



Тема лекции 4. КЛАССИФИКАЦИЯ И ПЕРЕ- КЛАССИФИКАЦИЯ ДАННЫХ ДИСТАНЦИОН- НОГО ЗОНДИРОВАНИЯ ЗЕМЛИ

Вопросы:

- 4.1. **Классификация и переклассификация данных дистанционного зондирования.**
- 4.2. **Интерактивные методы классификаций.**
 - 4.1.1 Общие положения контролируемой классификации
 - 4.1.2. Формирование обучающей выборки
 - 4.1.3. Метод классификации по минимальному расстоянию
 - 4.1.4. Метод параллелепипедов
 - 4.1.5. Метод максимального правдоподобия
- 4.3. **Вероятностный анализ классов изображений.**
- 4.4. **Анализ классов изображений по методу главных компонент.**
 - 4.4.1. Стандартный метод главных компонент
 - 4.4.2. Метод главных компонент с минимизацией шума
- 4.5. **Преобразование колпак с кисточкой**
- 4.6. **Определение вегетационных индексов по данным дистанционного зондирования.**

Литература

1. Токарева О. С. Обработка и интерпретация данных дистанционного зондирования Земли: учебное пособие / О. С. Токарев. – Томск: Издательство Томского политехнического университета, 2010. – 148 с.
2. Чандра А. М. Дистанционное зондирование и географические информационные системы / А. М. Чандра, С. К. Гош. – Москва: Техносфера, 2008. – 312 с.
3. Шовенгердт Р. А. Дистанционное зондирование. Модели и методы обработки изображений / Р. А. Шовенгердт. – М.: Техносфера, 2010. – 560 с.
4. Жиленев М. Ю. Обзор применения мультиспектральных данных ДЗЗ и их комбинаций при цифровой обработке / М. Ю. Жиленев // Геоматика. – 2009. – № 3. – С. 56–64.
5. Кашкин В. Б. Дистанционное зондирование Земли из космоса. Цифровая обработка изображений В. Б. Кашкин, А. И. Сухинин. – М.: Логос, 2001. – 264 с.
6. Сухих В. И. Аэрокосмические методы исследования в лесном хозяйстве и ландшафтном строительстве / В. И. Сухих. – Йошкар-Ола: Изд-во МарГТУ, 2005. – 392 с.
7. Козодеров В.В. Методы оценки состояния почвенно-растительного покрова по данным оптических систем дистанционного зондирования. Учебное пособие. М.: МФТИ, 2008 – 222 с.
8. Гарбук СВ., Гершензон В.Е. Космические системы дистанционного зондирования Земли. — М.: Издательство А и Б, 1997. — 296 с,
9. Обработка данных дистанционного зондирования Земли: практические аспекты : [учеб. пособие] / [В. Г. Коберниченко, О. Ю. Иванов, С. М. Зраенко и др. ; под общ. ред. В. Г. Коберниченко]. — Екатеринбург : Изд-во Урал. ун-та, 2013. — 168 с.

Вопрос 4.1. Классификация и переклассификация данных дистанционного зондирования.

Классификация и переклассификация данных дистанционного зондирования используются для анализа и интерпретации изображений, полученных со спутников и других источников. Эти процессы включают в себя разделение изображения на различные категории, такие как типы растительности, типы почвы, водные объекты и т. д.

Классификация может быть выполнена с использованием различных методов, таких как машинное обучение, статистический анализ и ручная интерпретация. Переклассификация, с другой стороны, подразумевает изменение существующих категорий или добавление новых для более точного описания данных.

Оба процесса важны для анализа данных дистанционного зондирования и могут помочь в принятии решений, связанных с управлением ресурсами, планированием землепользования и охраной окружающей среды.

Под распознаванием образов (классификацией) понимают **процедуру, позволяющую вынести решение о принадлежности данного изображения или его фрагмента к одному из n классов, $n > 1$.** Это решение выносится на основании наличия у изображения некоторых признаков того или иного класса. ***Результатом является выделение классифицированных объектов на изображении.***

Определение, что такое класс и каковы его признаки, зависит от задачи. На космическом изображении можно классифицировать области, покрытые снегом, с точки зрения степени загрязнения их промышленными выбросами, классы — участки с разной степенью загрязнения.

Распознавание образов относят к тематической обработке изображений, перед которой обычно выполняют предварительную обработку — восстанавливают и улучшают исходное изображение.

Задачи распознавания изображений с некоторой долей условности разделяют на задачи идентификации и задачи определения параметров положения. Напр., опознание созвездия по изображению участка звездного неба в системах астроориентации есть задача идентификации. ***Задача определения углов тангажа, крена космического аппарата по положению опознанного созвездия на кадре есть задача определения параметров положения.*** Задачи распознавания изображений решаются ***на основе общей теории распознавания образов.***

Подходы к распознаванию

В общей теории распознавания образов существует несколько различных подходов к распознаванию, отличающихся структурой описания классов признаков.

Детерминированный подход

Такой подход предполагает, ***что в любой точке пространства признаков, используемых для распознавания, с ненулевой априорной вероятностью могут появляться реализации только одного класса.***

При этом необходимо из всей совокупности признаков, характеризующих распознаваемые объекты, выделить *систему детерминированных свойств, т.е. таких признаков, определение которых не связано с теми или иными принципиально случайными механизмами.*

Типичным примером систем распознавания изображений с использованием детерминированного подхода могут служить *способы распознавания типографских букв для ввода в ЭВМ текстов с помощью настольного сканера и их последующего анализа.* Один из распространенных способов распознавания букв в этих системах основан на *корреляционно-экстремальном алгоритме.* Для этого в памяти ЭВМ должны храниться эталоны всех символов (букв, цифр, знаков препинания и др.), которые могут встретиться в обрабатываемом тексте. Каждый считываемый символ сравнивается со всеми эталонами, среди которых ищется максимально совпадающий с текущим считанным символом

Статистический подход

Предполагает, что в одной точке пространства признаков с отличной от нуля априорной вероятностью могут появляться реализации, относящиеся к различным классам.

Это может быть связано с неизбежными *случайными ошибками*, присутствующими в детерминированных признаках, а также *с использованием* признаков, являющихся принципиально случайными величинами, т.е. *вероятностных свойств.*

Методы статистического распознавания образов наиболее часто применяют в задачах дистанционного зондирования (ДЗ) в силу следующих причин:

Вследствие случайного характера протекания природных явлений результаты ДЗ подвержены случайным изменениям, маскирующим характерные различия между классами. Статистический анализ позволяет учесть эти изменения, потенциально уменьшить их отрицательное влияние на точность классификации;

Исследуемые классы могут перекрываться в пространстве измерений, т.е. некоторые измерения одного класса могут быть неотличимы от измерений других классов. В этих случаях методы статистического распознавания образов позволяют производить наиболее четкую классификацию.

Методы статистического распознавания образов обычно используют *функции распределения вероятностей, связанные с классами образов.* Однако зачастую эти функции неизвестны и должны оцениваться по множеству обучающих образов. В некоторых случаях **форма функции распределения вероятностей считается известной** (например нормальной) и по обучающим образам необходимо оценить только отдельные параметры, связанные с этими функциями (такие как математические ожидания, дисперсии, функции корреляции). Такой метод называется *параметрическим.* Если форма функций распределения вероятностей неизвестна заранее, метод является *непараметрическим.*

Параметрические методы обычно легче реализуются, но требуют большего объема априорной информации или фундаментальных предположений относительно природы образов.

Непараметрические методы имеют большие потенциальные возможности для точной оценки функций распределения вероятностей и *для точного распознавания*, но это преимущество обычно *требует сложных распознающих систем*, большого числа обучающих образов и, главное, больших временных затрат.

Нейрокомпьютерный подход

С начала 80-х годов в области исследований *по искусственному интеллекту* начало быстро развиваться направление работ, связанное с созданием нового класса устройств - нейрокомпьютеров. По сравнению с ЭВМ традиционных типов нейрокомпьютеры обладают рядом *необычных свойств*. Так, *их программирование осуществляется не заданием последовательностей команд, а предъявлением образов, примеров решения задач из нужного класса*.

Нейрокомпьютер - это программно-техническая система которая реализует, или, как говорят, обчисляет некоторую формальную модель естественной нейронной сети. Необычные свойства нейрокомпьютеров являются модельным отображением тех особенностей, которые присущи процессам переработки информации в живых организмах. Для каждого объекта может быть построено множество моделей, отличающихся друг от друга исходными концепциями, уровнем обобщений и т.д.

Нейрокомпьютерный подход служит мощным инструментом для решения задач распознавания изображений (*нейрокомпьютеры позволяют стандартным способом решать многие нестандартные задачи*). **Основной структурной единицей нейрокомпьютера** является *формальный нейрон, суммирующий входные сигналы с определенными весовыми коэффициентами и выдающий результирующий сигнал на входы других нейронов и на выход нейронной сети*.

Обучение нейрокомпьютера сводится к подбору весовых коэффициентов для получения требуемого результата. Существует принципиальное отличие нейрокомпьютерного подхода от классических детерминированного и статистического. *В данном случае интересна не конкретная конструкция устройства или конкретный алгоритм (они, как правило, остаются неизвестными), а положительный результат распознавания*, который достигнут с помощью обучения и перестройки связей нейронов в процессе обучения. Они особенно эффективны там, *где требуется подобие человеческой интуиции* — для распознавания образов (распознавание сложных изображений, чтение текстов и т.п.). Именно для таких задач обычно трудно формализовать набор признаков и создать явный алгоритм.

В основе используемых представлений лежит идея о том, что нейроны можно моделировать довольно простыми автоматами, а *вся сложность нейрокомпьютера, гибкость его функционирования и другие важнейшие качества*

определяются *связями между нейронами*. Каждая связь представляется как совсем простой элемент, служащий для передачи сигнала.

Особенностью нейροкомпьютерного подхода является **использование обучения вместо программирования**. Труд программиста заменяется трудом учителя (тренера). Программист предписывает ЭВМ все детали работы, учитель — создает «*образовательную среду*», к которой приспосабливается нейροкомпьютер. **Обучение обычно строится на основе задачника — набора примеров с заданными ответами**. Эти примеры предъявляются системе. Нейроны получают по входным связям сигналы — условия примера, преобразуют их, несколько раз обмениваются преобразованными сигналами и наконец выдают ответ — также набор сигналов. Отклонение от правильного ответа штрафует. Обучение состоит в минимизации штрафа как функции связей.

Вопрос 4.1. Интерактивные методы классификаций

Вопрос 4.1.1 Общие положения контролируемой классификации

Интерактивные методы классификации используются для анализа и интерпретации данных дистанционного зондирования, полученных со спутников и других источников. Они позволяют пользователю взаимодействовать с данными и изменять существующие категории или добавлять новые для более точного описания.

Эти методы могут включать в себя использование машинного обучения, статистических методов, ручных интерпретаций и других методов. Они могут быть полезны для принятия решений в области управления ресурсами, планирования землепользования и охраны окружающей среды.

Смысл *контролируемой классификации* заключается в **отнесении каждого из пикселей снимка к определенному классу объектов на местности, которому соответствует некоторая область в пространстве признаков**. Контролируемая классификация включает несколько этапов.

Первый этап заключается в определении, какие классы объектов будут выделены в результате выполнения всей процедуры. Это могут быть виды растительности, с/х-ные культуры, породы леса, гидрографические объекты и т.д.

На втором этапе для каждого из классов объектов выбираются типичные для него пиксели, т.е. формируется *обучающая выборка*.

Третий этап — вычисление параметров, «спектрального образа» каждого из классов, сформированного в результате набора эталонных пикселей. Набор параметров зависит от алгоритма, который предполагается использовать для классификации.

Четвертый этап процедуры классификации — просмотр всего изображения и отнесение каждого пикселя к тому или иному классу. Результатом этого этапа является изображение («карта классификации»), а также таблица, в которой даны координаты пикселя и имя класса, к которому он отнесен.

Вопрос 4.1.2. Формирование обучающей выборки

Обязательным условием выполнения этой процедуры является наличие на снимке *эталонов*, т.е. фрагментов изображения, однозначно относящихся к своему классу объектов. **Источниками, на основе которых выбираются эталоны, могут быть материалы специально проведенных полевых работ, карты, отдешифрованные аэроснимки.** Процедура создания обучающей выборки реализуется *выбором в пределах изображения эталонного объекта участков в несколько пикселей*. Процесс классификации цифрового снимка идет по픽сельно, т.е. каждый пиксел относится к тому или иному классу.

В идеале для классификации необходимы эталоны, полученные одновременно со съемкой и основанные на хорошо различающихся классах. *На практике*, как правило, существует некоторый интервал времени между получением данных и их обработкой. В этом случае *только группу пикселей можно использовать для обучающей выборки*, т. к. использование для обучения отдельных пикселей теряет смысл.

Качество обучающей выборки в решающей степени влияет на точность классификации и определяется *несколькими условиями*:

По отношению к целому снимку *обучающая выборка должна составлять 1—5% всех пикселей*, а количество пикселей, относящихся к одному классу, достаточно большим (обычно не меньше 20—30).

Желательно, чтобы каждому классу соответствовал не один, а несколько эталонных участков, расположенных в разных частях снимка.

Значения яркостей пикселей, относящиеся к одному классу, должны иметь распределение, близкое к нормальному, и располагаться компактно в пространстве признаков, т.е. иметь минимально возможную дисперсию. Области значений яркости разных классов не должны пересекаться, иначе произойдет смешение классов.

Вид, в котором обучающая выборка формируется в компьютере, зависит от метода классификации: это или интервал яркостей в каждой из съемочных зон или значения центров классов, представленных в выборке, или значения центров классов и ковариационная матрица.

В большинстве программных продуктов, предназначенных для работы со снимками, имеется возможность контролировать качество выборки по изображению двумерного поля признаков, оси координат которого дешифровщик предварительно выбирает (чаще это *красная и ближняя инфракрасная съемочные зоны*).

При разработке алгоритмов контролируемой классификации используются *два подхода: детерминированный и статистический*.

Детерминированный подход применяется, когда классы объектов не пересекаются в пространстве признаков. Однако, природные объекты, как правило, неоднородны, а спектральные характеристики изучаемых объектов довольно близки и частично пересекаются (например, разных видов растительного покрова или почв). Поэтому широкое распространение получили методы класси-

фикации, основанные на *статистическом подходе*, которые позволяют учитывать вариации признаков и допускают отнесение пикселей к «чужим» классам, если частота их появления относительно мала.

Вопрос 4.1.3. Метод классификации по минимальному расстоянию

Это один из методов классификации, основанный на *детерминированном*




Рис 4.1. Классификация по минимальному расстоянию

подходе. Он прост в вычислительном отношении. **Смысл метода** заключается в отнесении пиксела к тому эталонному классу, евклидово расстояние до центра которого в пространстве признаков **минимально** (рис 4.1).

Обучающая выборка используется для вычисления средних значений яркости, характеризующих каждый класс. Для каждого пиксела вычисляются расстояния до центров (средних значений яркости) классов, затем ему присваивается название класса, расстояние до которого минимально. Этот способ

целесообразно использовать при ограниченном числе классов в обучающей выборке.

Для успешной классификации необходимо, чтобы значения спектральной яркости объектов компактно группировались вокруг средних значений соответствующих классов.

Результат классификации приведен на рис 4.2. б.

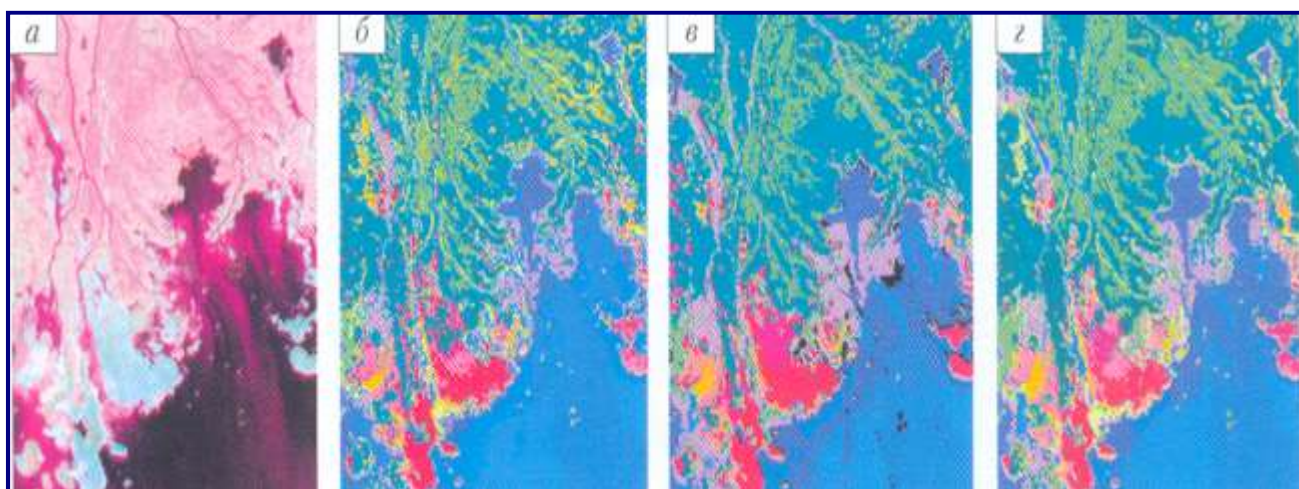


Рис 4.2. Фрагмент цветного синтезированного космического снимка (а) и результаты классификации: б - по методу минимального расстояния; в - по методу параллелипипеда; г - по методу максимального правдоподобия

Вопрос 4.1.4. Метод параллелепипедов

Реализует наиболее простой алгоритм, основанный на *статистическом подходе*. Он заключается в отнесении пикселей изображения к эталонным классам. В качестве эталонных характеристик классов задаются некоторые интервалы значений яркости. Они выбираются в *результате анализа гистограммы* распределения яркости на изображении. В пространстве признаков интервалы значений яркости определяют замкнутую область, которая в зависимости от размерности поля признаков может иметь форму параллелограмма, параллелепипеда или гиперпараллелепипеда для четырех и более зон (рис 4.3). На рис.4,3. показан принцип выбора интервалов значения яркости для двух объектов. Классификация всех пикселей снимка, состоящего, например, из трех съемочных зон, заключается в отнесении каждого из них к тому классу объектов, в параллелепипед которого он попадает по своим значениям яркости.




Рис 4.3. Сущность метода параллелепипеда

Преимущества: простота обучения и использования

Недостатки: пиксели в областях между параллелепипедами не классифицируются; пиксели в областях перекрывающихся параллелепипедов не могут быть классифицированы

Вопрос 4.3.5. Метод максимального правдоподобия




Рис 4.4. Сущность метода максимального правдоподобия

Также основан на *статистическом подходе*. Смысл этого метода сводится к определению вероятности попадания пиксела в тот или иной класс. Данный способ классификации использует условие **максимальной вероятности отнесения пиксела к тому или иному классу (максимальное правдоподобие)**

На рис. показано двумерное множество признаков обучающей выборки с тремя спектральными классами. Каждый из них имеет нормальное распределение значений яркости, и *вертикальная ось характеризует вероятность попадания пиксела в данный класс.*

Достоверность результатов контролируемой классификации зависит в первую очередь **от качества обучающей выборки**, т.е. от того, насколько правильно выбраны пикселы, используемые в качестве эталонных. Не меньшее значение имеет и характер классифицируемых объектов.

Наилучшие результаты дает классификация **однородных объектов с малым разбросом значений яркости**. Географические объекты иногда представляют собой сочетание комплексов более низкого ранга, различающихся по своим спектральным свойствам. Если части объекта, например **городской территории, меньше по размеру пиксела изображения**, но при этом они (дома, улицы, зеленые насаждения) различаются по яркостным свойствам, **результаты классификации могут оказаться неудовлетворительными**. Городская территория будет представлять пеструю картину чередования пикселов, относящихся к разным классам или не отнесенных ни к одному из них (неклассифицированных). Причина заключается в том, что вклад яркости каждого из малых объектов в интегральную яркость соседствующих пикселов оказывается различным.

Пограничные пикселы, яркость которых интегрирована из яркости двух соседних объектов, также часто не относятся ни к одному из соседствующих классов, а определяются как любые другие классы. По той же причине, **как правило, не поддаются классификации линейные объекты, изображающиеся одним-двумя пикселами.**

Вопрос 4.2. Вероятностный анализ классов изображений.

Классификация изображений на основе статистического анализа используется для разделения изображений на различные категории. Этот метод включает в себя анализ статистических свойств изображений, таких как гистограмма яркости, корреляция пикселей и другие. Затем эти данные используются для определения того, к какой категории относится изображение.

Говоря о статистических методах распознавания, мы предполагаем установление связи между отнесением объекта к тому или иному классу (образу) и вероятностью ошибки при решении этой задачи. В ряде случаев это сводится к определению апостериорной вероятности принадлежности объекта образу s_i при условии, что признаки этого объекта приняли значения x_1, x_2, \dots, x_N . Начнём с байесовского решающего правила. По формуле Байеса

$$p(s_i / x_1, \dots, x_N) = \frac{P_0(s_i) p(x_1, \dots, x_N / s_i)}{\sum_{j=1}^M P_0(s_j) p(x_1, \dots, x_N / s_j)}.$$

Здесь $P_0(s_i)$ – априорная вероятность предъявления к распознаванию объекта i -го образа:

$$P_0(s_i) > 0, \quad \sum_{i=1}^M P_0(s_i) = 1.$$

для каждого s_i

$$\int_{x_1} \dots \int_{x_N} p(x_1, \dots, x_N / s_i) dx_1 \dots dx_N = 1,$$

при признаках с непрерывной шкалой измерений

$$\sum_{j_1=1}^{x_1} \dots \sum_{j_N=1}^{x_N} p(x_1^{j_1}, x_2^{j_2}, \dots, x_N^{j_N} / s_i) = 1,$$

при признаках с дискретной шкалой измерений

$$p(x_1, \dots, x_N / s_i) \geq 0.$$

При непрерывных значениях признаков $p(x_1, \dots, x_N / s_i)$ представляет из себя функцию плотности вероятностей, при дискретных – распределение вероятностей.

Распределения, описывающие разные классы, как правило, "пересекаются", то есть имеются такие значения признаков x_1, \dots, x_N , при которых

$$p(x_1, \dots, x_N / s_i) \cdot p(x_1, \dots, x_N / s_j) > 0.$$

В таких случаях ошибки распознавания неизбежны. Естественно, неинтересны случаи, когда эти классы (образы) в выбранной системе признаков $(\bar{X}_1, \dots, \bar{X}_N)$ неразличимы (при равных априорных вероятностях решения можно выбирать случайным отнесением объекта к одному из классов равновероятным образом).

В общем случае нужно стремиться выбрать решающие правила так, чтобы минимизировать риск потерь при распознавании.

Риск потерь определяется двумя компонентами: вероятностью ошибок распознавания и величиной "штрафа" за эти ошибки (потерями). Матрица ошибок распознавания:

$$\begin{array}{cccccc}
 & s_1 & s_2 & s_3 & \dots & s_M \\
 s_1 & p_{11} & p_{12} & p_{13} & & p_{1M} \\
 s_2 & p_{21} & p_{22} & p_{23} & & p_{2M} \\
 & & & & & \\
 s_M & p_{M1} & p_{M2} & p_{M3} & & p_{MM} ,
 \end{array}$$

где p_{ii} – вероятность правильного распознавания;

p_{ij} – вероятность ошибочного отнесения объекта i -го образа к j -му ($i \neq j$).

Матрица потерь

$$\begin{array}{cccccc}
 & s_1 & s_2 & s_3 & \dots & s_M \\
 s_1 & u_{11} & u_{12} & u_{13} & & u_{1M} \\
 s_2 & u_{21} & u_{22} & u_{23} & & u_{2M} \\
 & & & & & \\
 s_M & u_{M1} & u_{M2} & u_{M3} & & u_{MM} ,
 \end{array}$$

где u_{ii} – "премия" за правильное распознавание;

u_{ij} – "штраф" за ошибочное отнесение объекта i -го образа к j -му ($i \neq j$).

Необходимо построить решающее правило так, чтобы обеспечить минимум математического ожидания потерь (минимум среднего риска). Такое правило называется байесовским.

Разобьём признаковое пространство X на M непересекающихся областей v_j ($j = 1, 2, \dots, M$), каждая из которых соответствует определённому образу.

Средний риск при попадании реализаций q -го образа в области других образов равен

$$r_q = \sum_{j=1}^M u_{qj} \int_{v_j} p(x_1, x_2, \dots, x_N / s_q) dx_1 \dots dx_N, \quad q \neq j.$$

Здесь предполагается, что все компоненты X имеют непрерывную шкалу измерений (в данном случае это не принципиально).

Величину r_q можно назвать условным средним риском (при условии, что совершена ошибка при распознавании объекта q -го образа). Общий (безусловный) средний риск определяется величиной

$$R = \sum_{q=1}^M P_0(s_q) r_q.$$

Решающие правила (способы разбиения X на $v_j, j = 1, \dots, M$) образуют множество D . Наилучшим (байесовским) решающим правилом является то, которое

обеспечивает минимальный средний риск $R_B = \min_D R_D$, где R_D – средний риск при применении одного из решающих правил, входящих в D .

Рассмотрим упрощённый случай. Пусть $u_{ii} = 0$, а $u_{ij} = 1$ ($i \neq j$). В таком случае байесовское решающее правило обеспечивает минимум вероятности (среднего количества) ошибок распознавания. Пусть $M = 2$. Вероятность ошибки первого рода (объект 1-го образа отнесён ко второму образу)

$$p_{12} = \int_{v_2} p(\bar{x} / s_1) d\bar{x},$$

где $\bar{x} = \{x_1, \dots, x_N\}$ – вероятность ошибки второго рода

$$p_{21} = \int_{v_1} p(\bar{x} / s_2) d\bar{x}.$$

Средние ошибки

$$P_{ou} = P_0(s_1)p_{12} + P_0(s_2)p_{21}.$$

Так как $\int_x p(\bar{x} / s_i) d\bar{x} = 1$, то $p_{12} = 1 - \int_{v_1} p(\bar{x} / s_1) d\bar{x}$ и

$$P_{ou} = P_0(s_1) + \int_{v_1} [P_0(s_2)p(\bar{x} / s_2) - P_0(s_1)p(\bar{x} / s_1)] d\bar{x}.$$

Ясно, что минимум P_{ou} будет иметь

минимум в том случае, если подынтегральное выражение в области v_1 будет строго отрицательным, то есть в v_1 $P_0(s_1)p(\bar{x} / s_1) > P_0(s_2)p(\bar{x} / s_2)$. В области v_2 должно выполняться противоположное неравенство. Это и есть байесовское решающее правило для рассматриваемого случая. Оно может быть записано иначе:

$\frac{p(\bar{x} / s_1)}{p(\bar{x} / s_2)} > \frac{P_0(s_2)}{P_0(s_1)}$; величина $p(\bar{x} / s_i)$, рассматриваемая как функция от s_i , называется правдоподобием s_i при данном \bar{x} , а $\frac{p(\bar{x} / s_1)}{p(\bar{x} / s_2)}$ – отношением правдоподобия.

Таким образом, байесовское решающее правило можно сформулировать как рекомендацию выбирать решение s_1 в случае, если отношение правдоподобия превышает определённое пороговое значение, не зависящее от наблюдаемого \bar{x} .

Без специального рассмотрения укажем, что если число распознаваемых классов больше двух ($S > 2$), решение в пользу класса (образа) s_j принимается в области v_j , в которой для всех $i \neq j$ $P_0(s_j)p(\bar{x} / s_j) > P_0(s_i)p(\bar{x} / s_i)$.

Иногда при невысокой точности оценки апостериорной вероятности (малых объёмах обучающей выборки) используют так называемые рандомизированные решающие правила. Они состоят в том, что неизвестный объект относят к тому или иному образу не по максимуму апостериорной вероятности, а случайным образом, в соответствии с апостериорными вероятностями этих образов $p(s_i / \bar{x}^*)$. Реализовать это можно, например, способом, изображённым на рис. 4.5.




Рис. 4.5. Иллюстрация рандомизированного решающего правила

После вычисления апостериорных вероятностей принадлежности неизвестного объекта с параметрами \bar{x}^* каждому из образов s_i , $i = 1, \dots, S$, отрезок прямой длиной единица разбивают на S интервалов с длинами, численно равными $p(s_i / \bar{x}^*)$, и каждому интервалу ставят в соответствие этот образ. Затем с помощью датчика случайных (псевдослучайных) чисел, равномерно распределённых на $[0,1]$, генерируют число, определяют интервал, в который оно попало, и относят распознаваемый объект к тому образу, которому соответствует данный интервал.

Понятно, что такое решающее правило не может быть лучше байесовского, но при больших значениях отношения правдоподобия ненамного ему уступает, а в реализации может оказаться достаточно простым (например, метод ближайшего соседа, о чём речь пойдёт позже).

Байесовское решающее правило реализуется в компьютерах в основном двумя способами.

1. Прямое вычисление апостериорных вероятностей

$$p(s_i / \bar{x}^*) = \frac{P_0(s_i)p(\bar{x}^*/s_i)}{\sum_{j=1}^M P_0(s_j)p(\bar{x}^*/s_j)},$$

где $\bar{x}^* = \{x_1^*, x_2^*, \dots, x_N^*\}$ – вектор значений параметров распознаваемого объекта и выбор максимума. Решение принимается в пользу того образа, для которого $p(s_i / \bar{x}^*)$ максимально. Иными словами, байесовское решающее правило реализуется решением задачи $\arg \left\{ \max_i p(s_i / \bar{x}^*) \right\}$.

Если пойти на дальнейшее обобщение и допустить наличие матрицы потерь общего вида, то условный риск можно определить по формуле $p(s_i / \bar{x}^*)u_{ii} - \sum_{j=1}^M p(s_j / \bar{x}^*)u_{ij}$, $i \neq j$. Здесь первый член определяет "поощрение" за правильное распознавание, а второй – "наказание" за ошибку. Байесовское решающее правило в данном случае состоит в решении задачи

$$\arg \left\{ \max_i \left[p(s_i / \bar{x}^*)u_{ii} - \sum_{j=1}^M p(s_j / \bar{x}^*)u_{ij} \right] \right\}, i \neq j.$$

2. "Топографическое" определение области v_i , в которую попал вектор \bar{x}^* значений признаков, описывающих распознаваемый объект.

Такой подход используют в тех случаях, когда описание областей v_i достаточно компактно, а процедура определения области, в которую попал \bar{x}^* , проста. Иными словами, данный подход естественно использовать, когда в вычислительном отношении он эффективнее (проще), чем прямое вычисление апостериорных вероятностей.

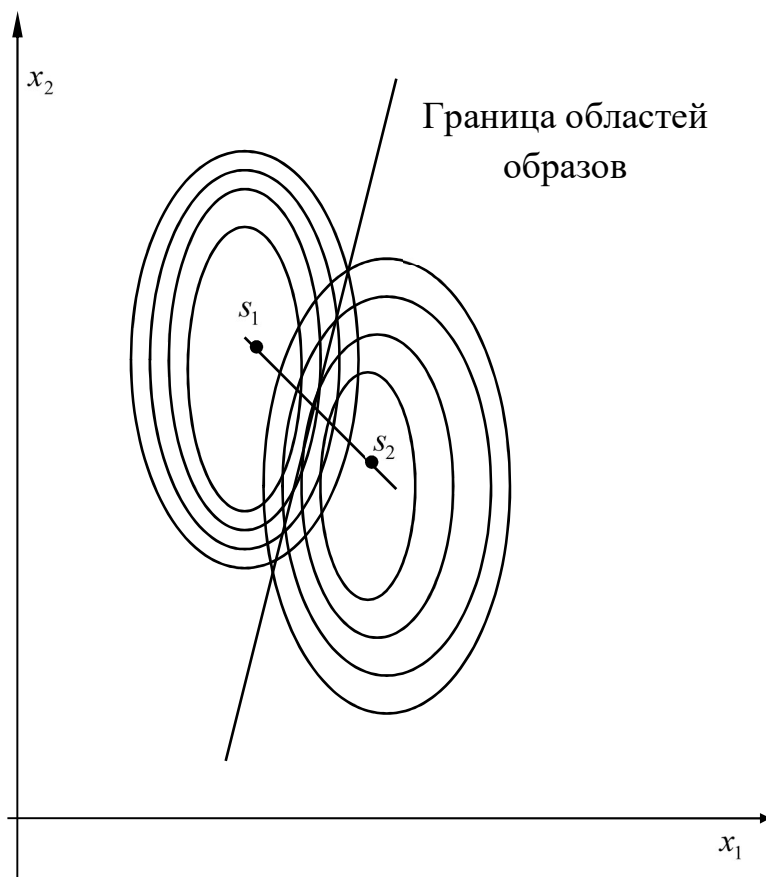


Рис. 4.6. Байесовское решающее правило для нормально распределённых признаков с равными ковариационными матрицами

Так, например (доказательство приводить не будем), если классов два, их априорные вероятности одинаковы, $p(\bar{x} / s_1)$ и $p(\bar{x} / s_2)$ – нормальные распределения с одинаковыми ковариационными матрицами (отличаются только векторами средних), то байесовская разделяющая граница – гиперплоскость. Запоминается она значениями коэффициентов линейного уравнения. При распознавании какого-либо объекта в уравнение подставляют значения признаков \bar{x}^* этого объекта и по знаку (плюс или минус) получаемого решения относят объект к s_1 или s_2 (рис. 19).

Если у классов s_1 и s_2 ковариационные матрицы $p(\bar{x} / s_1)$ и $p(\bar{x} / s_2)$ не только одинаковы, но и диагональны, то байесовским решением является отнесение объекта к тому классу, евклидово расстояние до эталона которого минимально (рис. 4.7).




Рис. 4.7. Байесовское решающее правило для нормально распределённых признаков с равными диагональными ковариационными матрицами (элементы диагоналей одинаковы)

Таким образом, мы убеждаемся в том, что некоторые решающие правила, ранее рассмотренные нами как эмпирические (детерминированные, эвристические), имеют вполне чёткую статистическую трактовку.

Вопрос 4.3. Анализ классов изображений по методу главных компонент

Полосы многоспектральных изображений часто оказываются коррелированными, т. е. они визуально и количественно похожи между собой. Подобная корреляция может возникать по целому ряду причин.

- *Корреляция спектральных свойств объектов.* Такая корреляция возникает, например, при относительно низкой отражательной способности растительного покрова в видимой части спектра, что приводит к схожести спектральных образов объектов во всех диапазонах регистрации видимого излучения. Диапазон длин волн, соответствующий высокой корреляции, определяется спектральной отражательной способностью объектов.

- *Топография.* На практике уровень затенения, возникающего из-за топографических особенностей местности, можно считать одинаковым во всех диапазонах регистрации отраженного солнечного излучения. Теневая компонента может доминировать при съемке гористой местности или при съемке на закате или восходе Солнца. В результате возникает корреляция между диапазонами, которая не зависит от типа объекта на поверхности..

- *Наложение диапазонов регистрации.* В идеальном случае этот фактор должен быть исключен еще на этапе разработки датчика, однако на практике такого наложения редко удается избежать полностью. Хотя интервал наложения, как правило, невелик, его величину необходимо знать для точной калибровки

данных.

Описанная корреляция приводит к избыточности информации, из-за чего анализ данных в исходных спектральных диапазонах становится неэффективным. Для преодоления избыточности используют метод преобразования к главным компонентам¹, которое определяется в пространстве исходных спектральных признаков (Ready и Wintz, 1973) и имеет вид с нулевым вектором смещения V и матрицей W_{PC} , которые определяются независимо для каждого снимка:

$$PC = W_{PC}DN.$$

Соответствующее преобразование для ковариационной матрицы записывается следующим образом:

$$C_{PC} = W_{PC}C W_{PC}^T.$$

Преобразование к главным компонентам является оптимальным в том смысле, что это единственное преобразование, которое приводит ковариационную матрицу исходного многоспектрального снимка к диагональному виду.

Собственное значение λ_k определяется как k -й корень характеристического уравнения:

$$|C - \lambda I| = 0,$$

где C — ковариационная матрица исходных данных,

а I — диагональная матрица тождественного преобразования.

Каждое из собственных значений матрицы равно дисперсии главного компонента изображения вдоль новых координатных осей. Поэтому сумма всех собственных значений должна равняться сумме дисперсий, рассчитанных для всех спектральных диапазонов исходного снимка тем самым сохраняя суммарную дисперсию данных

Поскольку матрица C_{PC} диагональная, изображения, соответствующие главным компонентам, являются некоррелированными. Такие изображения принято нумеровать в порядке убывания дисперсии, поэтому первая главная компонента соответствует наибольшей дисперсии, а главная компонента с номером k — наименьшей. Результатом преобразования снимков к главным компонентам является устранение корреляционной зависимости между исходными n -мерными данными при одновременном сжатии большей части дисперсии полного изображения до меньшей размерности.

Координатные оси в пространстве главных компонент определяются K собственными векторами e_k . Собственный вектор, соответствующий собственному значению находится из следующего векторно-матричного уравнения:

$$(C - \lambda_k I)e_k = 0 \quad (5.22)$$

Рассмотрим некоторые свойства преобразования к главным компонентам:

• *Преобразование к главным компонентам является жестким вращением, при котором совмещаются оси исходной системы координат k -мерного пространства с главными осями набора данных.*

¹ Иногда это преобразование называют также преобразованием Кахунена — Лоева (Karhunen-Loeve) или преобразованием Хёллеллинга (Hotelling).

Хотя в k -мерном пространстве главных компонент оси системы координат ортогональны, их проекции в пространстве исходных данных могут не обладать этим свойством

Преобразование набора данных к главным компонентам приводит к оптимальному перераспределению дисперсий.

Матрица преобразования W_{PC} зависит от исходного набора данных.

Главные компоненты более высокого порядка содержат, как правило, меньше полезной информации и больше шума, то есть фактически мы имеем дело с сжатием данных.

Преобразование к главным компонентам можно применять и для анализа многовременных данных. Если снимки, полученные в разные даты, анализировать без учета временной составляющей, то их преобразование к главным компонентам будет носить пространственно-временной характер, и результат такого преобразования будет довольно трудно интерпретировать. В то же время, если область снимка, на которой происходят изменения, относительно мала, то все изменения будут особенно четко видны на изображениях, соответствующих главным компонентам высших порядков. (Richards, 1984; Ingebritsen и Lyon, 1985). Анализ временных изменений можно упростить, если сначала вычислить по двум многоспектральным снимкам разностное изображение, а затем применить к нему метод главных компонент.

Вопрос 4.3.1. Стандартизованный метод главных компонент

Как полагают некоторые исследователи, для анализа данных дистанционного зондирования более подходящим является метод главных компонент, основанный на расчете собственных векторов не ковариационной, а корреляционной матрицы (Singh и Harrison, 1985). В этом случае данные нормализуются так, что

Таблица 4.1. Примеры использования метода главных компонент для анализа многовременных наборов данных космической съемки

Данные	Описание	Преобразование	Библиографическая ссылка
MSS	Земной покров, две даты съемки	8D	Вутеидр., 1980
	Пожары, две даты съемки	8D	Richards, 1984
	Открытые горные работы, две	8D	Ingebritsen и Lyon, 1985
	Земной покров, две даты съемки	8D	Fung и LeDrew, 1987
Индекс $NDVI$ по данным AVHRR	36 наборов данных $NDVI$, ежемесячная съемка	36D	Eastman и Fulk, 1993
TM	Нормализация данных $NDVI$ по времени	2D	Du и др., 2002
Обзорная статья	Определение изменений в экосистеме	—	Coppin и др., 2004
Обзорная статья	Определение изменений	—	Lu и др., 2004

Вопрос 4.3.2. Метод главных компонент с минимизацией шума

Данный метод², впервые предложенный в работе Грина и соавт. (Green и др., 1988), является модификацией обычного метода главных компонент и позволяет эффективно подавлять шум, присутствующий в небольшом числе исходных спектральных каналов. Этот метод особенно полезен для анализа гиперспектральных данных, для которых характерны значительные вариации значений отношения сигнал/шум в зависимости от спектрального канала. К сожалению, для корректного применения этого метода необходимо иметь более или менее точную оценку ковариационной матрицы шума в спектральном диапазоне.

Вопрос 4.4. Преобразование «колпак с кисточкой»

Коэффициенты преобразования к главным компонентам являются функциями ковариационной матрицы спектральных данных. Благодаря этому свойству алгоритм преобразования хорошо адаптируется к конкретному набору данных и обеспечивает оптимальные свойства преобразования с точки зрения сжатия информации. С другой стороны, это же свойство существенно затрудняет сравнение результатов преобразования, полученных для разных изображений. Хотя главные компоненты можно проинтерпретировать в терминах физических характеристик сцены, набор таких характеристик для разных сцен будет разным. По этой причине еще в эпоху запусков первых спутников Landsat стало понятно, что для анализа данных полезно иметь такое преобразование, которое позволяло бы использовать фиксированный набор физических характеристик.

Впервые такой набор характеристик, или признаков, предназначенных для мониторинга состояния сельскохозяйственных культур с помощью аппаратуры Landsat MSS, был предложен в работе Каута и Томаса (Kauth и Thomas, 1976). Как было замечено авторами этой работы, диаграммы рассеяния значений пикселей сельскохозяйственных областей обладают некоторыми постоянными свойствами, в частности треугольной формой распределения точек между полосам 4 и 2 (рис. 5.7). Если визуализировать подобные распределения в процессе созревания культуры, то они образуют в пространстве \wedge -измерений геометрическую фигуру, имеющую форму «колпака с кисточкой»

Основание этой фигуры называют плоскостью почв. По мере роста и созревания растений соответствующие пиксели стремятся занять место ближе к кончику колпака, а во время периода увядания вновь опускаются к основанию. Каут и Томас предложили линейное преобразование для четырех каналов съемочной системы MSS, в результате которого все данные преобразовывались к новой системе координат. Первая координата этой системы, названная яркостью почв, определяется спектральным образом тех областей, которые свободны от

² В англоязычной литературе используются три эквивалентных названия этого метода: Maximum Noise Fraction (MNF), Noise-Adjusted Principal Components (NAPC) (Lee и др., 1990), Minimum Noise Fraction (RSI, 2005).

растительности. Вторая координатная ось («зеленка») ортогональна первой и характеризует спектральный образ растительности, а оставшиеся две оси («желтое вещество» и «прочее») выбираются так, чтобы быть ортогональными двум первым.

Преобразование «колпак с кисточкой» является частным случаем линейного преобразования со специальной матрицей W_{rc} :

$$TC = W_{rc}DN + B. \quad (5.24)$$

В отличие от матрицы преобразования к главным компонентам, матрица преобразования «колпак с кисточкой» фиксирована для заданного датчика и не зависит от характеристик сцены съемки. В табл. 5.2 приведены значения элементов этой матрицы для аппаратуры Landsat-1 MSS (Kauth и Thomas, 1976), Landsat-2 MSS (Thompson и Whemanen, 1980), Landsat-4 TM (Crist и Cicone, 1984), Landsat-5 TM (Crist и др., 1986) и Landsat-7 ETM+ (Huang и др., 2002). Как и в методе главных компонент, оси новой системы координат в случае преобразования «колпак с кисточкой» ортогональны друг другу в K -мерном пространстве. При проецировании осей на пространство меньшей размерности это свойство теряется/

Основной причиной введения преобразования «колпак с кисточкой» было желание получить такой фиксированный набор координатных осей в пространстве признаков, который характеризовал бы физические свойства растительности на Среднем Западе США. Ось почв соответствует тому периоду времени, когда еще нет никаких всходов. По мере созревания культуры ее образ в пространстве спектральных признаков «смещается» от этой оси к оси зеленого цвета. Затем в период увядания растительности ее зеленая компонента становится все меньше, а желтая все больше. При применении этого преобразования в других климатических зонах его компоненты можно интерпретировать аналогичным образом, однако часть информации при этом может быть утеряна. В частности, в преобразованных данных могут быть неразличимы разные незеленые виды растительности и некоторые типы почв (Crist, 1996). При анализе данных MSS было показано, что компоненты преобразования «желтое вещество» и «прочее» позволяют отслеживать изменения, связанные с атмосферной дымкой, и, следовательно, их можно для калибровки снимков.

Таблица. 4.2. Коэффициенты преобразования «колпак с кисточкой» для некоторых датчиков. Коэффициенты преобразования для четвертого канала аппаратуры MSS соответствуют диапазону значений пикселей 0—63, а для других каналов — диапазону значений 0—127. Для ИСЗ Landsat-4 и Landsat-5 представленные коэффициенты соответствуют исходным данным, а для ИСЗ Landsat-7 — данным об отражательной способности объектов после внесения поправок на влияние атмосферы. Коэффициенты преобразования для аппаратуры Landsat-5 ТМ получены с учетом соответствующих коэффициентов для ИСЗ Landsat-4 — представленные в таблице аддитивные члены необходимы для сравнения характеристик результатов преобразования, полученных для этих двух датчиков (Crist и др., 1986)

Датчик	Название оси	W_{TC}						Смещение	
		Каналы 12		3	4				
L-1 MSS	Яркость почвы			0,433	0,632	0,586	0,264		
	Зелень			-0,290	-0,562	0,600	0,491		
	Желтое вещество			0,829	0,522	-0,039	0,194		
	Прочее			0,233	0,120	-0,543	0,810		
L-2 MSS	Яркость почвы			0,332	0,603	0,676	0,263		
	Зелень			0,283	-0,660	0,577	0,388		
	Желтое вещество			0,900	0,428	0,0759	-0,041		
	Прочее			0,016	0,428	-0,452	0,882		
		Каналы	1	2	3	4	5	6	
L-4 ТМ	Яркость почвы	0,3037		0,2793	0,4743	0,5585	0,5082		
	Зелень			0,1863					
	Влажность	-0,2848	-0,2435		-0,5436	0,7243	0,0840	-0,1800	
	Дымка	0,1509	0,1973		0,3279	0,3406	-0,7112	-0,4572	
	ТС5	0,8242	-0,0849		-0,4392	-0,0580	0,2012	-0,2768	
L-5 ТМ	Яркость почвы	0,2909	0,2493	0,4806	0,5568	0,4438	0,1706	10,369-	
	Зелень	-0,2728	-0,2174	-0,5508	0,7221	0,0733	-0,1648	0,7310 -	
	Влажность	0,1446	0,1761	0,3322	0,3396	-0,6210	-0,4186	3,3828	
	Дымка	0,8461	-0,0731	-0,4640	-0,0032	-0,0492	0,0119	0,7879	
	ТС5	0,0549	-0,0232	0,0339	-0,1937	0,4162	-0,7823	-2,4750 -	
L-7 ETM+	Яркость почвы	0,3561	0,3972	0,3904	0,6966	0,2286			
	Зелень			0,1596					
	Влажность	-0,3344	-0,3544	-0,4556	0,6966	-0,0242	-0,2630		
	Дымка	0,2626	0,2141	0,0926	0,0656	-0,7629	-0,5388		
	ТС5	0,0805	-0,0498	-0,1950	-0,1327	0,5752	-0,7775		
L-7 ETM+	ТС5	-0,7252	-0,0202	0,6683	0,0631	-0,1494	-0,0274		
	ТС6	0,4000	-0,8172	0,3832	0,0602	-0,1095	0,0985		

Вопрос 4.5. Вегетационные индексы

Вегетационный индекс (ВИ) это показатель, рассчитываемый в результате операций с разными спектральными диапазонами (каналами) ДДЗ, и имеющий отношение к параметрам растительности в данном пикселе снимка. Эффективность ВИ определяется особенностями отражения; эти индексы выведены, главным образом, эмпирически.

При всем своем разнообразии большей частью вегетационные индексы работают для территорий с разреженным растительным покровом очень плохо. Если растительный покров скудный, то спектр снимка в основном зависит от почвы. Почвы могут различаться очень сильно по отражению, даже если для анализа используются очень широкие спектральные диапазоны. Hueteetal. (1985) и ElvidgeandLyon (1985) показали, что почвенный фон сильно влияет на индексы – если он яркий, то значение индекса будет меньше, если фон темный, то индекс будет больше. ElvidgeandLyon (1985) показали, что многие фоновые материалы (почва, камни, растительная подстилка) сильно варьируют в красном – ближнем инфракрасном диапазоне, и это может сильно изменить индекс. Для решения этих проблем более эффективным методом является применение анализа спектральных смесей.

Для определенных ВИ существуют свои пороги чувствительности к разреженности растительности (например NDVI не стоит применять, если растительный покров меньше 30%):

- RVI, NDVI, IPVI = 30%
- SAVI, MSAVI1, MSAVI2 = 15%
- DVI = 30%
- PVI, WDV, GVI = 15%

NDVI – самый известный индекс и ему больше всего доверяют. 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. Для того чтобы просто посмотреть на растительность на снимке с количественной точки зрения, нет ничего лучшего, чем NDVI, только если вы не имеете территорию с бедной растительностью.

NDVI (Normalized Difference Vegetation Index) - нормализованный относительный индекс растительности - простой количественный показатель количества фотосинтетически активной биомассы (обычно называемый вегетационным индексом). Один из самых распространенных и используемых индексов для решения задач, использующих количественные оценки растительного покрова. Вычисляется по следующей формуле :

$$NDVI = \frac{NIR - RED}{NIR + RED}$$

где, NIR - отражение в ближней инфракрасной области спектра;

RED - отражение в красной области спектра

Согласно этой формуле, плотность растительности (NDVI) в определенной точке изображения равна разнице интенсивностей отраженного света в красном и инфракрасном диапазоне, деленной на сумму их интенсивностей.

Расчет NDVI базируется на двух наиболее стабильных (не зависящих от прочих факторов) участках спектральной кривой отражения сосудистых растений. В красной области спектра (0,6-0,7 мкм) лежит максимум поглощения солнечной радиации хлорофиллом высших сосудистых растений, а в инфракрасной области (0,7-1,0 мкм) находится область максимального отражения клеточных структур листа. То есть высокая фотосинтетическая активность (связанная, как правило, с густой растительностью) ведет к меньшему отражению в красной области спектра и большему в инфракрасной (рисунке 4.8). Отношение этих показателей друг к другу позволяет четко отделять и анализировать растительные от прочих природных объектов. Использование же не простого отношения, а нормализованной разности между минимумом и максимумом отражений увеличивает точность измерения, позволяет уменьшить влияние таких явлений как различия в освещенности снимка, облачности, дымки, поглощение радиации атмосферой и пр.




Рис. 4.8 – Участки характеристической кривой отражения растительности (усредненной), используемые для расчета NDVI с помощью данных MODIS

Для отображения индекса NDVI используется стандартизованная непрерывная градиентная или дискретная шкала, показывающая значения в диапазоне от -1...1

Благодаря особенности отражения в NIR -RED областях спектра, природные объекты, не связанные с растительностью, имеют фиксированное значение NDVI, что позволяет использовать этот параметр для их идентификации (табл. 4.3):

Таблица 4.3 – Значение коэффициента отражения в красной и инфракрасной области спектра для различных объектов

Тип объекта	Отражение в красной области спектра	Отражение в инфракрасной области спектра	Значение NDVI
Густая растительность	0.1	0.5	0.7
Разряженная растительность	0.1	0.3	0.5
Открытая почва	0.25	0.3	0.025
Облака	0.25	0.25	0
Снег и лед	0.375	0.35	-0.05
Вода	0.02	0.01	-0.25
Искусственные материалы (бетон, асфальт)	0.3	0.1	-0.5

Но, как правило, для задач связанных с картографированием растительности используют немасштабированную шкалу, начинающуюся с 0 (значения NDVI меньше 0 растительность принимать не может). Существует устойчивая корреляция между показателем NDVI и продуктивностью для различных типов экосистем (рис. 4.9)




Рис. 4.9 – Показатели NDVI для различных экосистем

Это свойство довольно активно используется для регионального картирования и анализа различных типов ландшафтов, оценке ресурсов и площадей биосистем в масштабе стран и континентов. Однако чаще, расчет NDVI употребляется на основе серии разновременных (разносезонных) снимков с заданным временным разрешением, позволяя получать динамическую картину процессов изменения границ и характеристик различных типов растительности (месячные вариации, сезонные вариации, годовые вариации).

Будучи искусственным безразмерным показателем NDVI предназначен для измерения эколого-климатических характеристик растительности, но в тоже время может показывать значительную корреляцию с некоторыми параметрами, совсем другой области:

- Продуктивностью (временные изменения)
- Биомассой
- Влажностью и минеральной (органической) насыщенностью почвы
- Испаряемостью (эвапотранспирацией)
- Объемом выпадаемых осадков
- Мощностью и характеристиками снежного покрова

Зависимость между этими параметрами и NDVI, как правило, не прямая и связана с особенностями исследуемой территории, ее климатическими и экологическими характеристиками, кроме этого, часто приходится учитывать временную разнесенность параметра и ответной реакции NDVI [16].

Благодаря всем этим особенностям, карты NDVI часто используются как один из промежуточных дополнительных слоев для проведения более сложных типов анализа. Результатами которых могут являться карты продуктивности лесов и сельхозземель, карты типов ландшафтов, растительности и природных зон, почвенные, аридные, фито-гидрологические и другие эколого-климатические карты. Так же, на его основе возможно получение численных данных для использования в расчетах оценки и прогнозирования урожайности и продуктивности, биологического разнообразия, степени нарушенности и ущерба от различных естественных и антропогенных бедствий, аварий и т.д.

В целом, главным преимуществом NDVI является легкость его получения: для вычисления индекса не требуется никаких дополнительных данных и методик, кроме непосредственно самой космической съемки и знания ее параметров.

Следует, однако, учитывать и главные недостатки использования NDVI-индекса:

- Невозможность использования данных, не прошедших этап радиометрической коррекции (калибровки);
- Погрешности, вносимые погодными условиями, сильной облачностью и дымкой - их влияние можно частично скорректировать использованием улучшенных коэффициентов и композитных изображений с сериями NDVI за несколько дней, недель или месяцев (MVC - MaximumValueComposite). Усредненные значения позволяют избежать влияния случайных и некоторых систематических погрешностей. Как показывает практика, это очень часто применяемый подход для подготовки данных для создания карт NDVI.

- Необходимостью для большинства задач сравнения полученных результатов с предварительно собранными данными тестовых участков (эталонов), в которых должны учитываться сезонные эколого-климатические показатели, как самого снимка, так и тестовых площадок на момент сбора данных. Особенно значимыми данные материалы становятся при расчетах продуктивности, запасах биомассы и прочих количественных показателях;

- Возможностью использования съемки только времени сезона вегетации для исследуемого региона. В силу своей привязанности к количеству фотосинтезирующей биомассы, NDVI не эффективен на снимках, полученных в сезон ослабленной или невегетирующей в этот период растительности.