

数字图象处理技术讲座

第四讲 图象分类

刘政凯

(中国科学技术大学无线电电子学系)

一、什么是图象分类

图象分类是图象处理领域中重要内容之一。我们获得的大量图象信息，大部分都需要进行图象分类处理。图象分类处理就是把混在一起的不同类别的物质根据各自在图象信息中所反映的不同特征，通过计算机区别开来。例如，根据遥感图象可以把地物分成有植被或无植被两大类。这样就可以区别出城市和乡村。在有植被这一大类里又可以进一步分为农作物、森林、牧草三类。同样，在农作物这一类里又可以分出高粱、大豆、玉米、小麦等。在森林这一类里又可以分成针叶林、阔叶林，以致再分成松树、柏树、杉树等等。为什么我们利用遥感图象能进行上述分类呢？这主要是根据各种地物具有不同的光谱特征。我们知道，由地球资源卫星上的多光谱扫描仪(MSS)可以获得同一地区的从可见光到红外的不同波段的图象。不同的物质在不同的波段图象上表现出的特性是不同的。例如，绿色植物在波长为 $0.7\mu\text{m}$ 处反射率最高。因此，在多光谱扫描仪获得的第五波段($0.6-0.7\mu\text{m}$)图象上，绿色植物的灰度表现很亮，而非绿色植物的灰度表现较暗。如果我们选择某一灰度门限，当灰度大于这个门限时，认为是绿色植物，反之认为无植被区，从而可以区分出有植被和无植被两大类。同样，农作物、森林、牧草等又具有不同的光谱特征，因此也可以区分它们。图象分类处理大体由两部分组成：特征提取和判决分类。特征提取就是找出该类区别于其它类别的最突出特征，例如

在第五波段遥感图象上的灰度大小反映绿色植物的特征。判决分类就是设计判决规则及判决门限值。例如，我们可以规定第五波段遥感图象的某一灰度值为判决门限值，那么灰度值高于门限的象素为绿色植物，低于者为无植被地区。

各类的特征主要指波谱特征、几何形状特征、彩色特征等等。也可以把某些特征进行组合和变换，形成更典型的特征。

判决分类的方法很多，主要有统计分类识别和句法分类识别两大分支。统计分类识别是利用概率统计方法，把各类的特征参数表示为特征空间中的向量，然后用判别函数把各特征向量的分界面找出来，从而把各类分开。例如，图1为土壤、水和植被三类地物在遥感图象第四波段和第七波段上的灰度分布图。统计分类方法就是寻找水、土壤和植被三类地物的分界线，也就是寻找判别函数。求出判别函数后，自然就可把各类分开了。句法分类方法是类似于语言分析，把各类的结构信息用形式语言加以描述，然后进行推理分类。本文主要介绍几种基本的统计图象分类方法。

统计图象分类分为无监督分类和有监督分类。所谓无监督分类是指在缺乏先验类别知识的情况下，只根据数据自身相似性进行比较的数学方法去确定判别函数或根据人们提供的简单阈值控制而进行的分类。也称为无人管理的非监督分类方法，又称为集群分析，或聚类分析。有监督分类方法是指根据对已知的训练区的先验知识找出分类边界或距离函数，从而建立判别函数。这两种分类方法各有优缺点。一




图1 三类物质的分布

般讲,无监督分类方法简单一些,精度差些,有监督分类需要训练区数据,精度较高。下面介绍无监督分类和有监督分类中几种常用分类方法。

二、无监督分类

1. 简单集群分类方法^[1]

简单集群分类是把特征相同的或在一定偏差之内的象元归成一类的聚类方法。以遥感图象为例,我们知道地球资源卫星的多光谱扫描仪 MSS 有四个波段,分别称为 4,5,6,7 波段。假定这四幅图象的第一行、第一列的象元的四个波段亮度值为

波段	4	5	6	7
亮度	20	60	80	40

我们把这第一个象素的四波段数据送入计算机,并作为第一类。接着输入第二象素的数据,如果第二个象素数据与第一象素数据完全相同,则认为二者同类;否则认为两者具有不同类别,并赋予第二个象素为第二类。如此下去,把新输入的象素与已分类的象素比较,归入相同的类别或建立新的类别。这样便可实现对所有象素的分类。

有时不需要把类别分得太细。这时可允许每类存在一定的变差范围。例如上例中,如果允许与第一个象素的各波段亮度有 $\pm 10\%$ 的

变差范围都可认为是第一类,即

波段 4 5 6 7

变差范围 18—22 54—66 72—88 36—44

那么,当新输入的象元与第一个象素比较时,如果差别在变差范围之内,则认为二者同类。否则,为另一类。显然,允许有一定的变差范围后,类别减少了。变差范围越大,可分类别越少。

简单集群分类方法的特点是简单、速度快,但分类精度很低。特别是当各类分布之间存在互相重叠时,很难确定其所属类别。

2. 相似性距离分类

(1) 特征向量

在遥感图象中,假设把某一象素在四个波段中的灰度值分别用 x_1, x_2, x_3, x_4 表示,那么我们可以用一个向量把它们表示出来,即

$$\mathbf{x} = (x_1, x_2, x_3, x_4)^T,$$

T 表示向量的转置。我们称 \mathbf{x} 为波段向量或特征向量。对于一般情况,我们定义以特征 $x_1, x_2, x_3, \dots, x_n$ 构成一个 n 维特征空间,而向量

$$\mathbf{x} = (x_1, x_2, \dots, x_n)^T$$

为特征向量。

(2) 相似性距离

相似性是以特征空间中向量间距离远近距离来表示的,因而这种距离称为相似性距离。假定有两个象素 $\mathbf{x}_i, \mathbf{x}_k$, 特征矢量 $\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{in})^T$ 和特征矢量 $\mathbf{x}_k = (x_{k1}, x_{k2}, \dots, x_{kn})^T$ 之间的相似性距离 $d(\mathbf{x}_i, \mathbf{x}_k)$ 可表示为

$$d(\mathbf{x}_i, \mathbf{x}_k) = \left[\frac{\sum_{j=1}^n |x_{ij} - x_{kj}|^2}{n} \right]^{1/2}, \quad (1)$$

其中 $j = 1, 2, \dots, n$ 表示特征空间中第 j 维变量。例如四个波段的四维空间可以用 $j = 4, 5, 6, 7$ 表示, 则

$$d(x_i, x_k) = \left[\frac{\sum_{j=4}^7 |x_{ij} - x_{kj}|^2}{4} \right]^{1/2} \\ = \{ [(x_{i4} - x_{k4})^2 + (x_{i5} - x_{k5})^2 + (x_{i6} - x_{k6})^2 + (x_{i7} - x_{k7})^2] / 4 \}^{1/2}. \quad (2)$$

(1) 式和 (2) 式定义的相似性距离称为欧氏距离。

通常还采用以下两种相似性距离, 即

$$d(\mathbf{x}_i, \mathbf{x}_k) = \sum_{j=1}^n |x_{ij} - x_{kj}| \quad (3)$$

和

$$d(\mathbf{x}_i, \mathbf{x}_k) = \max_{j \leq n} |x_{ij} - x_{kj}|. \quad (4)$$

(3) 相似性距离分类

由于分类前不知道有几类, 也不知道每类的中心。因此, 我们主观的假定待分的物质是 A 类和 B 类两类物质。如果待分象素数目为 m , 其均值为 \bar{x} , 偏差为 s 。则我们可取 A 类的中心为 $\bar{x} - s$, B 类的中心为 $\bar{x} + s$, 即

$$\left. \begin{aligned} \bar{x}_A &= \bar{x} - s, \\ \bar{x}_B &= \bar{x} + s. \end{aligned} \right\} \quad (5)$$

然后根据任何一个相似性距离公式, 计算待分象元与 A 类中心及 B 类中心的相似性距离, 根据相似性距离的大小, 把待分象元归入相似性距离最小的那一类中去。

这样分类是否符合实际情况, 还需要进一步检验。即分别计算出实际所分的 A, B 类中心及标准偏差 s_A, s_B 。如果各类标准偏差小于事先规定的某一阈值, 那么可以认为分类正确。如果标准偏差 s_A, s_B 超过规定的阈值, 那么说明待分象素不仅是两类, 需要进一步分类。这时可以在已分成两类的基础上把 A 类再分裂成两类, B 类再分裂成两类。然后重新计算各类中心位置及偏差并检验偏差是否在规定阈值范围之内。这样分裂下去, 直到合适为止。

物理

3. K-Means 分类算法^[2]

K-Means 算法是集群分析中常用算法之一。它的判据是某类中各象素与其类别中心的距离平方和为最小。根据这个判据进行集群分类。

K-Means 算法可分以下步骤:

第一步, 选择各类初始中心 $\mathbf{z}_1(1), \mathbf{z}(2), \dots, \mathbf{z}_m(1)$ 。其中 m 代表欲分类别数目。各类初始中心的选取可以是任意的, 但通常把所给样本中的前 m 个样本作为 m 个初始中心。

第二步, 择近分类。假定进行 k 次更新后, 象素 \mathbf{x} 所属类别应由下式判定:

如果

$$\|\mathbf{x} - \mathbf{z}_j(k)\| < \|\mathbf{x} - \mathbf{z}_i(k)\|, \quad (6)$$

则 \mathbf{x} 属于第 j 类, 表示为

$$\mathbf{x} \in S_j(k), \quad (7)$$

其中 $i, j = 1, 2, \dots, m, i \neq j$ 。 $S_j(k)$ 代表集群中心为 $\mathbf{z}_j(k)$ 的所有象素集合。

第三步, 计算新中心。根据第二步的结果, 计算新的集群中心 $\mathbf{z}_j(k+1), j = 1, 2, \dots, m$, 使得 $S_j(k)$ 中各象素到新的集群中心的距离平方和为最小, 即

$$J = \min_{\mathbf{x} \in S_j(k)} \sum \|\mathbf{x} - \mathbf{z}_j(k+1)\|^2. \quad (8)$$

这时, 新的集群中心 $\mathbf{z}_j(k+1)$ 可由下式算出:

$$\mathbf{z}_j(k+1) = \frac{1}{N_j} \sum_{\mathbf{x} \in S_j(k)} \mathbf{x}, \quad (9)$$

其中 N_j 为第 j 类象素总数。K-Means 这个名字也就是依次更新集群中心的意思。

第四步, 是否结束。如果各类的新中心与老中心之差小于其事先给定的误差门限值, 则分类结束, 否则返回第二步。

K-Means 算法的性能取决于分类数目, 初始各类中心的选择, 象素的次序, 以及象素本身分布情况。只要各类别之间不是太混杂在一起, 总是可以获得较好分类效果。

三、有监督分类

1. 最小距离分类^[1,3]




图2 最小距离分类

最小距离分类是有监督分类。它与相似性距离分类不同之点，在于已知各类的中心及偏差，即均值 $\bar{x}_1, \bar{x}_2, \dots, \bar{x}_m$ 及标准偏差 S_1, S_2, \dots, S_m 等。最小距离分类方法首先计算待分象素与各类之间的距离，然后把待分象素归入距离最小的那一类别。例如，只存在二类的情况，其第一类的均值为 \bar{x}_1 ，标准偏差为 S_1 ；第二类均值为 \bar{x}_2 ，标准偏差为 S_2 。如图2所示，待分象元为 x ，我们计算待分象元 x 与第一类中心（即均值 \bar{x}_1 ）的距离及该象元与第二类中心（即均值 \bar{x}_2 ）的距离，比较这两个距离，然后判定 x 属于距离小的那一类。

最小距离分类的判别方程可以选用(1)式至(4)式定义的相似性距离 $d(x_i, x_k)$ 。下面举例说明最小距离分类的计算过程。

我们选用(1)式的欧氏距离作为最小距离分类的判别函数，即

$$D(x_i, \bar{x}_k) = \left[\frac{\sum_{j=1}^n (x_{ij} - \bar{x}_{kj})^2}{4} \right]^{1/2}, \quad (1)$$

其中 $j = 4, 4, 6, 7$ 为波段序号； x_{ij} 为待分象素 i 的第 j 波段亮度值； \bar{x}_{kj} 为已知的第 k 类在第 j 波段的均值。

假定已知类别为高粱、大豆、玉米、小麦等四类并分别用 $\omega_1, \omega_2, \omega_3, \omega_4$ 表示。通过训练区的统计，每类的均值 \bar{x}_j 和偏差 S_j 如表1所示

表 1

	\bar{x}_4	S_4	\bar{x}_5	S_5	\bar{x}_6	S_6	\bar{x}_7	S_7
ω_1	31	4.1	34	7.2	28	7.5	8	3.0
ω_2	33	5.0	45	9.9	60	3.0	23	20
ω_3	30	2.0	40	3.0	32	2.6	21	3.5
ω_4	26	2.8	32	1.5	47	1.8	20	3.2

待分类的目标为象素 x ，其四个波段的亮度值为 $x_4 = 31, x_5 = 45, x_6 = 32, x_7 = 20$ 。根据欧氏距离 $D(x, \bar{x}_k)$ ，判别 x 的所属类别。

分类步骤如下：

(1) 计算目标象素 x 至 $\omega_1, \omega_2, \omega_3, \omega_4$ 各类的距离 $D(x, \bar{x}_k)$ 。

x 与 ω_1 类的距离为

$$\begin{aligned} D(x, \bar{x}_1) &= \left[\frac{\sum_{j=4}^7 (x_j - \bar{x}_{1j})^2}{4} \right]^{1/2} \\ &= \{ [(x_4 - \bar{x}_{14})^2 + (x_5 - \bar{x}_{15})^2 + (x_6 - \bar{x}_{16})^2 \\ &\quad + (x_7 - \bar{x}_{17})^2] / 4 \}^{1/2} \\ &= \{ [(31 - 31)^2 + (45 - 34)^2 \\ &\quad + (60 - 28)^2 + (21 - 8)^2] / 4 \}^{1/2} \\ &= 70.25; \end{aligned}$$

x 与 ω_2 类的距离为

$$\begin{aligned} D(x, \bar{x}_2) &= \left[\frac{\sum_{j=4}^7 (x_j - \bar{x}_{2j})^2}{4} \right]^{1/2} \\ &= 199.25; \end{aligned}$$

x 与 ω_3 类的距离

$$D(\mathbf{x}, \bar{\mathbf{x}}_3) = \left[\frac{\sum_{j=4}^7 (x_j - \bar{x}_{3j})^2}{4} \right]^{1/2} = 6.75;$$

\mathbf{x} 与 ω_4 类的距离为

$$D(\mathbf{x}, \bar{\mathbf{x}}_4) = \left[\frac{\sum_{j=4}^7 (x_j - \bar{x}_{4j})^2}{4} \right]^{1/2} = 104.75.$$

(2) 比较上面计算结果, 可以找出最小距离 $D(\mathbf{x}, \bar{\mathbf{x}}_3) < D(\mathbf{x}, \bar{\mathbf{x}}_1) < D(\mathbf{x}, \bar{\mathbf{x}}_2) < D(\mathbf{x}, \bar{\mathbf{x}}_4)$ 此结果说明, 待分目标象素 \mathbf{x} 与 ω_3 类的欧氏距离最小。

(3) 计算待分目标象元 \mathbf{x} 与 ω_3 类的最小欧氏距离 $D(\mathbf{x}, \bar{\mathbf{x}}_3)$ 是否满足阈值要求。这里我们事先定义某一阈值 T , 如果最小欧氏距离满足下式:

$$|D(\mathbf{x}, \bar{\mathbf{x}}_3) - S_{kj}| \leq T, \quad (10)$$

即最小欧氏距离 $D(\mathbf{x}, \bar{\mathbf{x}}_k)$ 与该类的各波段的偏差 S_{kj} 之间的绝对值小于给定的门限值 T , 则我们判定该待分目标象素 \mathbf{x} 属于该类。例如, 我们取 $T = 5$, 则在本例中, 最小距离 $D(\mathbf{x}, \bar{\mathbf{x}}_3) = 6.75$, 由表 1 可见, 第三类各波段方差 S_{3j} 分别为 2.0, 3.0, 2.6 和 3.5。由于 $|D(\mathbf{x}, \bar{\mathbf{x}}_3) - S_{3j}| \leq 5$, 因此我们判定待分目标象素 \mathbf{x} 属于 ω_3 类, 即待分目标象素 \mathbf{x} 属于玉米之类。

最小距离分类的精度取决于已知类别的多少及训练区统计参数的准确程度。一般说来, 最小距离分类方法具有简便实用的优点。

2. 最大似然比分类

最大似然比分类是按最大后验概率准则进行分类。即求后验概率 $P(\omega_i/\mathbf{x})$ 的最大值。

$$\max P(\omega_i/\mathbf{x}), \quad (11) \\ 1 \leq i \leq m$$

其中 m 为要分的类数, ω_i 代表类别。根据 Bayes 公式

$$P(\omega_i/\mathbf{x}) = \frac{P(\mathbf{x}/\omega_i)P(\omega_i)}{P(\mathbf{x})}, \quad (12)$$

因此求(11)式最大值, 即求

$$\max P(\mathbf{x}/\omega_i)P(\omega_i), \quad (13) \\ 1 \leq i \leq m$$

假设每类的象素分布都满足 n 维正态分布 (n 为特征维数), 记为

$$\mathbf{x} = (x_1, x_2, \dots, x_n)^T,$$

其均值矢量为

$$\bar{\mathbf{x}}_i = (\bar{x}_{i1}, \bar{x}_{i2}, \dots, \bar{x}_{in})^T,$$

协方差矩阵为

$$\Sigma_i = (\mathbf{x} - \bar{\mathbf{x}}_i)^T (\mathbf{x} - \bar{\mathbf{x}}_i),$$

则其正态分布可表示为

$$P(\mathbf{x}/\omega_i) = \frac{1}{(2\pi)^{n/2} |\Sigma_i|^{1/2}} \\ \times \exp \left[-\frac{1}{2} (\mathbf{x} - \bar{\mathbf{x}}_i)^T \Sigma_i^{-1} (\mathbf{x} - \bar{\mathbf{x}}_i) \right], \quad (14)$$

其中 $i = 1, 2, \dots, m$ 。因此, 求(13)式最大值, 即求

$$\max \left\{ \frac{P(\omega_i)}{(2\pi)^{n/2} |\Sigma_i|^{1/2}} \right. \\ \left. \times \exp \left[-\frac{1}{2} (\mathbf{x} - \bar{\mathbf{x}}_i)^T \Sigma_i^{-1} (\mathbf{x} - \bar{\mathbf{x}}_i) \right] \right\}. \quad (15)$$

对上式取对数并化简后变为

$$\max \{ C_i - (\mathbf{x} - \bar{\mathbf{x}}_i)^T \Sigma_i^{-1} (\mathbf{x} - \bar{\mathbf{x}}_i) \}, \quad (16)$$

式中

$$C_i = 2 \ln P(\omega_i) - \ln |\Sigma_i|. \quad (17)$$

根据训练区数据, 可以求出各类的 $P(\omega_i)$, Σ_i , $\bar{\mathbf{x}}_i$ 等参数, 把待分象素 \mathbf{x} 的数据代入(16)式, 即可确立 \mathbf{x} 应归入的类别。

3. 树型分类方法

上面介绍的最大似然比分类方法是一种常用的有监督分类方法。但该分类方法存在着计算量大的缺点。在实际分类处理中, 某一类物质区别于另一类物质可以主要取决于少数几个特征, 不见得需要特征空间中的所有特征。另外, 在实际应用时, 往往需要某些类分得细一些, 某些类可以分得粗些。最大似然比分类方法不能很好地解决这些问题。因此, 近年来提出了树型分类方法。

树型分类器是一种多层分类方法。例如二

(下转第 108 页)