第六章 遥感图像分类

概述-遥感图像计算机分类的一般原理

- 遥感图像的解译

目视解译

计算机自动解译

- 光谱特征

如图：

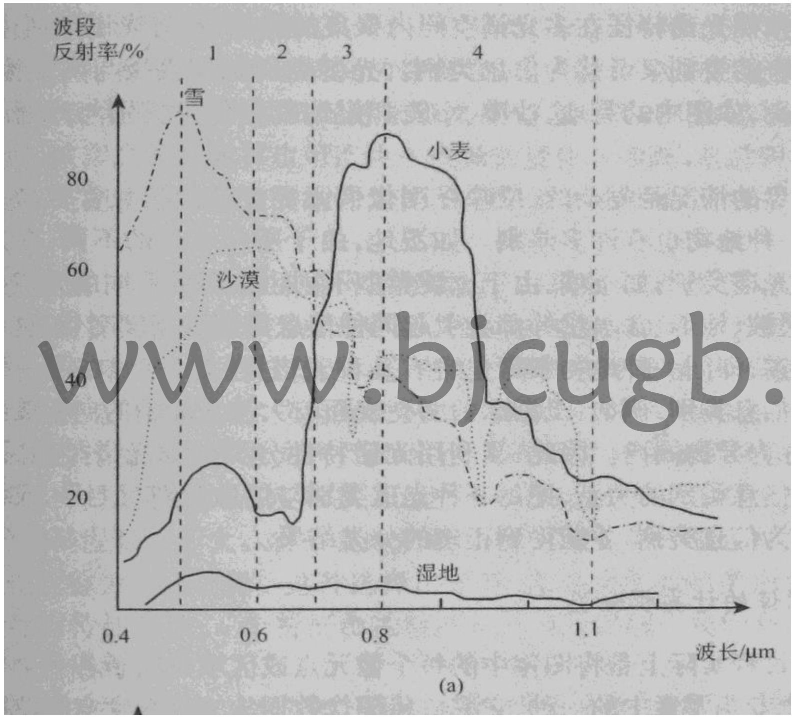

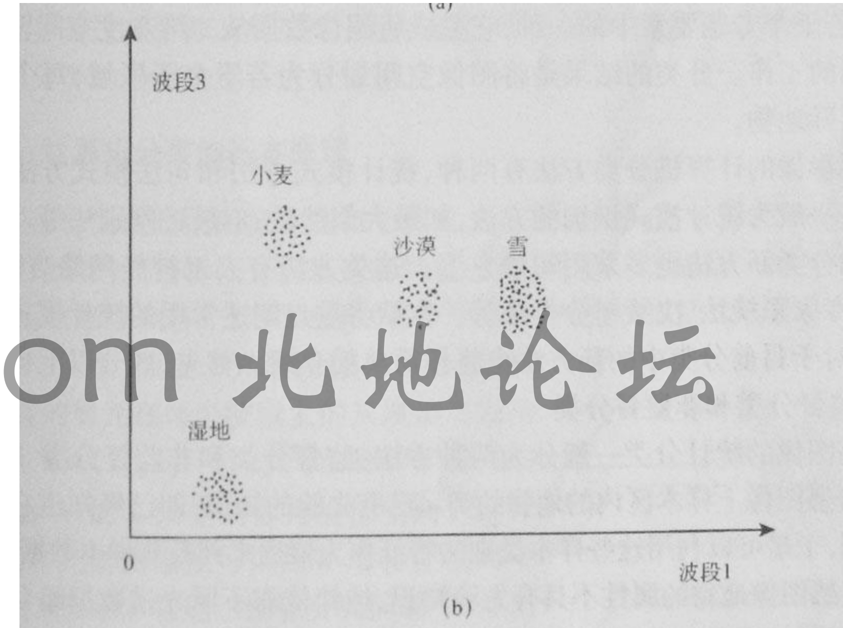

图 6.1 地物反射率差异图

这种同类聚集的特性说明，如果按照地物类别聚集的规律把多光谱空间划分为若干个子空间，每一子空间包含有一个类别，这样就可以把图像中未知的像元进行分类，把他们分配到各自的子空间中去。

遥感图像的计算机分类

1监督分类和非监督分类

监督分类：基于对于图像上样本区内的地物类属已有先验的知识，即已经知道它所对应的地物类别，于是可以利用这些样本类别的特征作为依据来判断非样本数据的类别；

遥感图像的计算机分类

1 监督分类和非监督分类

非监督分类：遥感图像地物的属性不具有先验知识，纯粹依靠不同光谱数据组合在统计上的差别来进行“盲目分类”，事后再对已分出各类的地物属性进行确认的过程。

2计算机分类处理（监督分类）的一般过程

1）原始图像的预处理

2）训练区的选择

3）特征选择和特征提取

4）图像分类运算

5）检验结果

- 计算机分类的基本原理

$$X=(x_1,x_2,\ldots x_n)^T$$

称作某像元的特征值，包含X的n维空间称为特征空间，因此n个波段的多光谱便可以用n维空间中的一系列点来表示。

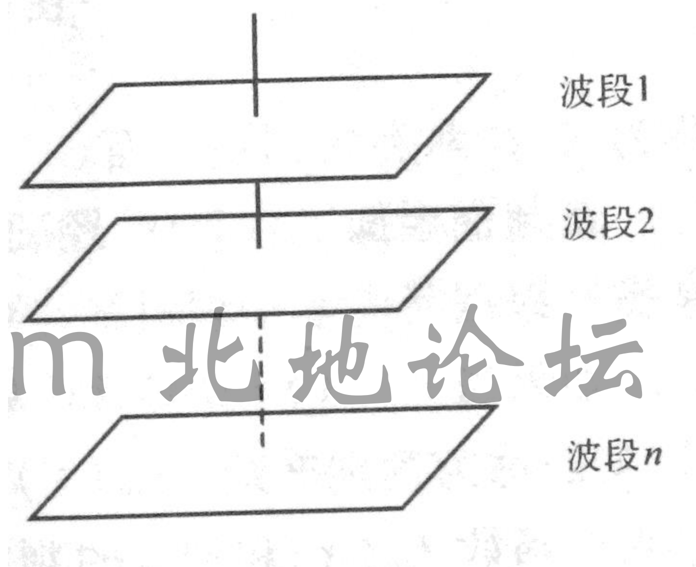

图 6.2　多光谱图像的例子

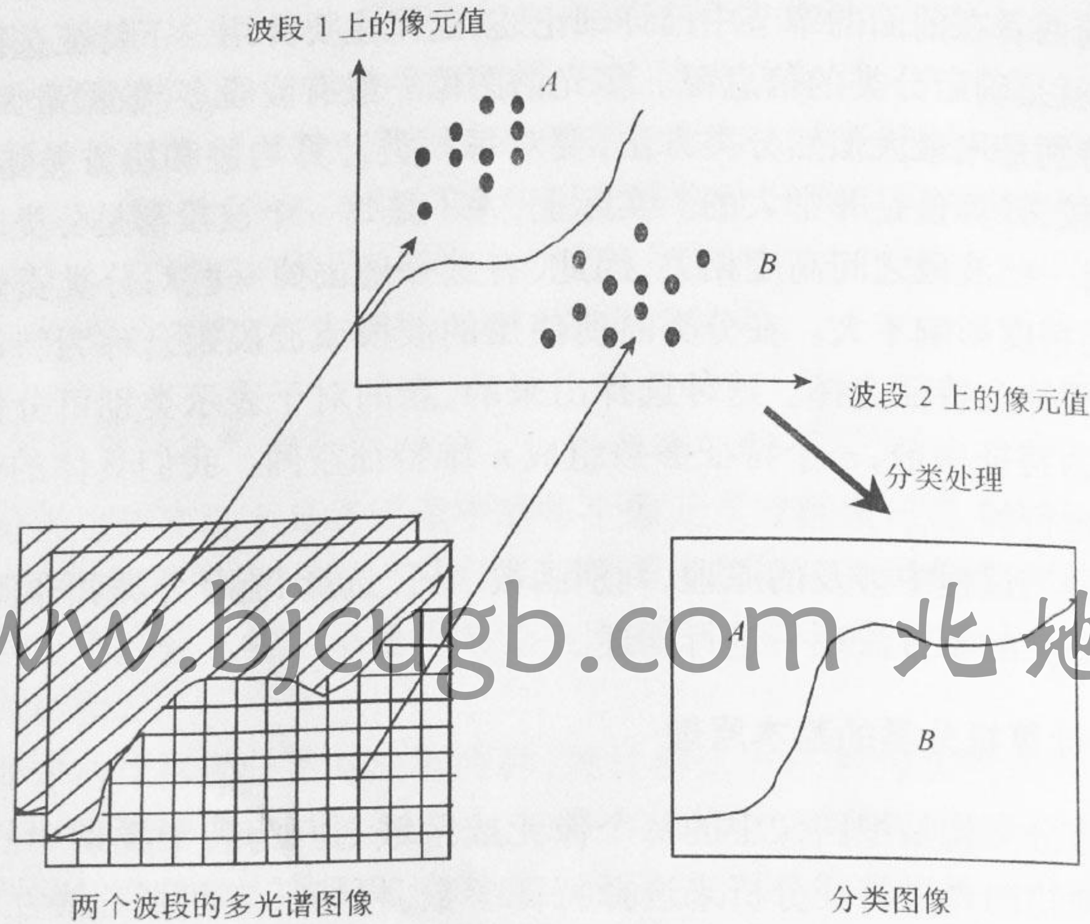

图 6.3 多光谱图像分类原理

$f_{AB}(X)$ 称为A，B两类的判别函数 $\begin{matrix} f_{AB}(X)>0, \text{则} X \in S_A \\ f_{AB}(X)<0, \text{则} X \in S_B \end{matrix}$ 称为判别准则。

判别函数

$$d_i(x_k)(i=1,2,\ldots,n)$$

若 $d_i(x_k) < d_j(x_k), i \neq j$，则k像元属于i类，否则k不属于i类。此处，$d(x)$ 就成为距离判别函数

判别函数

运用距离判别函数时，要求各个类别集群的中心位置Mi(均值）是已知的，对于光谱特征空间中的任一点k，计算它到各类中心点的距离

$$d_i(x_k)(i=1,2,\ldots,n)$$

- 常用的距离判别函数有：

1.绝对值距离，表达式为：

$$d_i(x_k) = \sum_{j=1}^{n} \left| x_{kj} - M_{ij} \right|$$

$d_i(x_k)$为距离；j为波段序号；总波段数为n，

i为类别号；x_{kj}为k像元在j波段的亮度值；M_{ij}为均值。

2.欧几里德距离

欧氏距离在二维空间就是两点之间的直线距离。如图，二维平面中A，B两点间的欧氏距离为

$$d_i(x_k)=\sqrt{\sum_{j=1}^{n}(x_{kj}-M_{ij})^2}$$

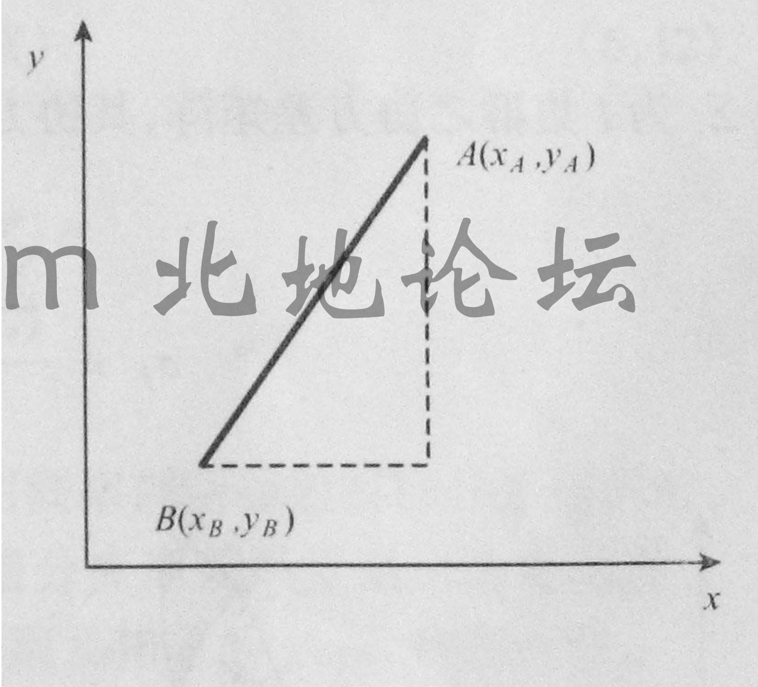

图 6.5 二维平面中的欧氏距离

以上两种距离都称作闵氏距离，使用闵氏距离应该注意以下问题：

（1）闵氏距离与特征参数的量纲有关。具有不同量纲的特征参数的闵氏距离常常是无意义的。将数量级相差较大的数以同等的权组合起来时，只能是突出绝对值大的特征参数的作用而降低绝对值小的特征参数的作用。

（2）闵氏距离没有考虑特征参数间的相关性，彼此相关的一些参数意味着他们在表征地物特征方面有共性。若某组特征参数大部分相关性较强，而个别的相关性不大，则一般来说相关的参数和不相关的参数在距离中的权应是不一致的，但在闵氏距离中权是相同的。

3.马哈拉诺比斯距离（马氏距离）

马氏距离是一种加权的欧式距离，
它通过协方差来考虑变量的相关性。
如果各个点群具有相同的方差，
则马氏距离是欧式距离的平方

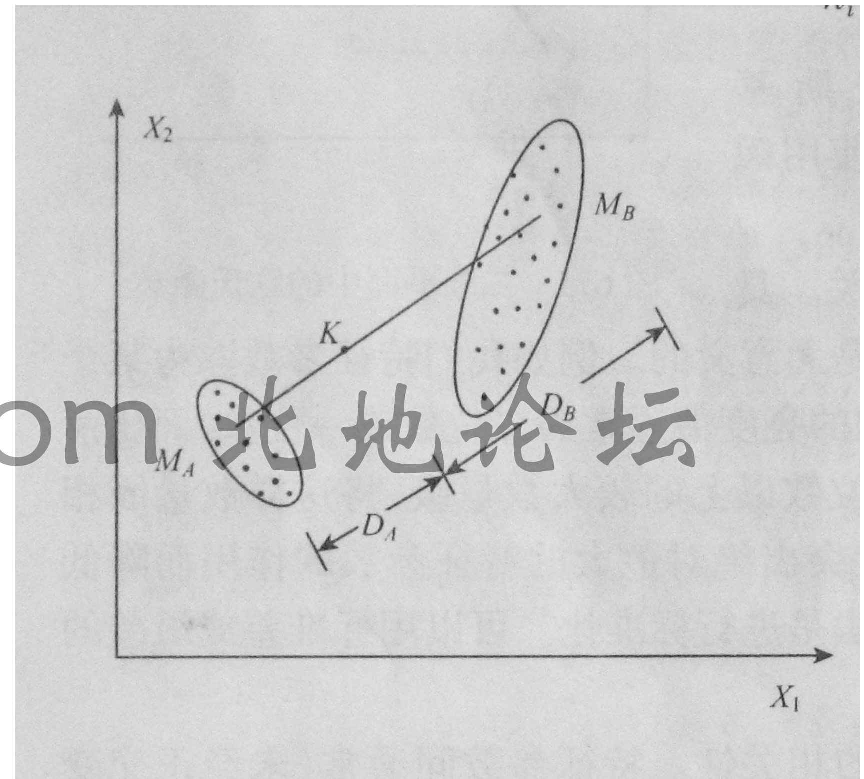

图 6.6 马氏距离

非监督分类

- 非监督分类，是指人们事先对分类过程不施加任何的先验知识，仅凭据遥感影像地物的光谱特征的分布规律，随其自然地进行盲目的分类。其分类的结果，只是对不同类别达到了区分，并不确定类别的属性，其属性是通过事后对各类的光谱响应曲线进行分析，以及与实地调查相比较后确定的。

非监督分类的理论依据

- 遥感图像上的同类地物在相同的表面结构特征、植被覆盖、光照等条件下，一般具有相同或相近的光谱特征，从而表现出某种内在的相似性，规属于同一个光谱空间区域；不同的地物，光谱信息特征不同，归属于不同的光谱空间区域。

非监督分类主要是采用聚类分析的方法，聚类是把一组像素按照相似性规成若干类别。它的目的是使得属于同一类别的像素之间的距离尽可能地小而不同类别上像素间的距离尽可能地大。

在进行聚类分析时，首先要确定基准类别的参量。但非监督分类的情况下，并无基准类别的先验知识可以利用，因而，只能先假定初始的参量，并通过预分类处理来形成集群。再由集群的统计参数来调整预置的参量，接着再聚类、再调整。如此不断地迭代，直到有关参数达到允许的范围为止。

- 非监督分类的主要过程

（1）确定初始类别参数，即确定最初类别数和类别中心（集群中心）。

（2）计算每一个像元所对应的特征矢量与各集群中心的距离。

（3）选与中心距离最短的类别作为这一矢量的所属类别。

（4）计算新的类别均值向量。

（5）比较新的类别均值与原中心位置上的变化。若位置发生了改变，则以新的类别均值作为聚类中心，再从第2步开始重复，进行反复迭代操作。

（6）如果聚类中心不再变化，计算停止。

初始类别参数的选定

初始类别参数是指:基准类别集群中心(均值Mi),以及集群分布的协方差矩阵Σ_i ,因为无论采用何种判别函数,都要预先确定其初始类别的参量。设总体直方图的均值和方差分别为

$$M=[m_1,m_2,\ldots,m_n]^T$$

$$\sum=[\sigma_1{}^2,\sigma_2{}^2,\ldots,\sigma_n{}^2]^T$$

$$m_i=\frac{1}{N}\sum_{j=1}^{N}x_{ij}$$

$$\sigma_i{}^2=\frac{1}{N-1}\sum_{j=1}^{N}(x_{ij}-m_i)^2$$

式中：i为波段号；j为像素点；x_{ij}为像素j在第i波段的亮度值；

n为波段数；N为像素总数。

初始类别参数的选定

总体直方图均匀定心法

该方法是在整幅遥感影像的总体直方图的基础上进行类别中心的选定的。如图所示

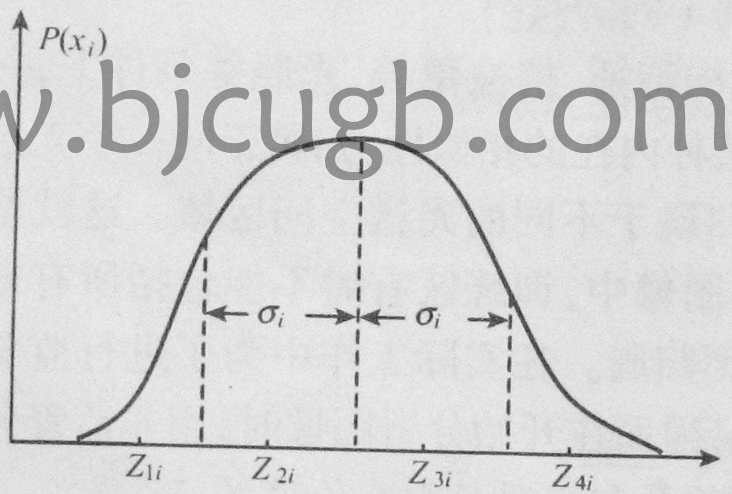

图 6.8 直方图均匀定心法

初始类别参数的选定

总体直方图均匀定心法

现假设我们需要有Q个初始类别，每个初始类别集群中心位置Zq（q＝1，2，…，Q）可按下式确定

$$Z_{qi}=m_i+\sigma i[2(q-1)/(Q-1)-1](i=1,2,\ldots,n)$$

例如,上图表示了$Q=4$的情况,这时

$$\mathrm{Z}_{1\mathrm{i}}=m_i-\sigma_i;\mathrm{Z}_{2\mathrm{i}}=m_i-\frac{1}{3}\sigma_i;\mathrm{Z}_{3\mathrm{i}}=m_i+\frac{1}{3}\sigma_i;\mathrm{Z}_{4\mathrm{i}}=m_i+\sigma_i$$

初始类别参数的选定

最大最小距离选心法

该法的选心原则是使各初始类别之间，尽可能地保持远距离。为做到这一点，首先在整幅图像中按一定方式（如等间隔方式）获取一个抽样的像素集合 $\overrightarrow{\{X\}}$

$$\overrightarrow{\{X\}} = \{\overrightarrow{X}_1 \ \overrightarrow{X}_2 \ldots \overrightarrow{X}_n\}$$ n为抽样个数。

初始类别参数的选定

最大最小距离选心法

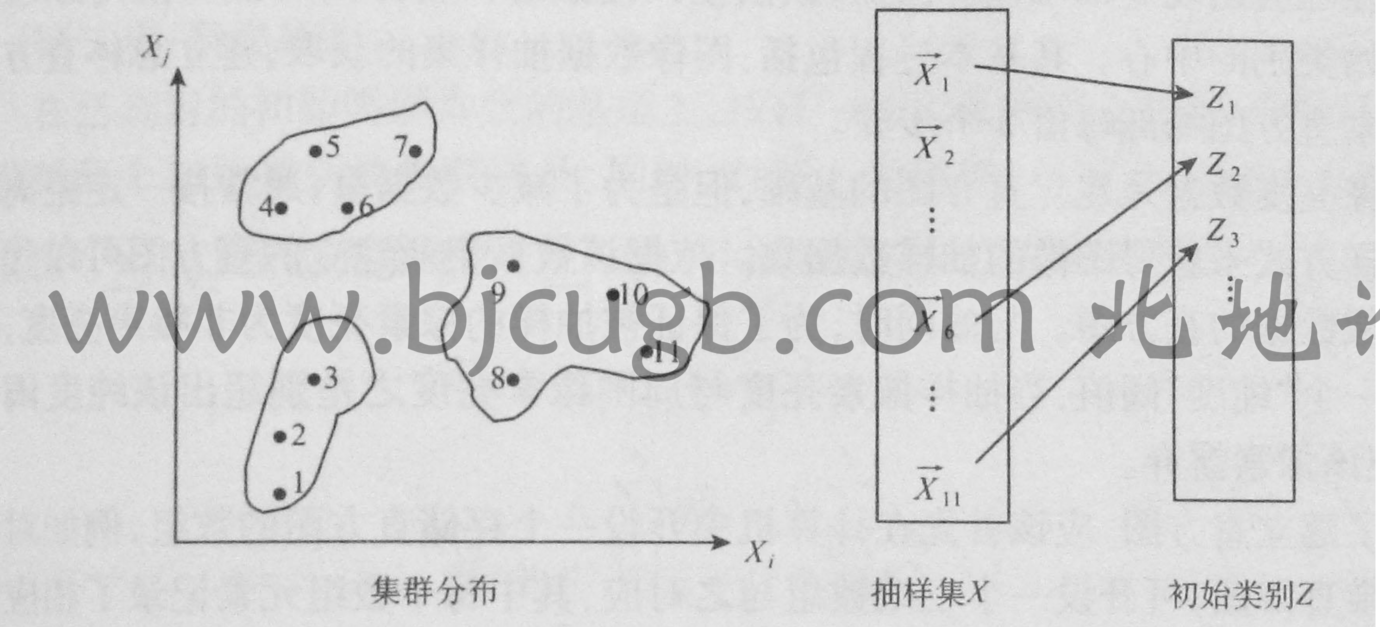

图 6.9　最大最小距离定心法

初始类别参数的选定

最大最小距离选心法

（1）取抽样集中任一像素之特征点（例如$\overrightarrow{X_1}$ ）作为第一个初始类别的中心Z1。

（2）计算$\overrightarrow{X_1}$与其他各抽样点之间的距离D1i。取与之距离最远的那个抽样点（例如$\overrightarrow{X_7}$）作为第二个初始类别中心Z2，即若

$$D_{17} = \max\{D_{12}, D_{13}, \ldots, D_{17}\}$$

则 $Z_2 = \overrightarrow{X}_7$

初始类别参数的选定

最大最小距离选心法

（3）对于剩余的每个抽样点，计算它到已有各初始类别中心的距离Dij（i＝1，2，…，m），m为已有初始类别数，并取其中的最小距离作为该点的代表距离Dj。

$$Dj = \min\left\{D_{1j}, D_{2j}, \ldots, D_{mj}\right\}$$

式中,m为已形成的初始类别数。

在此基础上，再对所有各剩余点的最小距离Dj进行相互比较，取其中最大者，并选择与该最大的最小距离相应的抽样点（例如$\vec{X}_{11}$）作为一个新的初始类别中心（例如$Z_3 = \vec{X}_{11}$）

初始类别参数的选定

最大最小距离选心法

（4）重复上面步骤，直到初始类别的个数达到需要的个数为止。

非监督分类

K一Means算法

K一means算法称作K一均值算法。其基本思想是：通过迭代，移动各个基准类别的中心，直至得到最好的聚类结果为止。算法如下：

非监督分类

K－Means算法步骤

第一步：初始类别的中心选择，可按上法进行选择。假设有c个初始类别，其中心分别为

$$Z^{(1)}_1, \quad Z^{(1)}_2, \ldots, \quad Z^{(1)}_c$$

非监督分类

K一Means算法步骤

第二步：在第k次迭代中，对于任一样本X计算它到已有类别的距离。选最小距离，将其调整到相应的类别中去。

$$if \left\| X - Z^{(k)}{}_j \right\| < \left\| X - Z^{(k)}{}_i \right\| then$$

$X \in S^{(k)}{}_j$,其中$S^{(k)}{}_j$是以$Z^{(k)}{}_j$为中心的类。

非监督分类

K－Means算法

第三步：由第二步得到$S^{(k)}_{j}$ 计算类新的中心 $Z^{(k+1)}_{j}$

非监督分类

K－Means算法

第四步：对所有的j＝1，2，…，c，如果 $Z^{(k+1)}{}_{j}=Z^{(k)}{}_{j}$ ，则迭代结束，否则转到第二步继续迭代。

K—means方法例子

假定4个像素A、B、C、D的两个波段B1和B2的数据如下：

像素	波段	
	B1	B2
A	5	3
B	-1	1
C	1	-2
D	-3	-2

然后计算这两个类的中心坐标

类	类中心坐标	
	B1	B2
（AB）	(5+（-1）)/2=2	(3+1)/2=2
（CD）	(1+（-3）)/2=-1	(-2+（-2）)/2=-2

然后计算每个像素到类中心的欧式距离，并将每个像素分配给最近的一类

类	类中心坐标	
	B1	B2
（A）	5	3
（BCD）	-1	-1

然后再次检查每个像素，
以决定是否需要重新分类。计算各个平方距离

类	像素到类中心的平方距离			
	A	B	C	D
（A）	0	40	41	89
（BCD）	52	4	5	5

监督分类-最大似然法判别函数

1.最大似然判别规则

从概率统计分析，要想判别某位置的向量X属于哪一个类别，判别函数要从条件概率

$$P(\omega_i / X)(i = 1,2,3,...,m)$$

来决定，ω i代表第i个类别，P表示在模式X出现的条件下，X为ω i类的概率等于多少。

1.最大似然判别规则

因此，我们找到一个像元属于每一类的可能性，然后比较他们的大小，哪一种类别出现的概率大，就把这个像元归哪类，即：

$$\text{如果}P(\omega_i / X) > P(\omega_j / X),(i \neq j, j = 1,2,3,\ldots,m$$

$$\text{则}X \in \omega_i$$

由于概率是建立在统计意义上的，因而当使用概率判别函数实行分类判别时，不可避免地会出现错分漏分现象，我们希望以错分概率或风险最小为准则建立所需要的判别规则，这就是下面介绍的Bayes准则及相应的Bayes判别函数。

- 贝叶斯（Bayes）公式

$$P(w_i / X) = \frac{P(w_i)P(X / w_i)}{P(X)}$$

式中：$P(w_i)$为先验概率，也就是在被分类的图像中类别w_i出现的概率。

$P(X / w_i)$为似然概率，也称为条件概率密度函数，

它表示在w_i这一类中出现像元X的概率。

所有属于wi的像元出现的概率密度知道后，就可以画出wi的概率分布曲线。有多少类别就有多少分布曲线。由此可知，只要有一个已知的训练区域，用这些已知类别的像元做统计就可以求出平均值及方差、协方差等特征参数，从而可以求出总体的先验概率。在不知道的情况下，也可以认为所有的P（wi）为相同。 P（wi / X）为X属于wi的概率，也称后验概率。

P（X）表示不管什么类别X出现的概率

$$P(X)=\sum_{i=1}^{m}P(X/\omega_i)P(\omega_i)$$

从式中可以看出P（X）与类别wi无关，是对各类来说一个公共因子，在比较大小时不起作用，因此做判别函数时可以去掉。因此下式是一组理想的判别函数

$$g_i(X)=P(X/w_i)P(w_i)(i=1,2,...,m)$$

判别规则为若：

$$P(w_i)P(X/w_i)\geq P(w_j)P(X/w_j)$$

则：$X\in w_i$

2.正态分布

$$P(X/w_i)=\frac{1}{(2\pi)^{\frac{p}{2}}\left|Si\right|^{\frac{1}{2}}}\exp[-\frac{1}{2}(X-M_i)^T S^{-1}{}_i(X-M_i)]$$

$$M_i=\frac{1}{n_i}\sum_{j=1}^{n_i}Xj$$

$$S_i=\frac{1}{n_i-1}\sum_{j=1}^{n_i}[(X_j-M_i)(X_j-M_i)^T]$$

n_i是类w_i的像元数目，j为像元标号，p是参加分类的特征数（或波段数）

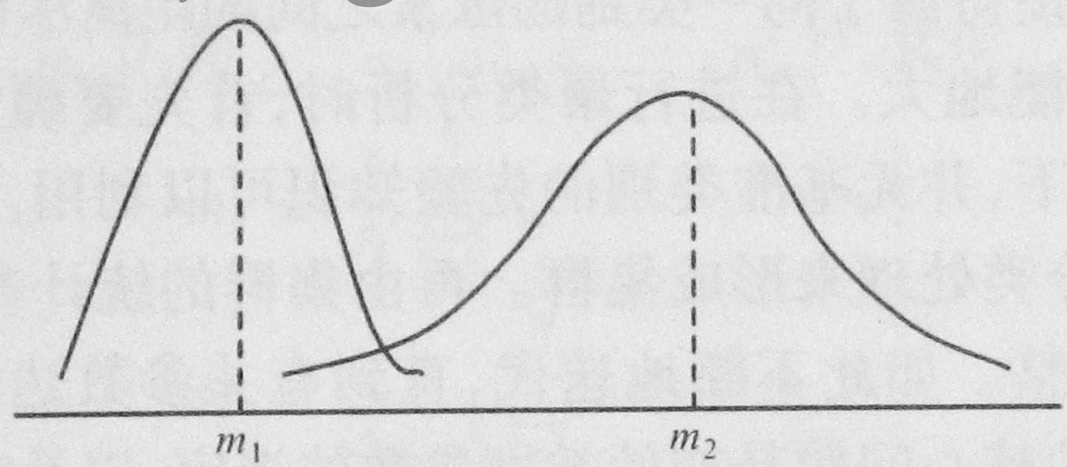

图 6.7　一维正态分布

2.正态分布

对判别函数用对数变换可得出更便于计算的形式，
即判别函数为：

$$g_i(X) = \ln P(w_i) - \frac{1}{2}\ln\left|S_i\right| - \frac{1}{2}(X - M_i)^T S_i^{-1}(X - M_i)$$

只要

$$g_i(X) \geq g_j(X),\ j \neq i$$

像元X就属于第i类

分类结果检验

图像类别	检验数据			
	X	Y	Z	行和
X	A	E	F	G
Y	B			
Z	C			
列和	D			

错分误差（用户精度）
漏分误差（生产者精度）

Kappa 系数

$$K=\frac{N\sum_{i=1}^{m}x_{ii}-\sum_{i=1}^{m}x_{i+}x_{+i}}{N^{2}-\sum_{i=1}^{m}x_{i+}x_{+i}}$$

M是误差矩阵中总列数（即总的类别数）；xii是第i行第i列上像素数量；xi+和x+i分别是第i行第i列的总像素数；N是用于精度评估的总像素数

表 9.3　分类质量与 Kappa 统计值

K(Kappa 系数)	分类质量
<0.00	很差
0.00～0.20	差
0.20～0.40	一般
0.40～0.60	好
0.60～0.80	很好
0.80～1.00	极好

表 9.4　Kappa 系数值的意义

K(Kappa 系数)	意义
1	评价者间的意见完全一致。说明两次判断的结果完全一致
0	评价者间的意见一致程度是依据偶然的。说明两次判断的结果是偶然造成
<0	评价者间的意见一致程度还不如偶然的。说明一致程度比偶然造成的还差，两次检查结果很不一致，在实际应用中无意义
>0	说明有意义。Kappa 越大，说明一致性越好
≥0.75	说明已经取得相当满意的一致程度
<0.4	说明一致程度不够理想