выше, ниже, справа или слева от него.

Для того чтобы ограничить площадь области, необходимо включить параметр **Area** в секции **Geographic Constraints** (Географические ограничения). Это максимальное количество пикселей, которое может содержать область интереса.

Поле **Spectral Euclidean Distance** (Спектральное эвклидово расстояние) указывает, что пиксели, включаемые (принимаемые) в область интереса, должны находиться в пределах заданного спектрального расстояния от исходного пикселя.

Поскольку значение **Spectral Euclidean Distance** (Эвклидовое расстояние в пространстве спектральных характеристик) в диалоге Region Growing Properties (Свойства инструмента «Выращивание из затравки»)

по умолчанию равно 1, то и первоначальная область оказалась мала. Измените это значение на **15** (см. рис. 63) и нажмите кнопку **Redo** (Перестроить с новыми параметрами, используя тот же исходный пиксель в качестве начального).

После того, как с учетом нового значения эвклидового расстояния будет вычислен регион, вы увидите, как эта величина влияет на форму и размер региона. Изменяйте значение эвклидового расстояния и прочие параметры, проанализируйте произошедшие с регионом изменения (рис. 64).




Рис. 64. Влияние настройки параметров на выращенную область

Последний построенный вами регион (при оптимальных на ваш взгляд параметрах) будет использоваться как один из эталонов в классификации. В Редакторе эталонов (**Signature Editor**) выберите кнопку **Create New Signature** (Создать новый эталон). Это операция добавит информацию о спектральных характеристиках пикселов в пределах области интереса (**AOI**) в Редактор эталонов.

Вы добавили еще один класс водных поверхностей в Редактор эталонов – назовите его «**Маленькое озеро**» (рис. 65).




Рис. 65. Два эталона классов в редакторе

3-й вариант – используя пространство признаков *Feature Space*.



Одним из базовых понятий, использующихся в пакете ERDAS Imagine для описания характеристик выделяемых классов, является понятие **сигнатуры**. **Сигнатурой (спектральной сигнатурой)** пикселя называют соответствующий ему вектор значений пикселя по слоям (спектральным диапазонам). Под **сигнатурой класса** понимается вся совокупность типичных для данного класса n -мерных векторов.

Для построения пространства признаков выберите на вкладке **Raster/Supervised** функцию **Feature Space Image** (рис. 66).




Рис. 66. Вызов функции **Feature Space Image**

В открывшемся окне задайте имя изображения (**Input Raster Layer**) – **1.img**. В качестве корневого имени ПП-изображения (**Output Root Name**) можно использовать имя исходного (проверьте путь сохранения файлов).

Порядковые номера пары признаков, которой соответствует каждая проективная плоскость, указываются в имени файла. В именах файлов номер первого канала соответствует оси абсцисс, второго – оси ординат. В группе кнопок **Level Slice** установите **Color**, поставьте галочку напротив режима **Output to Viewer** (рис. 67).




Рис. 67. Окно параметров создания пространства признаков

Нажмите **ОК**, чтобы запустить процесс построения. После завершения все проекции пространства признаков по парам каналов будут выведены на экран (каждое в своем окне) (рис. 68).

Относительное количество точек с конкретной парой значений признаков отображается цветом от красного к фиолетовому в порядке убывания. Красные пятна, таким образом, соответствуют локальным максимумам многомерной гистограммы изображения.

С точки зрения общей информативности для классификации лучше всего выбрать пары признаков с наиболее широкими диаграммами рассеяния и наибольшим количеством локальных максимумов (красных или желто-оранжевых пятен на цветном ПП-изображении). Если эти моды соответствуют каким-то тематическим классам, то такие классы будут выделяться наиболее надежно. Проанализируйте с этой точки зрения результаты. В данном примере указанным требованиям более всего отвечает пара 2-го и 4-го каналов, она и будет использоваться далее.




Рис. 68. Результат построения проекций пространства признаков

Для того чтобы связать исходное изображение с выбранной проекцией пространства признаков, необходимо в окне Редактора эталонов (**Signature Editor**) выбрать из меню **Feature/View/Linked Cursors** (рис. 69).




Рис. 69. Связывание исходного и ПП-изображения

Укажите номер ПП-вьюера и нажмите **Link**. На изображении появится перекрестье, которое будет перемещаться одновременно с перекрестьем в ПП-вьюере и показывать положение пикселя в проективной плоскости пространства признаков. Внизу в ПП-вьюере будут показываться значения координат точки (пара значений признаков).

Если в данном примере навести курсор на изображение большого озера, то в ПП-вьюере курсор попадет на один из локальных максимумов (рис. 70).




Рис. 70. Соответствие исходного и ПП-изображения

Поэкспериментируйте и попробуйте найти соответствия прочим локальным максимумам.

Для создания эталона в пространстве признаков вызовите инструмент кнопкой  и выделите интересующую область в ПП-вьюере (рис. 71).




Рис. 71. Создание **AOI** в пространстве признаков

Добавьте эталон в редактор. После этого выберите в редакторе функцию меню **Feature/Statistics** для подсчета статистических характеристик сигнатуры.

Чтобы посмотреть, куда попадает сформированная сигнатура на изображении, выберите в меню редактора сигнатур функцию **Feature/Masking/Feature Space to Image**. Нажмите **Apply**. Пиксели, которые попадают по всем значениям внутрь выбранной Вами области в ПП-вьюере, будут подсвечены на изображении ее цветом. На рис. 72 показан результат построения сигнатуры в признаковом пространстве для данного изображения. Анализ показывает, что выбранный локальный максимум соответствует объектам древесной растительности.



Рис. 72. Результат построения эталона в пространстве признаков

Задайте имя эталону (в данном примере «Древесная растительность») (рис. 73).




Рис. 73. Три эталона классов в редакторе

Повторите процесс создания эталонов любыми из указанных способов и добавьте сигнатуры, наиболее полно представляющие различные типы ландшафта и антропогенных объектов, присутствующих на изображении. В меню Редактора эталонов выберите **File/Save** (Файл/Сохранить). Назовите сохраняемый файл **Signature.sig**. Нажмите **OK**.

Задание 2. Оценить качество эталонов.

Прежде чем приступить к проведению непосредственно классификации, необходимо оценить качество подготовленных эталонов. В данном примере их будет только три, но после выполнения задания 1 этой лабораторной работы у вас их должно быть значительно больше – в соответствии с объектным составом территории. Следующие шаги позволят вам ознакомиться с некоторыми инструментами оценки качества созданных вами эталонов. Работая с этими инструментами, отметьте эталоны, чьи спектральные характеристики являются смешанными с эталонами других классов.

Откройте файл эталонов, созданный в предыдущем задании в редакторе эталонов (**Signature Editor**). Выделите все имеющиеся эталоны либо какую-то часть. Нажмите кнопку **Display Histograms Window**  (Показать окно с гистограммами) – перед вами появится окно работы с гистограммами (**Histogram Plot Control Panel**) (рис. 74).




Рис. 74. Окно работы с гистограммами

В этом окне щелкните кнопки **All Selected Signatures** (Все выбранные эталоны) и **All Bands** (Все каналы изображения), а затем нажмите кнопку **Plot** (Нарисовать графики).

Измените размер и расположите открытые диалоговые окна и Вьюеры так, чтобы все они были доступны одновременно. Это значит, что на экране должны быть открыты графики, в каждом из которых по две гисто-

граммы, причем цвет гистограммы соответствует цвету отдельного эталона (рис. 75).




Рис. 75. Гистограммы выбранных эталонов

Проведите анализ гистограмм, выявите каналы, в которых эталоны хорошо разделимы, а в каких – плохо, после этого удалите все окна с гистограммами, нажав на кнопку **Close** (Заккрыть) в диалоге **Histogram Plot Control Panel**.

Просмотрите на экране статистические характеристики (статистики) эталонов – это поможет вам определить, какие слои выбранных эталонов содержат перекрытия в пределах правила параллелепипеда. Убедитесь, что один из эталонов, гистограммы которого вы просматривали, выбран в редакторе эталонов (Signature Editor) с помощью индикатора (>). Вы можете изменить положение эталона, просто щелкнув по соответствующей ячейке таблицы. В окне Редактора эталонов нажмите на кнопку **Display Statistics Windows** Σ (Отобразить статистическую информацию) – на эк-

ране появится диалог **Statistics Plot** (Статистические диаграммы). Статистическая информация будет меняться вместе с перемещением индикатора в редакторе эталонов с одного на другой выбранный класс.

Возможно, вы обнаружите, что два эталона содержат области нежелательных перекрытий (рис. 76).

Layer	Minimum	Maximum	Mean	Std. Dev.
1	163.000	200.000	176.442	3.721
2	345.000	388.000	365.507	5.132
3	276.000	315.000	290.121	3.718
4	81.000	124.000	96.086	3.456

Layer	1	2	3	4
1	13.847	3.024	1.782	1.952
2	3.024	26.341	2.807	1.072
3	1.782	2.807	13.824	1.396
4	1.952	1.072	1.396	11.947

Layer	Minimum	Maximum	Mean	Std. Dev.
1	145.000	175.000	160.667	4.136
2	270.000	303.000	286.241	6.437
3	243.000	265.000	254.677	3.628
4	139.000	182.000	158.030	8.555

Layer	1	2	3	4
1	17.103	13.186	4.249	10.439
2	13.186	41.439	8.991	12.850
3	4.249	8.991	13.164	4.872
4	10.439	12.850	4.872	73.182

Рис. 76. Область перекрытия значений

Вместо того, чтобы переделывать эти эталоны, используя инструмент работы с областями интереса (AOI), вы можете поправить параметры эталона, выбрав в меню редактора эталонов (**Signature Editor**) команды **Edit/Parallelepiped Limit** (Редактировать/Изменить пределы «параллелепипеда»). Введите новые верхний (**Upper**) и нижний (**Lower**) предел в текстовых полях или нажмите **Set** (Установить), чтобы изменить и другие опции (рис. 77).

Layer	Lower	Upper
1	163.0000	200.0000
2	345.0000	388.0000
3	276.0000	315.0000
4	81.0000	124.0000

Layer	Lower	Upper
1	163.0000	175.0000
2	345.0000	388.0000
3	276.0000	315.0000
4	81.0000	124.0000

Рис. 77. Изменение пределов

Закройте диалог статистики (**Statistics**), используя кнопку **Close**.

Выберите несколько классов в редакторе эталонов. На панели инструментов редактора эталонов выберите кнопку **Display Mean Plot Window**  (Вывести на экран график средних значений) и на экране появится график средних значений (**Signature Mean Plot**).

Чтобы увидеть все эталоны, выбранные вами в редакторе эталонов, нажмите кнопку **Switch Between Single and Multiple Signature Mode**  (Показать средние значения по одному или нескольким эталонам). Таким образом вы сможете увидеть средние значения одного или нескольких эталонов по каждому каналу съемки (рис. 78).

Переместите курсор на диаграмму средних значений (Mean plot). Наведя курсор на точку на графике, отвечающую определенному эталону и спектральному диапазону (точку излома), в строке состояния можно увидеть точное значение средней по эталону спектральной яркости.




Рис. 78. Графики средних значений эталонов

Теперь, когда вы ознакомились с различными возможностями оценки ваших эталонов, вернитесь к файлу эталонов и отредактируйте ваши эталоны одним из следующих способов:

- удалите эталон и создайте его заново;
- измените пределы параллелепипеда для эталона;

– определите, какие смешанные классы не могут быть разделены и что нужно с ними сделать: создать из этих нескольких классов один или переделать их, используя пространство спектральных признаков (Feature Space).

Задание 3. Выполнить управляемую классификацию.

Вызвать диалог классификации с обучением (**Supervised Classification**) можно двумя способами:

Если вы только что создавали эталоны, и редактор эталонов (**Signature Editor**) еще открыт, то в меню редактора эталонов выберите **Classify/Supervised** (Классифицировать/С обучением) (рис. 88).




Рис. 79. Вызов диалога классификации через редактор эталонов

Если же вам нужно использовать файл эталонов, не загруженный в редактор эталонов, обратитесь к Главной панели **IMAGINE** и выберите **Raster/Classifier/Supervised Classification** (Растр/Классификатор/Классификация с обучением) (рис. 80).




Рис. 80. Вызов диалога классификации

В появившемся окне нужно будет указать имя входного растрового файла (**Input Raster File**) и имя файла эталонов (**Input Signature File**).

Введите имя выходного файла классифицированного изображения **1_supervised.img**.

Включите флажок **Output Distance File** (Выходной файл расстояний) и введите имя файла **1_distance.img** в строке **File Name** (Имя файла).

В качестве параметрического решающего правила используйте (**Parametric Rule**) правило наибольшего правдоподобия (**Maximum Likelihood**).



Внимание! Если при выполнении классификации были выбраны некоторые эталоны в редакторе эталонов, то выходной файл будет основан только на выбранных эталонах.

Используйте установки, предложенные по умолчанию (рис. 81), и нажмите **OK**.




Рис. 81. Параметры классификации

Когда процесс выполнения задания будет завершен, отобразите во Вьюере одно за другим изображения **1_supervised.img**, **1_distance.img** и исходное изображение, используя опцию **Fit to Frame** (Вписать изображение в окно Вьюера). Оцените результат.

Выполните управляемую классификацию всеми остальными способами, имеющимися в **Erdas Imagine**. Проанализируйте полученные результаты. Сохраните наиболее правдоподобный результат.

Контрольные вопросы по лабораторной работе № 4

1. Какую информацию об эталоне можно получить из таблицы **CellArray**?
2. Какие произойдут изменения в размере Области интереса (АОТ), если изменить значение спектрального расстояния?
3. Если использовать правило 8-и ближайших соседей, как изменится Рабочая область?
4. Каковы преимущества использования способа получения эталона методом «выращивания» перед ручной рисовкой эталонов?
5. В каких спектральных зонах наблюдается смешение эталонов, а в каких они различаются лучше?
6. В каких каналах диаграммы средних значений наиболее близки и каков смысл использования этих каналов в классификации?
7. В каких диапазонах съемки диаграммы больше всего различаются?
8. Каково среднее значение каждого эталона в канале с наибольшей дисперсией?
9. Для чего используется файл расстояний **Distance File**?
10. Какая разница между параметрическим и непараметрическим эталоном?
11. Остались ли какие-нибудь классы, которые не выделились в результате классификации с обучением, несмотря на то, что вы этого ожидали?
12. Каким путем вы пойдете, если столкнетесь с неточно заданными эталонами и необходимостью редактирования этого файла?

2.5. Лабораторная работа № 5

Преобразование Фурье

Прежде, чем использовать редактор преобразования Фурье, вы должны из исходного изображения создать Фурье-образ (.fft-файл).

Преобразование Фурье

Откройте во Вьюере файл с именем **1.img**. На вкладке **Raster Options** (Параметры загрузки растра) в ниспадающем списке **Display as** (Отобразить как) выберите **Gray Scale** (В градациях серого).

Секция **Display Layer** (Отобразить канал) обновится, так что вы сможете выбрать, какой из каналов файла отобразить. Оставьте установленный по умолчанию первый канал **Layer 1** (рис. 82).




Рис. 82. Загрузка файла

Чтобы вывести файл во Вьюер, нажмите **OK**.

В главном меню **IMAGINE** выберите вкладки **Raster/Fourier Analysis** (Анализ Фурье). В выпадающем меню выберите пункт **Fourier Transform** (Преобразование Фурье) (рис. 83).

В диалоге **Fourier Transform** в поле **Input File** (Входной файл) введите **1.img**.

В этом примере, чтобы ускорить процесс обработки, вы будете работать только с одним каналом, однако методика применима и к множеству каналов изображения.




Рис. 83. Выбор редактор преобразования Фурье

Имя **1.fft** в поле **Output File** создается автоматически. Убедитесь, что вы находитесь в правильной директории. В поле **Select Layers** (Выбор каналов) введите 1:1. В диалоге **Fourier Transform** нажмите **OK**, чтобы создать новый файл (рис. 84).




Рис. 84. Параметры преобразования

В меню **Fourier Analysis** (Анализ Фурье) выберите пункт **Fourier Transform Editor** (Редактор Фурье-образа). Откроется окно **Fourier Editor**.

На панели инструментов **Fourier Editor** нажмите кнопку **Open**  (Открыть) или выберите **File/Open** в меню. Откроется диалог **Open FFT Layer** (Открытие файла FFT). Укажите путь и имя ранее созданного файла **1.fft**. Так как этот файл содержит только один канал, то значение поля **Layer Number** (Номер канала) по умолчанию установлено равным 1. Однако, если файл содержит более одного канала, вы можете выбрать здесь определенный канал для редактирования. Редактирование, сделанное на одном канале, может быть применено ко всем каналам .fft-файла с помощью пункта **File/Save All** (Файл/Сохранить все) меню **Fourier Editor**.

Нажмите **OK**, чтобы отобразить выбранный файл в окне **Fourier Editor**.

Сначала отобразится индикатор состояния, показывающий процесс чтения файла. Затем файл отобразится в окне **Fourier Editor** (Редактора Фурье-образа). Вы можете изменить размеры окна, чтобы увидеть полностью все изображение (рис. 85).




Рис. 85. Фурье-образ

Щелкните в любой точке внутри окна Fourier Editor, и в строке состояния отобразятся координаты этой точки. Чтобы динамически обновлять координаты, перемещайте мышь, удерживая кнопку.

Фильтр низких частот (ФНЧ) подавляет высокочастотные составляющие изображения, оставляя низкочастотные.

В меню **Fourier Editor** (Редактора Фурье-образа) выберите пункты **Mask / Filters** (Маска/Фильтры) (рис. 86).




Рис. 86. Выбор маски

Откроется диалог **Low/High Pass Filter** (Низко-/высокочастотный фильтр). В диалоге **Low/High Pass Filter** в ниспадающем списке **Window Function** (Оконная функция) выберите **Ideal**. Идеальная оконная функция дает резкое изменение на границе фильтра. Измените значение поля **Radius** на **10.00** (рис. 87).




Рис. 87. Параметры фильтрации

Все остальные параметры оставьте как есть и нажмите **OK**.

Ко всем значениям за пределами радиуса, равного 10.00, применяется низкочастотный фильтр. Поэтому все изображение становится черным, исключая маленький белый кружок в центре. Удаление такой большой части Фурье-образа соответственно удаляет много информации из изображения, так что, скорее всего, следует отменить этот шаг редактирования и попробовать выполнить его с другими параметрами.

В меню **Fourier Editor** выберите **Edit/Undo** (Редактировать/Отменить). Изображение вернется в исходное состояние.

В меню выберите **Mask/Filters**. В диалоге **Low/High Pass Filter** в ниспадающем списке **Window Function** выберите **Ideal**. Введите значение **Radius**, равное **80.00**. В диалоге **Low/High Pass Filter** нажмите **OK**.

Все частоты за пределами радиуса, равного **80**, затухают, а внутри радиуса *не подвергаются* влиянию фильтра. Файл **.fit** принимает следующий вид (рис. 88).




Рис. 88. Результат применения маски

В меню **Fourier Editor** выберите **File/Save As** (Файл/Сохранить как). Откроется диалог **Save Layer As** (Сохранить как). В выбранной директории введите имя для нового .fft-файла, например, **1Lowpass.fft**.

Нажмите **ОК**, чтобы сохранить файл.

Обратное преобразование Фурье

Теперь сделаем обратное преобразование Фурье, чтобы вы могли увидеть отфильтрованное изображение и посмотреть, какой эффект дает данное преобразование.

На панели инструментов **Fourier Editor** (Редактор Фурье-образа) нажмите кнопку **Run**  (Пуск) или в меню выберите **File/Inverse Transform** (Файл/Обратное преобразование). Откроется диалог **Inverse Fourier Transform** (Обратное преобразование Фурье).

В диалоге **Inverse Fourier Transform**, в поле **Output File** (Выходной файл) введите имя для нового выходного файла, например **inverse_1.img**. Этот файл по умолчанию имеет расширение **.img**. Убедитесь, что вы выбрали правильную директорию. Нажмите **ОК**, чтобы создать новый файл. Откройте файл в новом Вьюере (рис. 89).




Рис. 89. Результат обратного преобразования Фурье

Оцените результаты. Не обязательно, что все действия по редактированию, описанные в этом руководстве, приведут к улучшению изображения. Многие упражнения выполняются просто для иллюстрации работы каждого конкретного метода. В ходе обработки различных наборов данных вы можете поэкспериментировать с различными методами или комбинацией методов, чтобы найти тот способ, который будет работать наилучшим образом. Для закрепления навыков исследуйте другие маски и окна с разными радиусами, представленные в меню **Fourier Editor** (Редактора Фурье-образа) (рис. 90).




Рис. 90. Варианты преобразований

Контрольные вопросы по лабораторной работе № 5

1. Что такое преобразование Фурье?
2. Зачем применяется обратное преобразование Фурье?
3. Использование круглой маски.
4. Использование прямоугольной маски.
5. Использование клиновидной маски.
6. Чем отличаются низко- и высокочастотные фильтры?

2.6. Лабораторная работа № 6

Использование геометрических параметров при распознавании объектов

Для выполнения данной работы в качестве исходных данных необходимо использовать результат, полученный по итогам выполнения лабораторной работы № 4. В качестве примера возьмем классифицированный растр, полученный по методу максимального правдоподобия с соответствующим набором эталонов (рис. 91).




Рис. 91. Исходные данные

Задание 1. Удалить мелкие полигоны тематического растра.

NB

Функция **Clump** формирует связные по индексу класса области путем анализа окрестности каждого пикселя «крестом» (рассматриваются только соседи по горизонтали и вертикали) либо окном (рассматриваются

все 8 соседей). Каждому сегменту присваивается собственный новый индекс. При этом индекс класса также сохраняется в атрибутах сегмента. Растровый результат представляется в виде серого полутонового изображения, на котором значения яркости соответствуют номерам выделенных сегментов, которые располагаются в порядке просмотра изображения.

На Главной Панели **IMAGINE** выберите вкладку **Raster/Thematic/Clump** (Растр/Тематическая обработка/Кламп) (рис. 92).




Рис. 92. Выбор опции **Clump**

На экране появится диалог **Clump** (рис. 92).

Введите имя входного файла (**Input File**), имя выходного файла (**Output File**). Для анализа связности пикселов (**Connected Neighbors**) выберите значение **4**. Нажмите **OK**.




Рис. 93. Диалоговое окно опции **Clump**

Откройте во Вьюере полученное изображение. Этот файл отобразится как полутоновое изображение в градациях серого с переходом от темного к светлому сверху вниз (рис. 94).




Рис. 94. Результат применения опции **Clump**

Для удаления мелких полигонов могут быть использованы функции **Sieve** или **Eliminate**.

NB

Функция **Sieve** исключает из рассмотрения сегменты меньше заданного размера (обнуляет их индексы). Максимальный размер сегмента, который подлежит удалению, задается пользователем.

Функция **Eliminate**, в отличие от **Sieve**, сливает мелкие сегменты с более крупными, используя анализ ближайших соседей. Значения пикселей из мелких сегментов заменяются преобладающими в окрестности в несколько итераций, пока сегменты не будут полностью «поглощены» соседями. Растровый результат после выполнения этой процедуры отображается уже не по номерам сегментов, а по номерам классов.

Для генерализации растра путем поглощения мелких полигонов их ближайшими соседями на Главной панели **IMAGINE** выберите вкладку **Raster/Thematic/Eliminate** (Растр/Тематическая обработка/Слияние).

На экране появится диалог **Eliminate**.

Введите имя исходного файла (**Input file**). Для выходного файла (**Output file**) введите имя. В поле **Minimum** (Минимальный размер) введите значение (подобрать экспериментально, в примере используется **5**) **Pixels**, чтобы задать величину минимального поглощаемого полигона (рис. 95). Нажмите **ОК**.




Рис. 95. Диалоговое окно опции **Eliminate**

Откройте во Вьюере полученное изображение. Откройте редактор атрибутов (**Attribute Editor**) для исходного и полученного файлов. Скопируйте цвета исходного файла в редактор атрибутов полученного изображения. Сравните два файла визуально (рис. 96).




Рис. 96. Результат применения опции **Eliminate**

Подберите оптимальное значение размера поглощаемых полигонов и сохраните полученный результат.

Задание 2. Использование значений площади определяемого объекта.

Откройте редактор атрибутов (**Attribute Editor**) для генерализованного изображения. Используя вкладку **Table/Column** (Таблица/Колонка), добавьте колонки Имя класса и Площадь при помощи опции **Add Class Name** и **Add Area** (рис. 97).




Рис. 97. Добавление колонок

Добавьте резервную колонку цвета и скопируйте в нее данные из колонки **Color**. После внесенных изменений редактор атрибутов должен выглядеть примерно так, как показано на рис. 98.

1_class_elim.img						
Row	Class_Names	Histogram	Color	Area	Opacity	Column 6
4	Растительность 2	131056		209.69	1	
3	Растительность 1	133904		214.246	1	
10	Почва	33380		53.408	1	
16	Лес	188119		300.99	1	
1	Вода	51380		82.208	1	
2	Антропоген	92281		147.65	1	

Рис. 98. Редактор атрибутов

Используя колонку Прозрачность (**Opacity**), можно сделать невидимыми не представляющие интереса классы. Для этого нужно поменять значение на **0**. В качестве примера оставим видимым только класс «Лес» (рис. 99).



Рис. 99. Невидимость классов



Изменить прозрачность можно и иначе. Для этого нужно щелкнуть правой кнопкой мыши ячейку, обозначающую цвет любой из выделенных строк и выбрать **Other** (Другой). Появившийся Цветовой диск позволяет задать любой цвет, но для данного упражнения будет полезно изменить только прозрачность выбранных классов. Отключите опцию **Use Color** (Использовать цвет), но включите опцию **Use Opacity** (Использовать непрозрачность). Перетащите бегунок к значению ноль, чтобы сделать выбранные классы полностью прозрачными. Нажмите **Apply**, а потом Close.

Предположим, что из всех объектов класса «Лес» нас будут интересовать только относительно большие участки, плотно покрытые древесной растительностью. Для того, чтобы выделить только их, необходимо выполнить следующие действия. Повторно проведите процедуру **Clump** для генерализированного изображения. Откройте рядом эти два изображения и определите при помощи курсора запросов **Original Value** (Истинное значение) соответствующее классу «Лес» (рис. 100). В данном случае оно равно **16**.




Рис. 100. Определение Истинного значения класса

При помощи инструментария **Measure** (Измерения), который можно вызвать при помощи вкладок главной панели **Home/Information** (Главная/Информация) (рис. 110), определите примерную минимальную площадь интересующих участков, в данном случае примерно 3,7 гектара.




Рис. 101. Измерение площади участка

Откройте редактор атрибутов (**Attribute Editor**) для последнего полученного изображения.

Поместите курсор мыши в столбец **Row** и правой кнопкой мыши вызовите контекстное меню. Выберите в нем **Criteria** (Критерии). В появившемся диалоге задайте критерии.

Щелчком мыши выберите **Original Value**, затем продолжите задание условия, выбрав «**and**», «**Area**», «**>**» и набрав значение площади (подобрать экспериментально). В данном примере условие должно выглядеть так, как показано на рис. 102.




Рис. 102. Определение параметров выборки

Нажмите кнопку **Select** (Выбрать), чтобы получить результат запроса в таблице атрибутов. Если все сделано правильно, то вы увидите, что несколько полей таблицы выделены цветом. Если этого не произошло, проверьте правильность формирования условия (критерия) и нажмите **Select** снова. Нажмите кнопку **Close**.

Для искомых полигонов задайте какой-либо яркий цвет. Затем выделите и спрячьте все остальные классы. Щелчком правой кнопки мыши в столбце **Row** вызовите контекстное меню. В нем выберите **Invert Selection** (Инверсия выборки). Теперь щелкните ячейку, обозначающую цвет

любой из выделенных строк, выберите **Other** (Другой) и включите опцию **Use Opacity** (Использовать непрозрачность).

Откройте в этом же Вьюере исходный снимок и поместите его под полученную маску.

Оцените результат (рис. 103). При необходимости внесите изменения в критерии запросов. Сохраните результат.




Рис. 103. Выделенные объекты класса «Лес» заданной площади

Задание 3. Использование описания формы определяемого объекта.

Анализ полученных результатов показывает, что введение параметра «площадь» значительно повышает достоверность классификации, однако во многих случаях одного этого критерия недостаточно.

Одним из отличительных геометрических признаков объектов является их форма. Поэтому следующим этапом работы является выявление параметра, позволяющего выделить интересующие объекты по данному признаку.

На Главной панели **IMAGINE** выберите вкладку **Raster/Thematic/Perimeter** (Растр/Тематическая обработка/Периметр) (рис. 104).




Рис. 104. Выбор опции **Perimeter**

Откроется диалоговое окно **Perimeter** (рис. 105), в котором нужно указать имя входного файла.




Рис. 105. Выбор опции **Perimeter**

После вычисления периметров всех полигонов в окне редактора атрибутов (**Attribute Editor**) появятся новые колонки (рис. 106).

Row	Original Value	Histogram	Perimeter, exterior	Perimeter, islands	Area	Color	Opacity
0	0	2490	0	0	3.984		1
1	16	8759	2195.14	258.108	14.0144		1
2	4	43454	23505.3	20064.3	69.5264		1
3	3	163	548.416	0	0.2608		1

Рис. 106. Окно редактора атрибутов

Для выявления дорог воспользуемся так называемой функцией «Округлость» (*Circularity*).

NB

Запрос для расчета округлости выглядит следующим образом:

$4 * \pi * \text{"Area"} * 10000 / (\text{"Perimeter, exterior"} * \text{"Perimeter, exterior"})$.

Значением этого выражения будет число от 0 до 1. Ноль соответствует линии (предельно узкий полигон), единица – кругу (максимально округлый полигон).

Далее, используя полученные ранее навыки, необходимо определить истинное значение и примерную площадь полигонов, которые могут описать объекты, относящиеся к дорогам на данной территории (к ним будут относиться некоторые полигоны, содержащиеся в классе «Антропоген»). В результате запрос по всем выявленным критериям в данном примере стал таким, как показано на рис. 107.




Рис. 107. Определение параметров выборки

После по полученному растру была создана маска (Mask), показывающая все объекты, удовлетворяющие данному запросу (рис. 108).




Рис. 108. Выделенные из класса «Антропоген» (голубой цвет) объекты класса «Дороги» (зеленый цвет)

Контрольные вопросы по лабораторной работе № 6

1. В каких единицах измерения рассчитывается периметр?
2. Каков предел значений округлости полигонов?
3. Как можно запросить типы выбранных участков?
4. Можно ли применить маску одновременно более чем к одному слою?
5. Какого размера файл будет получен в результате выполнения поиска, если задать размер ячейки выходного файла равным 1 метру?
6. Можно ли выполнить поиск, используя как входной файл многослойное изображение?

2.7. Лабораторная работа № 7

Выявление изменений по разновременным снимкам

Для выполнения данной работы в качестве исходных данных необходимо использовать два снимка одной территории, полученные на разные даты, но имеющие единую систему координат. На рис. 109 представлена такая пара снимков.




Рис. 109. Пара разновременных снимков

Для выявления изменений к представленным снимкам можно применить технологию Change Detection. Для этого на Главной панели **IMAGINE** выберите вкладку **Raster/Zonal Change/Image Difference** (Растр/Зональные изменения/Различие изображений), как показано на рис. 110.




Рис. 110. Выбор функции **Image Difference**

В появившемся диалоговом окне, показанном на рис. 111, необходимо указать имена более раннего (**Before Image**) и более позднего (**After Image**) снимков, определить канал снимков, по которому будет производиться сравнение, имена выходных файлов **Image Difference File** (Файл различий) и **Highlight Change File** (Файл выделения изменений), а также указать величину изменений либо в процентах (**As Percent**), либо в яркости (**As Value**). Также этот диалог позволяет задать цвет выявленным изменениям.




Рис. 111. Диалоговое окно Change Detection

На рис. 112 представлена модель алгоритма **Image Difference**, реализованная в программе ERDAS Imagine.





Рис. 112. Модель алгоритма **Image Difference**


Рассмотрим работу данного алгоритма. Первым шагом загружаются разновременные космические снимки. Затем вычисляется разностное изображение, отображающее произошедшие изменения. Реализация данной функции в программе ERDAS Imagine представлена на рис. 113.



\$n2_22 - \$n1_11

Рис. 113. Вычисление разностного изображения

Далее для разностного изображения генерируются максимальные и минимальные значения по полному набору данных. Данный процесс осуществляется с помощью функций GLOBAL MIN и GLOBAL MAX, представленных на рис. 114.




GLOBAL MIN (\$n4_difference)

GLOBAL MAX (\$n4_difference)

Рис. 114. GLOBAL MIN и GLOBAL MAX
в программе ERDAS Imagine

Следующим шагом отбраковываются значения яркостей, которые не соответствуют заданным пороговым значениям по выражениям, представленным на рис. 115.



MIN (0.0, \$n8_Output[0]) * MIN (MAX (0.0, \$n11_Float), 100.0) / 100.0

MAX (0.0, \$n10_Output[0]) * MIN (MAX (0.0, \$n12_Float), 100.0) / 100.0

Рис. 115. Функции отбраковки яркостей, не соответствующих пороговым значениям

Затем полученные значения яркостей пикселей сравниваются со значениями яркостей разностного изображения с помощью оператора условия CONDITIONAL, представленного на рис. 116.

```
CONDITIONAL { ($n4_difference < $n15_Float) 1 ,  
  (($n4_difference >= $n15_Float) && ($n4_difference < 0.0)) 2 ,  
  ($n4_difference == 0.0) 3,  
  (($n4_difference > 0.0) && ($n4_difference <= $n16_Float)) 4,  
  ($n4_difference > $n16_Float) 5 }
```

Рис. 116. Оператор условия CONDITIONAL

По заданным условиям оператора CONDITIONAL пикселям присваиваются значения от 1 до 5.

Данный метод поиска изменений, как вычисление разности, является достаточно простым, устойчивым и понятным в интерпретации.

На рис. 117 представлены результаты обработки разновременных снимков по методу Change Detection при указанных выше параметрах.




Рис. 117. Выявленные изменения

В данном случае были выделены яркости, отличающиеся более чем на 10 % (это значение необходимо подобрать экспериментально).

При дальнейшем выполнении работы необходимо выполнить аналогичные исследования, но в качестве исходных изображений использовать классифицированные изображения, а также преобразованные (главные компоненты, индексы).

Для визуализации произошедших изменений используются различные технические решения, наиболее простым из которых является создание композитных изображений, сформированных из каналов разновременных снимков.

В целях визуального анализа можно «подменить» какой-либо канал снимка любым каналом снимка на другую дату. Для этого нужно воспользоваться вкладкой **Multispectral/Bands** (Мультиспектр/Каналы). На рис. 118 представлен вариант композитного изображения.




Рис. 118. Вариант композитного изображения

Контрольные вопросы по лабораторной работе № 7

1. Основные подходы к выделению изменений.
2. Классификация алгоритмов и методов выделения изменений Change Detection.
3. Для чего используют предварительную классификацию изображений?
4. В каких случаях и как следует использовать метод главных компонент?
5. Что такое композитное изображение?

ЗАКЛЮЧЕНИЕ

Учебно-методическое пособие содержит базовые сведения по вопросам, связанным с автоматизированным дешифрированием снимков. Краткое изложение принципов распознавания объектов по их изображениям и методы конструирования алгоритмов различных типов позволяют приступить к детальному изучению методов автоматизированного распознавания. Также в учебно-методическом пособии приводится описание лабораторных работ с использованием программного комплекса ERDAS Imaging.

Лабораторные работы поясняют действие алгоритмов, рассмотренных в теоретической части данного пособия. После изучения материалов учебно-методического пособия можно самостоятельно пользоваться основными программами программного комплекса ERDAS для автоматизированного дешифрирования реальных снимков.

Для обучающихся, желающих расширить свои знания в области распознавания образов по снимкам, предлагается воспользоваться источниками из библиографического списка.

Вопросы преобразования изображений и различные подходы к сегментации изображений детально изложены в работе [2].

Для изучения статистических методов распознавания образов рекомендуется использовать учебник [9].

Для детального освоения методов главных компонент и других ортогональных преобразований рекомендуется обратиться к классической монографии [5].

Для изучения вейвлет-преобразования – эффективного активно развивающегося метода анализа изображений – можно рекомендовать учебник [7].

Следует отметить, что в данном учебно-методическом пособии вследствие ограниченного объема не рассмотрены вопросы, связанные с построением и использованием методов нейронных сетей. В последнее время в связи с возможностью использовать практически неограничен-

ные вычислительные мощности и разработкой методов обратного распространения ошибок вновь проявился интерес к нейронным сетям, разработанным еще в 80-х гг. XX в. В настоящее время с помощью нейронных сетей решается широкий круг задач распознавания объектов по их изображениям.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Гук А. П., Конечный Готтфрид. Фотограмметрия и дистанционное зондирование. – 2018. – 250 с.
2. Гонсалес Р. Вудс. Цифровая обработка изображений. – М. : Техносфера, 2006. – 1072 с.
3. Дистанционное зондирование: количественный подход / пер. с англ. ; Ш. М. Дейвис, Д. А. Ландгребе, Т. Л. Филипс и др. ; под ред. Ф. Свейна и Ш. Дейвис. – М. : Недра, 1983. – 415 с.
4. Митропольский А. К. Техника статистических вычислений. – М. : Мир, 1982. – 576 с.
5. Прэтт У. Цифровая обработка изображений: пер. с англ. – М. : Мир, 1982.
6. Дж. Ту, Гонсалес Р. Принципы распознавания образов: пер. с англ. – М. : Мир, 1978. – 411с.
7. Фрейзер М. Введение в вейвлеты в свете линейной алгебры / пер. с англ. – М. : Бином : Лаборатория знаний, 2011. – 487 с.
8. Яне Б. Цифровая обработка изображений. – М. : Техносфера, 2006. – 584 с.
9. Дуда Р., Харт П. Распознавание образов и анализ сцен. – М. : МИР, 1976.

Учебное издание

Гук Александр Петрович
Хлебникова Елена Павловна

МЕТОДЫ И ТЕХНОЛОГИИ РАСПОЗНАВАНИЯ ОБЪЕКТОВ ПО ИХ ИЗОБРАЖЕНИЮ

Редактор *Е. Н. Ученова*
Компьютерная верстка *К. В. Ионко*

Изд. лиц. ЛР № 020461 от 04.03.1997.
Подписано в печать 19.03.2019. Формат 60 × 84 1/16.
Усл. печ. л. 8,02. Тираж 60 экз. Заказ 33.
Гигиеническое заключение
№ 54.НК.05.953.П.000147.12.02. от 10.12.2002.
Редакционно-издательский отдел СГУГиТ
630108, Новосибирск, ул. Плахотного, 10.
Отпечатано в картопечатной лаборатории СГУГиТ
630108, Новосибирск, 108, Плахотного, 8.