

基于目标约束与谱空迭代的高光谱图像分类方法

于纯妍¹, 赵猛¹, 宋梅萍^{1,2*}, 李森¹, 王玉磊^{1,2,3}

¹大连海事大学信息科学技术学院, 辽宁 大连 116026;

²综合业务网理论及关键技术国家重点实验室, 陕西 西安 710071;

³中国科学院光谱成像技术重点实验室, 陕西 西安 710071

摘要 针对复杂背景像元影响高光谱分类精度的问题, 将目标检测方法引入地物分类研究, 提出了一种基于谱空特征迭代的高光谱图像分类方法, 该方法通过将约束能量最小化设计了一种多目标约束的类别分类器(MTCC)。该分类器利用检测原理提取多类目标地物, 有效地降低了复杂背景数据对分类精度的影响; 同时为了解决光谱特征带来的过分类问题, 方法中利用反馈式谱空融合方式强化空间增强信息在分类中的作用, 以逐步提高分类精度。利用 Purdue、Salinas 和 Pavia 数据集进行实验, 结果表明, 所提方法的平均分类精度分别为 98.09%、97.33% 和 84.68%, 精确率分别为 96.84%、95.32% 和 79.13%, 与其他方法相比所提方法具有更高的泛化能力, 实用性更强。

关键词 遥感; 高光谱图像分类; 谱空特征; 迭代; 多类别分类器

中图分类号 O751.1

文献标识码 A

doi: 10.3788/AOS201838.0628003

Hyperspectral Image Classification Method Based on Targets Constraint and Spectral-Spatial Iteration

Yu Chunyan¹, Zhao Meng¹, Song Meiping^{1,2}, Li Sen¹, Wang Yulei^{1,2,3}

¹Information Science and Technology College, Dalian Maritime University, Dalian, Liaoning 116026, China;

²State Key Laboratory of Integrated Services Networks, Xi'an, Shannxi 710071, China;

³Key Laboratory of Spectral Imaging Technology, Chinese Academy of Sciences, Xi'an, Shannxi 710071, China

Abstract Aiming to solve the problem that the complex background pixels affect the hyperspectral classification accuracy, the object detection theory is introduced into the hyperspectral image classification domain, and a hyperspectral image classification method based on spectral-spatial feature iteration is proposed. A multi-target constrained classifier (MTCC) is designed by constrained energy minimization method. Based on the detection theory, the MTCC can effectively decrease the influence of complex background data on the classification accuracy. At the same time, to eliminate the over-classification problem caused by the spectral features, the method uses the feedback fusion of spectral-spatial to strengthen the spatial enhancement information so as to improve the classification accuracy gradually. The results of the experiments on the data sets of Purdue, Salinas and Pavia show that the average accuracies of the proposed methods are 98.09%, 97.33% and 84.68% respectively, and the precisions of the proposed method are 96.84%, 95.32% and 79.13% respectively. Compared to other algorithms, the proposed method has higher generalization ability and practicability.

Key words remote sensing; hyperspectral image classification; spectral-spatial feature; iteration; multiple classifier

OCIS codes 280.4750; 100.4145; 100.5010; 100.3008

收稿日期: 2017-11-20; 收到修改稿日期: 2017-12-27

基金项目: 国家自然科学基金(61601077)、辽宁省自然科学基金(20170540095)、中央高校基本科研业务费项目(3132016331, 3132016308)、中央高校基本科研业务费专项(3132018196)、中国科学院光谱成像重点实验室开放基金(LSIT201707D)

作者简介: 于纯妍(1979—), 女, 博士, 讲师, 硕士生导师, 主要从事高光谱图像分类、图像分割、机器学习等方面的研究。

E-mail: yuchunyan1997@126.com

* 通信联系人。E-mail: smping@163.com

1 引 言

高光谱图像具有较高的光谱分辨率,可以探测到多光谱图像无法探测到的地物类别,在环境监测、军事安全、林业防护等领域应用越来越广泛。分类技术作为高光谱图像处理中的一项重要应用,其本质是把多维特征空间划分为若干区域(子空间)^[1],若一个高光谱数据有 C 类地物,则会被分成 $C+1$ 个子空间,即包含一个背景子空间。近年来高光谱分类技术^[2-5]得到越来越广泛的关注,从目前的分类方法来看,基于机器学习的高光谱图像分类方法是地物分类的主流方法,这类方法主要是利用模式识别分类器^[6][逻辑回归、支持向量机(SVM)、神经网络等]对像元进行地物分类,根据分类器的生成是否需要将已知样本的光谱特征或其他特征进行样本训练,可分成监督式分类和非监督式分类两种。文献^[7]中提出了一种非监督式高光谱分类方法,首先将高光谱数据进行波段子集聚类,利用空谱域提取任意形状特征后,通过置信理论进行融合子集实现高光谱图像分类,该方法对噪声更具稳健性。在监督式分类方法中,空间信息的作用被广泛重视,目前基于谱间-空间特征的高光谱图像分类方法成为研究热点^[2,8-14],这类方法通过引入空间信息特征辅助光谱特征以提高分类的精度。Zhang 等^[11]则是通过马尔科夫随机场,设计相对同质系数约束同质区域中的空间信息,将光谱特征与空间信息结合,有效提升了 SVM 分类器的分类效果。Kang 等^[12]提出基于边缘保持滤波的空谱分类框架,利用双边滤波与引导滤波的边缘保持特性,联合高光谱影像的空间与光谱信息,取得了不错的分类效果。Chen 等^[13]利用窗口方法,对窗口内的像素进行联合稀疏表达的方式引入空间信息,使重构误差最小化,获得分类结果。Guo 等^[14]将支持张量机(STM)方法利用用于解决高光谱分类问题上,通过张量特征表达的特殊结构引入空间信息,实现了光谱-空间信息联合的高光谱分类。

当前高光谱分类方法为实现地物分类提供了大量理论支持与解决方案,然而还存在一定的问题:一方面,由于背景信息比较复杂,高光谱分类没有单独的背景样本,无法进行背景类别训练,因此在分类结果中通常是将背景类别归属为地物类别之一;另一方面,谱空联合分类方法在空间强化信息方面仍缺少有效融合模式,相对于数量众多的光谱波段特征,该方法弱化了空间增强特征在分类中的重要性。针

对以上问题,本文提出了一种全新的多目标约束的高光谱分类方法,该方法将检测理论用于高光谱目标分类,通过定义的多目标约束的类别分类器(MTCC)直接对地物类别进行检测,并融入空间特征进一步提高分类精度。本文一方面提出了一种全新的谱间和空间特征的融合方式,即将分类结果中的空间特征提取反馈叠加到光谱特征中,并采用迭代分类的方法逐步提高分类精度;另一方面利用能量约束矩阵对多目标地物进行约束,可以实现多目标同时检测,通过阈值分割实现地物分类,有效降低了背景像元对分类的影响,提高了分类稳健性。从定义的客观评价标准可以看出,与已有的相关算法相比,本文提出的方法的分类精度与精确度均较高、并且具有较高的泛化性,实用性强。

2 约束能量最小化算法

约束能量最小化(CEM)算法^[15]是高光谱目标检测的经典算法之一,其工作原理主要是设计有限冲激响应(FIR)滤波器,利用能量约束函数最小化的方式检测目标地物。已知高光谱图像数据 $\mathbf{r} = (\mathbf{r}_1, \mathbf{r}_2, \dots, \mathbf{r}_n)^\top$,其中 n 是高光谱图像的像元数目, $\mathbf{r}_i (1 \leq i \leq n)$ 表示高光谱图像的第 i 个像元, $\mathbf{r}_i = (r_{i1}, r_{i2}, \dots, r_{iL})^\top$,其中 L 表示高光谱图像的波段数目; $\mathbf{d} = (d_1, d_2, \dots, d_L)^\top$ 为待测地物目标的光谱签名,参数 \mathbf{W} 为 L 维向量, $\mathbf{W} = (\omega_1, \omega_2, \dots, \omega_L)^\top$ 。具体地,当输入为 \mathbf{r}_i 时,FIR 的输出值为 y_i ,则有 $y_i = \sum_{l=1}^L \omega_l r_{il} = \mathbf{W}^\top \mathbf{r}_i = \mathbf{r}_i^\top \mathbf{W}$ 。FIR 滤波器的平均输出能量为:

$$\frac{1}{n} \sum_{i=1}^n y_i^2 = \mathbf{W}^\top \mathbf{R} \mathbf{W}, \quad (1)$$

式中 \mathbf{R} 为高光谱图像的样本光谱自相关矩阵,其定义如下:

$$\mathbf{R}_{L \times L} = \frac{1}{n} \sum_{i=1}^n (\mathbf{r}_i \mathbf{r}_i^\top). \quad (2)$$

约束能量最小化算法用来设计解决如下的线性约束优化问题:

$$\min_{\mathbf{w}} \{ \mathbf{W}^\top \mathbf{R} \mathbf{W} \} \text{ s.t. } \mathbf{d}^\top \mathbf{W} = \mathbf{W}^\top \mathbf{d} = 1. \quad (3)$$

通过引入拉格朗日乘子,得到优化的 \mathbf{W}^* 值为:

$$\mathbf{W}^* = \mathbf{R}^{-1} \mathbf{d} / (\mathbf{d}^\top \mathbf{R}^{-1} \mathbf{d}). \quad (4)$$

3 多目标约束的类别分类器

本研究利用目标检测原理,在约束能量最小化算法的基础上,提出了一种基于谱空迭代的多目标约束的类别分类器。该分类器通过迭代检测

原理对多目标地物进行检测,通过背景压制的方法消除背景信息对目标的影响;同时利用空间滤波器提取检测结果中地物的空间特征,并将其反馈融合进谱间特征,将空间特征逐步强化,通过这种迭代方式一步步消除了仅利用光谱特征带来的

过分类噪声问题,提高了分类精度;同时设计的多类别分类器可以将多种地物目标与背景地物进行分类,实现真正意义上的地物与背景分类。所提出的分类方法流程如图 1 所示,图中 HSI 表示高光谱图像数据。

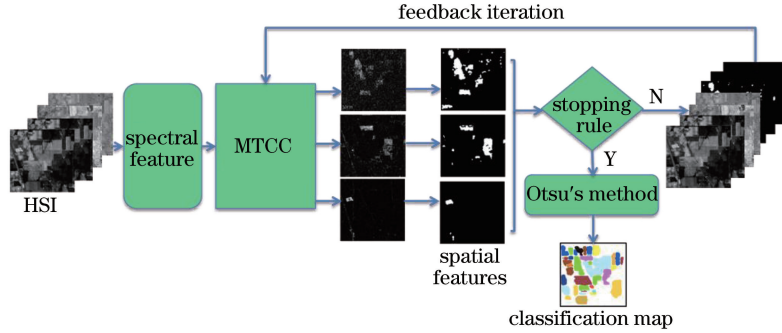


图 1 分类方法流程图

Fig. 1 Flow chart of classification method

3.1 多目标地物检测方法

以约束能量最小化算法为基础,通过设定多个约束目标的 FIR 过滤器,使所有的目标地物能同时被检测到。已知高光谱图像的信号源包括多目标地物,其中 $\mathbf{D} = \{d_1, d_2, \dots, d_p\}$ 为目标地物的光谱特征集合, $d_i = (d_{i1}, d_{i2}, \dots, d_{in})^T$ 为第 i 个待测地物目标的光谱特征,参数 \mathbf{W} 为 L 维向量 $\mathbf{W} = (\omega_1, \omega_2, \dots, \omega_L)^T$,根据 p 的数目,设置约束向量 $\mathbf{C} = [c_1, \dots, c_p]^T$ 为 $p \times 1$ 的矩阵,其中向量 $c_j = \mathbf{1}$ ($1 \leq j \leq p$) 用于约束第 j 个地物目标。

根据光谱矩阵 \mathbf{D} 和约束向量 \mathbf{C} ,定义同时对 p 个目标进行分类的多类别检测器 MTCC,根据 FIR 滤波器原理,MTCC 用于约束如下的优化问题:

$$\min\{\mathbf{W}^T \mathbf{R}_{L \times L} \mathbf{W}\} \text{ s.t. } \mathbf{D}^T \mathbf{W} = \mathbf{C}. \quad (5)$$

定义拉格朗日函数:

$$F(\mathbf{W}, \boldsymbol{\lambda}) = \frac{1}{2} \mathbf{W}^T \mathbf{R}_{L \times L} \mathbf{W} + \boldsymbol{\lambda} (\mathbf{D}^T \mathbf{W} - \mathbf{C}), \quad (6)$$

式中 $\boldsymbol{\lambda}$ 为拉格朗日乘子向量。

利用拉格朗日乘子法,分别对(6)式中 \mathbf{W} 和 $\boldsymbol{\lambda}$ 求偏导数,可以得到:

$$\frac{1}{2} \mathbf{R}_{L \times L} \mathbf{W} + \frac{1}{2} \mathbf{R}_{L \times L}^T \mathbf{W} + \boldsymbol{\lambda} \mathbf{D}^T = 0, \quad (7)$$

$$\mathbf{D}^T \mathbf{W} - \mathbf{C} = 0. \quad (8)$$

推导(7)和(8)式,得到:

$$\mathbf{R}_{L \times L} \mathbf{W} + \boldsymbol{\lambda} \mathbf{D}^T = 0, \quad (9)$$

$$\mathbf{D}^T \mathbf{W} = \mathbf{C}. \quad (10)$$

由(10)式可得:

$$\mathbf{W} = \mathbf{C} \mathbf{D}^{-1}, \quad (11)$$

将(11)式代入(9)式,得到:

$$\boldsymbol{\lambda} \mathbf{D}^T = -\mathbf{R}_{L \times L} \mathbf{W}, \quad (12)$$

将(11)式代入(12)式,可以得到:

$$\boldsymbol{\lambda} = -2\mathbf{C} (\mathbf{D}^T \mathbf{R}_{L \times L}^{-1} \mathbf{D})^{-1}. \quad (13)$$

由(13)和(10)式得到:

$$2\mathbf{R}_{L \times L} \mathbf{W} = -\mathbf{D} \boldsymbol{\lambda} \Rightarrow \mathbf{W} = -\mathbf{R}_{L \times L}^{-1} \mathbf{D} \boldsymbol{\lambda}, \quad (14)$$

将(13)式代入(14)式,得到:

$$\mathbf{W}^{\text{MTCC}} = \mathbf{R}_{L \times L}^{-1} \mathbf{D} (\mathbf{D}^T \mathbf{R}_{L \times L}^{-1} \mathbf{D})^{-1} \mathbf{C}, \quad (15)$$

式中 \mathbf{W}^{MTCC} 为 $L \times p$ 维矩阵, \mathbf{W} 表示的是滤波器中所有目标的权重矩阵。将约束能量最小化算法扩展为 MTCC 的出发点是利用多通道的 FIR 滤波器同时检测地物类别,通过逆矩阵 \mathbf{R}^{-1} 把高光谱图像的样本光谱进行背景压制,扩展之后的检测方法可以同时实现多类别地物的检测,为进一步进行多目标地物分类提供基础。

3.2 空间特征迭代

仅使用光谱特征的高光谱分类器会产生过分类问题,因此需要融入空间特征来消除过分类问题,并提高分类精度。本研究提出一种谱空特征迭代的融合方法,首先在多类别分类器的初始分类结果中提取空间特征,然后将每种地物目标空间特征图均反馈叠加到高光谱图像中,接着采用迭代方法继续对叠加空间特征之后的高光谱图像分类,通过这种谱空特征迭代的方式,将空间特征增强信息逐步强化。

在高光谱图像分类中,利用数学形态学的方法提取空间特征已颇为流行。形态学方法的基本原理^[16]是利用具有一定形态的结构元素对图像进行度量和提取,其基本操作是腐蚀和膨胀,可以对图像的边缘进行消除或填充。相对于基本的腐蚀和膨胀

运算,开运算和闭运算不仅能平滑图像的轮廓、削弱图像的突出和边缘毛刺、断开目标物之间的粘连,还具有基本保持目标物尺寸不变的优点。本研究采用形态学开闭算子提取目标地物的空间特征。

因为形态学算子将像元周围的邻域像元进行了形态学处理,所以提取到的空间特征在一定程度上表示了地物的空间信息,但是由于分类结果中计算出来的像元类别的丰度值的范围比较大,如果直接叠加丰度值结果会导致非地物信号的影响仍然很大,因此在叠加到原始数据的时候,需要将结果信号进行压缩,以重点突出丰度值较大的目标地物信号,缩减非目标地物信号的影响。因此在叠加到原来的数据上的时候,本研究提出了两种思路,一种是将分类丰度值信号取绝对值,从而将信号的强度范围缩小一半,借以突出地物类别的信号;另外一种思路是将分类丰度值为负值的信号设置为0,从而也缩小了信号的强度范围。

设 $a(j)$ 为第 j 个像元的丰度值, $1 \leq j \leq N$, 其中 N 为所有的像元数目,则方法 1 的叠加量为:

$$\mathbf{T}_{sk} = [a'(j)] = [a'(j) = |a(j)|], \quad (16)$$

方法 2 的叠加量为:

$$\mathbf{T}_{sk} = [a'(j)] = \begin{cases} a'(j) = a(j), & a(j) \geq 0 \\ a'(j) = 0, & a(j) < 0 \end{cases} \quad (17)$$

图 2 为 Purdue 图像 (<https://engineering.purdue.edu/~biehl/MultiSpec/documentation.html>) 的第二类地物(corn-notill)根据(16)和(17)式得到的反馈叠加量示意图,第一行为所有像元的示意图,第二行为其中(65:70, 95:105)区域的 66 个像元的示意图;第一列为分类的丰度值,第二列为融合形态学空间特征之后的分类丰度值,第三列为采用所提第一种方法得到的反馈叠加量,第 4 列为采用所提第二种方法得到的反馈叠加量。可以看出,直接叠加融合空间特征的反馈量的目标地物类别与背景地物区分不明显,而经过所提方法得到的反馈叠加量较好地体现了目标地物的空间信息;然而第二种方法会丢失部分的像元,从右下角的细节图可以看出所有的 66 个像元被当作一类地物,因此比起第二行第三个图就会丢失稍多的空间特征,因此性能会稍微差一些。




图 2 反馈叠加方法比较

Fig. 2 Comparison of feedback stack methods

3.3 迭代条件的设定与阈值设定

3.3.1 阈值设定

经过多类别分类器之后得到的值是目标地物的丰度值,要将目标地物与背景分开,还需要设定阈值对丰度值进行切割,从而达到分类的目的。基于谱空特征迭代的分类方法采用逐步增加空间特征的方式,最终的检测结果中目标地物和背景地物已经区分得比较明显,本研究利用自适应阈值方法^[17]将高光谱图像地物目标和背景部分进行分类。图像背景和目标之间的类间方差越大,说明两者的差别越大,按照最大类间方差法设置阈值,将图像

分成背景和地物部分,分别代表高光谱数据的背景和地物目标。

3.3.2 迭代停止条件

所提方法旨在利用迭代方法进行多类别目标地物分类,提高高光谱类别分类器的通用性,因此分类模型还应具备自动停止迭代的功能。为了实现这一目标,采用 Jaccard 相似性系数^[18]来设定迭代的停止条件:

$$J^{(k)} = \frac{|S_k \cap S_{k-1}|}{|S_k| + |S_{k-1}| - |S_k \cap S_{k-1}|}, \quad (18)$$

式中 $|S|$ 的含义为集合 S 的大小, S_k 和 S_{k-1} 表示第

k 次和第 $k-1$ 迭代的阈值分类结果;

从(18)式可以看出, J 表示 S_k 与 S_{k-1} 之间的差异,其范围为 $0 < J < 1$ 。设定阈值 ϵ ($0.85 < \epsilon < 1$),当第 k 次与 $k-1$ 次迭代的分类结果交集与并集差大于 ϵ 时,表明这相邻两次分类结果比较接近,即第 k 次迭代取得了稳定的分类结果,迭代停止。

3.4 算法步骤

输入:高光谱图像数据 $\mathbf{r} = (\mathbf{r}_1, \mathbf{r}_2, \dots, \mathbf{r}_n)^T$,波段数目 L ,地物类别数目 p ;

初始化:设置初始迭代次数 $k=1$,迭代停止系数 ϵ ($0.85 < \epsilon < 1$),约束矩阵 \mathbf{C} ;

进行待分类地物目标 \mathbf{d}_m 的计算:

$$\mathbf{d}_m^k = \frac{1}{N_m} \left[\sum_{i=1}^{N_m} \mathbf{r}_m^k(i) \right], \quad (19)$$

式中 N_m 为第 m 类地物的样本数目, k 为迭代次数, $\mathbf{r}_m^k(i)$ 为第 m 类地物的第 i 个像元;

过程:以迭代的方式进行谱空特征融合分类;

输出:高光谱图像分类结果。

1)利用(19)式计算地物光谱特征矩阵: $\mathbf{D}^k = [\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_p]$;

2)利用(15)式计算像元 $\mathbf{r}(i)$ 的类别丰度值为 $\mathbf{T}_k = \mathbf{W}^{\text{MTCC}} \times \mathbf{r}(i)$;

3)利用 Otus 阈值分割方法将目标地物与背景地物分开;

4)迭代条件判断:按照(18)式计算迭代系数 $J^{(k)}$,如果 $J^{(k)} > \epsilon$,则跳到步骤 7;

5)利用(16)或(17)式提取 \mathbf{T}_k 中的空间特征 \mathbf{T}_{sk} ;

6) $k = k + 1$; 将 p 张含有空间特征的图像反馈叠加到 \mathbf{r} 中,令 $\mathbf{r} = \{\mathbf{r} \cup \mathbf{T}_{sk}\}$, $L = L + p$,跳到步骤 1 继续执行;

7)输出高光谱图像 p 个地物的分类结果。

4 实验结果与分析

4.1 实验评价标准

为评估本算法的分类性能,以下采用三组高光谱遥感图像数据集进行实验,其中 MTCC-1 表示采用(16)式进行反馈空间特征叠加的方法,MTCC-2 表示采用(17)式进行反馈空间特征叠加的方法,同时将本算法与文献[12]中提出的分类方法进行比较,选择文献[12]的方法是因为其是一个在谱空特征结合方面优秀的算法,该算法利用 SVM 进行分类,结合了谱间特征和空间特征,取得了不错的分类

精度。在分类方法评价方面,目前绝大多数的高光谱分类评价指标通常是总体精度(OA)、平均精度(AA)及 Kappa 系数,其评价标准是针对测试集中同一类像元数目而言的,缺少包含背景像元的分类准确率的计算。为了更客观地对分类方法进行评价,本研究利用的评价指标包括目标地物分类的精确率及分类精率,在计算的时候考虑了背景像元的分类结果对评价指标的影响。定义目标地物分类结果的混淆矩阵如表 1 所示,其中 C_i 表示地物的类别,BKG 表示背景类别, n_{ij} 表示真实结果中类别为第 j 类的地物,而分类结果为 i 类地物的像元数目。

表 1 C-类分类结果的混淆矩阵

Table 1 Confusion matrix of C-class classification results

Classification	Real result				
	C_1	C_2	\dots	C_n	BKG
C_1	n_{11}	n_{12}	\dots	n_{1n}	n_{1B}
C_2	n_{21}	n_{22}	\dots	n_{2n}	n_{2B}
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
C_n	n_{n1}	n_{n2}	\dots	n_{nn}	n_{nB}
BKG	n_{B1}	n_{B2}	\dots	n_{Bn}	n_{BB}

利用混淆矩阵,定义总的分类精度 A_O 与精确度 P ,以及每一类目标地物的分类精率 $C_{i,OA}$ 与精确率 $C_{i,Pre}$ 的计算公式如下:

$$A_O = \frac{\sum_{i=1}^p n_{ii}}{\sum_{i=1}^p \sum_{j=1}^p n_{ij}}, \quad (20)$$

$$P = \frac{\sum_{i=1}^p n_{ii} + n_{BB}}{\sum_{i=1}^p \sum_{j=1}^p n_{ij} + \sum_{i=1}^p n_{iB} + \sum_{i=1}^p n_{Bi}}, \quad (21)$$

$$C_{i,OA} = \frac{n_{ii}}{\sum_{j=1}^p n_{ji}}, \quad (22)$$

$$C_{i,Pre} = \frac{n_{ii}}{\sum_{j=1}^p n_{ij}}. \quad (23)$$

4.2 Indian Pine 实验区数据实验

Indian Pine 实验区数据是采用机载可见光/红外成像光谱仪(AVIRIS)在美国印第安纳州西北部获得的农田图像,以下简称 Purdue 数据,图像分辨率为 $145 \text{ pixel} \times 145 \text{ pixel}$,空间分辨率为 20 m,原始波段数目为 220 个,包括 16 类地物类别;其真实地物信息和已标注真实图像如图 3 所示,具体类别名称及每类所含的像元数目如表 2 所示。

表 2 Purdue 图像类别名称及像元数目

Table 2 Category name and pixel number of Purdue image

Label	Class name	Sample
Class 1	Alfalfa	46
Class 2	Corn-notill	1428
Class 3	Corn-min	830
Class 4	Corn	237
Class 5	Grass/pasture	483
Class 6	Grass/trees	730
Class 7	Grass/pasture-mowed	28
Class 8	Hay-windrowed	478
Class 9	Oats	20
Class 10	Soybeans-notill	972
Class 11	Soybeans-min	2455
Class 12	Soybeans-clean	593
Class 13	Wheat	205
Class 14	Woods	1265
Class 15	Bldg-grass green-drives	386
Class 16	Stone-steel towers	93
BKG	Background	10776

实验参数的设置为:在提取空间特征时,形态学开运算的结构元素为“圆盘”,大小为 3×3 ,形态学闭运算的结构元素为 3×3 的“正方形”;设置迭代停止系数 $\epsilon = 0.99$ 。MTCC-1 迭代 14 次,当 $J = 0.9901$ 时迭代分类停止,MTCC-2 迭代 18 次,当 $J =$

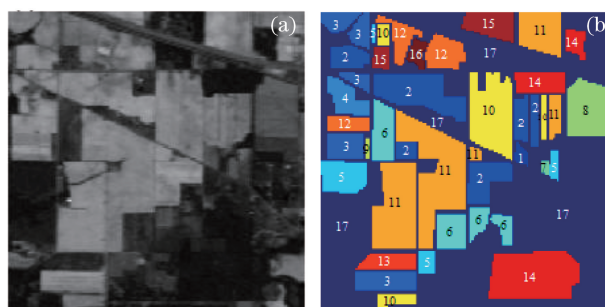


图 3 Purdue 图像。(a) 伪彩图像; (b) 真实地物图像
Fig. 3 Image of Purdue. (a) False color image; (b) image of ground truth

0.9938 时迭代分类停止。MTCC-1 和 MTCC-2 方法得到的分类结果分别如图 4、图 5 所示。表 3 列出的是所提方法与文献[12]中方法的比较,从实验数据可以看出,所提方法在平均 OA 上要高于文献[12]中提出的 4 种方法:EPF-B-g、EPF-B-c、EPF-G-g 和 EPF-G-c,最重要的是所提方法在准确率上要远远高于 EPF-B-g、EPF-B-c、EPF-G-g 和 EPF-G-c,这主要是因为 EPF-B-g、EPF-B-c、EPF-G-g 和 EPF-G-c 在进行分类的时候无法进行背景像元分类,因此只在测试集中的分类上精度高,而对所有的像元都进行考虑时,分类准确度就会大大下降。

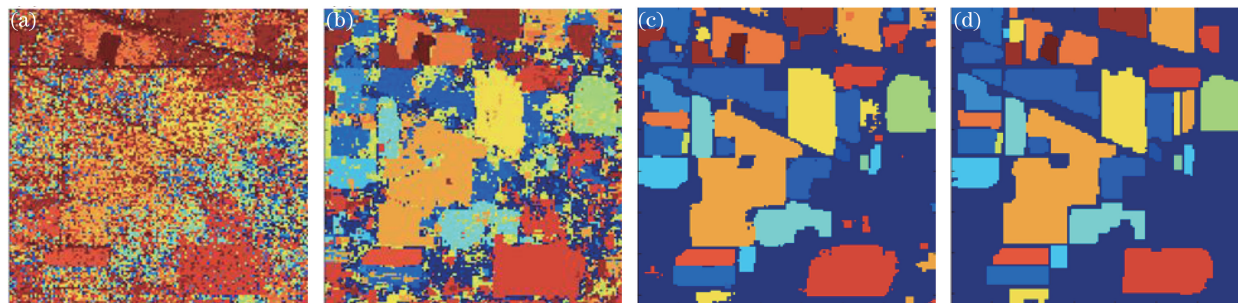


图 4 MTCC-1 方法得到的 Purdue 数据分类结果图。(a) 迭代 1 次; (b) 迭代 2 次; (c) 迭代 5 次; (d) 最终结果
Fig. 4 Classification results of Purdue data by MTCC-1 method. (a) Iteration for 1 time; (b) iteration for 2 times; (c) iteration for 5 times; (d) final result




图 5 MTCC-2 方法得到的 Purdue 数据分类结果图。(a) 迭代 1 次; (b) 迭代 2 次; (c) 迭代 5 次; (d) 最终结果
Fig. 5 Classification results of Purdue data by MTCC-2 method. (a) Iteration for 1 time; (b) iteration for 2 times; (c) iteration for 5 times; (d) final result

表 3 不同方法对 Purdue 数据的分类评价结果比较

Table 3 Comparison of classification evaluation results of Purdue data with different methods

%

Class	MTCC-1		MTCC-2		EPF-B-g		EPF-B-c		EPF-G-g		EPF-G-c	
	$C_{i,OA}$	$C_{i,Pre}$	$C_{i,OA}$	$C_{i,Pre}$	$C_{i,OA}$	$C_{i,Pre}$	$C_{i,OA}$	$C_{i,Pre}$	$C_{i,OA}$	$C_{i,Pre}$	$C_{i,OA}$	$C_{i,Pre}$
1	91.30	97.67	95.65	95.65	100.00	57.50	97.83	57.69	97.83	58.44	100.00	60.53
2	97.76	94.58	97.69	91.96	85.01	67.03	84.94	66.91	85.22	67.09	84.45	65.76
3	99.40	93.96	98.80	92.34	93.13	74.40	94.10	73.54	92.41	73.12	92.41	74.11
4	100.00	99.16	100.00	99.58	99.16	64.74	99.16	64.56	99.16	60.26	99.16	59.95
5	97.10	94.94	93.79	95.77	93.58	39.65	93.37	41.45	94.00	42.23	93.58	43.55
6	97.40	95.05	98.63	91.25	100.00	49.06	99.73	48.92	99.73	46.82	100.00	48.70
7	100.00	100.00	100.00	100.00	96.43	62.79	96.43	65.85	96.43	56.25	96.43	56.25
8	99.58	99.37	99.58	100.00	100.00	69.88	100.00	70.40	100.00	71.77	100.00	71.34
9	100.00	64.52	100.00	62.50	95.00	38.78	100.00	42.55	100.00	55.56	95.00	63.33
10	97.53	93.03	97.53	90.46	82.30	62.70	82.82	61.97	81.79	62.21	82.51	62.51
11	98.78	95.62	98.37	94.19	95.23	76.71	95.64	76.63	94.46	77.02	94.70	77.45
12	96.96	94.73	96.80	97.95	98.82	62.47	98.65	63.38	98.48	61.67	98.65	61.13
13	98.54	98.54	97.07	98.51	99.02	79.61	99.02	77.19	99.51	76.69	99.51	73.12
14	97.55	97.70	95.57	96.95	98.26	31.91	98.50	31.58	98.10	31.90	98.50	31.97
15	97.15	98.17	99.74	98.72	96.63	7.85	96.89	7.94	94.30	7.67	99.48	7.99
16	96.77	95.74	96.77	96.77	96.77	54.88	98.92	57.86	100.00	52.25	100.00	52.54
A_O	98.09		97.70		94.83		95.33		94.99		94.60	
P	96.84		96.00		46.23		46.47		46.31		46.12	

4.3 Salinas Valley 数据实验

Salinas Valley 数据是采用 AVIRIS 传感器在美国加利福尼亚州南部地区获取的 Salinas 山谷的高光谱图像,以下简称 Salinas 数据。图像的分辨率为 512 pixel×217 pixel,空间分辨率为 3.7 m,含有 224 个波段,共包括 16 类地物,其真实地物信息和已标注真实图像如图 6 所示,具体类别名称及每类所含的像元数目如表 4 所示。

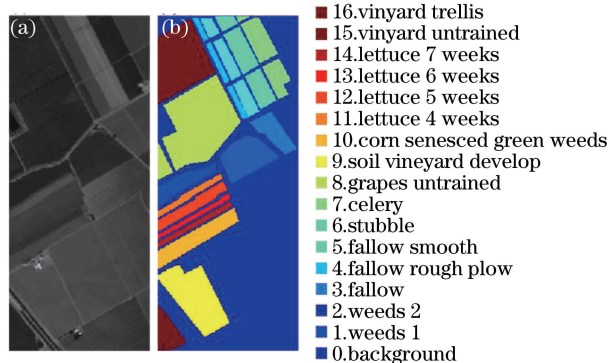


图 6 Salinas 山谷图像。(a)伪彩图像;(b)真实地物图像

Fig. 6 Image of Salinas Valley.

(a) False color image; (b) image of ground truth

实验参数的设置为:在提取空间特征时候,形态学开运算的结构元素为“圆盘”,大小为 5×5,形态学闭运算的结构元素为 3×3 的“正方形”;设置迭代停止系数 $\epsilon = 0.99$ 。MTCC-1 迭代 11 次,当 $J = 0.9905$ 时迭代分类停止,MTCC-2 迭代 13 次,当 $J =$

表 4 Salinas 图像类别名称及像元数目

Table 4 Category name and pixel number of Salinas image

Label	Class name	Sample
Class 1	Weed 1	2009
Class 2	Weed 2	3726
Class 3	Fallow	1976
Class 4	Fallow rough plow	1394
Class 5	Fallow smooth	2678
Class 6	Stubble	3959
Class 7	Celery	3579
Class 8	Grapes untrained	11271
Class 9	Soil vineyard develop	6203
Class 10	Corn	3278
Class 11	Lettuce 4 weeks	1068
Class 12	Lettuce 5 weeks	1927
Class 13	Lettuce 6 weeks	916
Class 14	Lettuce 7 weeks	1070
Class 15	Vineyard untrained	7268
Class 16	Vineyard trellis	1807
BKG	Background	56975

0.9924 时迭代分类停止。MTCC-1 和 MTCC-2 方法得到的分类结果分别如图 6、图 7 所示。表 5 列出的是所提方法与 EPF-B-g、EPF-B-c、EPF-G-g 和 EPF-G-c 方法的具体评价标准的比较。从结果可以看出,所提方法虽然只对第 8 类及第 15 类的 $C_{i,OA}$ 值要高于 EPF-B-g、EPF-B-c、EPF-G-g 和 EPF-G-c,但所提算法的每一类的分类精确度均比较稳定,并且平均 OA 要高于其他 4 种方法,值得注意的是在

准确率方面,所提方法远远高于 EPF-B-g、EPF-B-c、EPF-G-g 和 EPF-G-c,表明所提方法在分类的准确
度方面比较优秀。综合精确度与准确度的结果可以看出,所提算法的稳健性比较高。

表 5 不同方法对 Salinas 数据的分类评价结果比较

Table 5 Comparison of classification evaluation results of Salinas data with different methods %

Class	MTCC-1		MTCC-2		EPF-B-g		EPF-B-c		EPF-G-g		EPF-G-c	
	$C_{i,OA}$	$C_{i,Pre}$	$C_{i,OA}$	$C_{i,Pre}$	$C_{i,OA}$	$C_{i,Pre}$	$C_{i,OA}$	$C_{i,Pre}$	$C_{i,OA}$	$C_{i,Pre}$	$C_{i,OA}$	$C_{i,Pre}$
1	98.61	93.22	99.15	90.46	100.00	73.19	100.00	74.05	100.00	74.00	100.00	71.22
2	98.28	95.22	99.06	94.01	100.00	56.22	99.97	56.21	100.00	56.72	100.00	54.67
3	92.91	92.73	95.24	88.69	100.00	12.20	100.00	12.22	100.00	12.13	100.00	12.10
4	94.12	85.47	94.62	83.75	100.00	23.13	100.00	23.25	100.00	23.04	100.00	22.64
5	95.22	86.03	96.34	85.63	98.51	55.95	98.36	55.66	98.47	56.29	98.84	57.61
6	98.81	89.97	99.27	89.32	100.00	81.75	100.00	81.18	100.00	81.58	100.00	80.65
7	98.44	89.87	99.39	88.35	100.00	79.34	100.00	80.14	100.00	80.21	99.97	79.48
8	98.97	95.61	98.05	94.88	81.52	87.11	81.47	86.84	82.37	88.33	83.52	88.82
9	94.97	96.70	94.23	96.50	99.85	35.25	99.84	35.33	99.87	35.19	99.87	34.90
10	95.79	95.88	96.03	94.93	96.19	28.06	96.06	27.77	96.49	27.96	97.86	30.16
11	94.10	93.75	95.32	89.85	100.00	23.57	99.91	23.58	100.00	23.71	100.00	24.09
12	96.94	90.59	97.82	90.36	100.00	27.42	100.00	27.36	100.00	27.20	100.00	27.23
13	97.38	76.96	96.83	76.27	99.13	67.16	99.45	67.38	99.56	66.91	99.78	66.52
14	97.57	83.92	98.60	82.17	100.00	65.97	100.00	65.64	100.00	65.40	100.00	67.85
15	98.35	98.18	96.86	96.89	93.82	76.17	93.26	75.86	94.32	76.86	96.19	77.94
16	97.68	92.80	98.56	92.23	99.61	69.47	99.56	69.19	99.39	70.35	99.67	70.38
A_o	97.33		97.29		95.87		95.70		96.01		96.55	
P	95.32		94.81		46.71		46.63		46.77		47.04	




图 7 MTCC-1 方法得到的 Salinas 数据分类结果图。(a)迭代 1 次;(b)迭代 2 次;(c)迭代 5 次;(d)最终结果
Fig. 7 Classification results of Salinas data by MTCC-1 method. (a) Iteration for 1 time;
(b) iteration for 2 times; (c) iteration for 5 times; (d) final result




图 8 MTCC-2 方法得到的 Salinas 数据分类结果图。(a)迭代 1 次;(b)迭代 2 次;(c)迭代 5 次;(d)最终结果
Fig. 8 Classification results of Salinas data by MTCC-2 method. (a) Iteration for 1 time;
(b) iteration for 2 times; (c) iteration for 5 times; (d) final result

4.4 Pavia University 数据实验

Pavia University 数据是采用反射光学系统成像光谱仪 (ROSIS-03) 传感器在 Pavia 大学上空获取的城市地域图像, 以下简称 Pavia 数据, 图像分辨率为 $610 \text{ pixel} \times 340 \text{ pixel}$, 空间分辨率为 1.3 m , 含有 103 个波段, 共包括 9 类地物, 其真实地物信息和已标注真实图像如图 9 所示, 具体类别名称及每类所含的像元数目如表 6 所示。

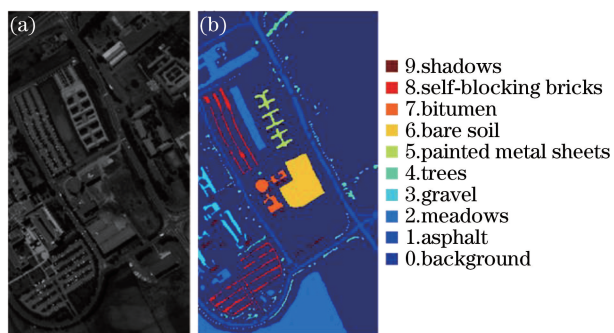


图 9 Pavia 大学图像。(a) 伪彩图像; (b) 真实地物图像
Fig. 9 Image of Pavia University. (a) False color image; (b) image of ground truth

实验参数的设置为: 在提取空间特征时候, 形态学开运算的结构元素为“圆盘”, 大小为 3×3 , 形态

表 6 Pavia 图像类别名称及像元数目

Table 6 Category name and pixel number of Pavia image

Label	Class name	Sample
Class 1	Asphalt	6631
Class 2	Meadows	18649
Class 3	Gravel	2099
Class 4	Trees	3064
Class 5	Painted metal sheets	1345
Class 6	Bare soil	5029
Class 7	Bitumen	1330
Class 8	Self-blocking bricks	3682
Class 9	Shadows	947
BKG	Background	164624

学闭运算的结构元素为 3×3 的“正方形”; 设置迭代停止系数 $\epsilon = 0.95$ 。MTCC-1 迭代 18 次, 当 $J = 0.9515$ 时迭代分类停止, MTCC-2 迭代 15 次, 当 $J = 0.9551$ 时迭代分类停止。MTCC-1 和 MTCC-2 方法得到的分类结果分别如图 10、图 11 所示。所提方法与 EPF-B-g、EPF-B-c、EPF-G-g 和 EPF-G-c 的综合平均指标详情如表 7 所示, 数据结果 (尤其是在准确率上) 进一步显示, 所提方法远远高于 EPF-B-g、EPF-B-c、EPF-G-g 和 EPF-G-c, 可以看出所提方法在识别背景像元方面的优异性能。

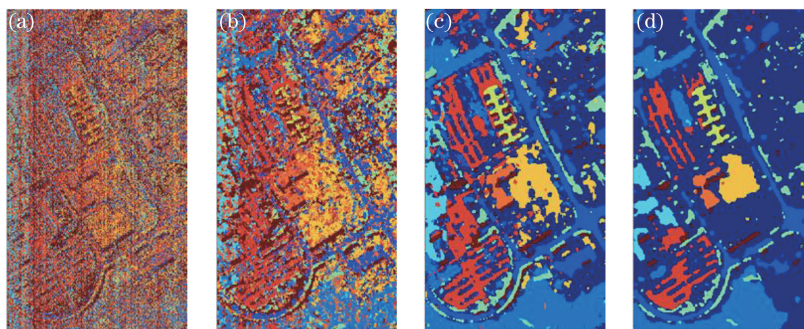


图 10 MTCC-1 方法得到的 Pavia 数据分类结果图。(a) 迭代 1 次; (b) 迭代 2 次; (c) 迭代 5 次; (d) 最终结果
Fig. 10 Classification results of Pavia data by MTCC-1 method. (a) Iteration for 1 time; (b) iteration for 2 times; (c) iteration for 5 times; (d) final result




图 11 MTCC-2 方法得到的 Pavia 数据分类结果图。(a) 迭代 1 次; (b) 迭代 2 次; (c) 迭代 5 次; (d) 最终结果
Fig. 11 Classification results of Pavia data by MTCC-2 method. (a) Iteration for 1 time; (b) iteration for 2 times; (c) iteration for 5 times; (d) final result

表 7 不同方法对 Pavia 数据的分类评价结果比较

Table 7 Comparison of classification evaluation results of Pavia data with different methods %

Class	MTCC-1		MTCC-2		EPF-B-g		EPF-B-c		EPF-G-g		EPF-G-c	
	$C_{i,OA}$	$C_{i,Pre}$	$C_{i,OA}$	$C_{i,Pre}$	$C_{i,OA}$	$C_{i,Pre}$	$C_{i,OA}$	$C_{i,Pre}$	$C_{i,OA}$	$C_{i,Pre}$	$C_{i,OA}$	$C_{i,Pre}$
1	83.56	32.66	85.06	23.00	97.07	18.28	97.10	18.20	96.53	18.56	96.95	18.72
2	85.05	85.17	84.63	76.47	98.10	36.51	98.09	36.48	98.13	37.10	98.16	37.42
3	80.04	42.60	76.46	33.66	91.47	34.19	91.71	34.55	91.76	35.11	91.81	35.02
4	83.86	22.37	84.93	19.18	95.04	10.03	93.99	9.93	94.35	10.21	98.14	10.69
5	99.12	61.43	98.03	60.02	100.00	42.92	100.00	44.42	100.00	41.81	100.00	44.63
6	85.41	89.91	88.24	85.92	100.00	9.69	100.00	9.74	100.00	9.73	100.00	9.72
7	87.37	70.25	85.29	66.51	100.00	39.82	100.00	39.19	100.00	40.82	100.00	41.34
8	82.03	27.09	90.52	22.79	99.02	19.19	98.72	19.23	98.91	19.28	99.51	19.31
9	80.15	24.55	73.22	19.06	100.00	9.41	100.00	9.15	100.00	7.44	100.00	7.00
A_o	84.68		85.43		98.97		98.95		98.84		99.17	
P	79.13		71.44		20.41		20.41		20.39		20.45	

5 结 论

提出了一种基于谱空特征迭代的高光谱多类别分类方法,该算法不需要进行样本训练,而是直接将地物的光谱特征矩阵作为输入,设计 MTCC 进行地物目标识别,通过将空间特征反馈迭代融入谱间特征的方式逐步增强分类器中地物的空间特征影响,并利用自适应丰度阈值分割方法与迭代自动停止判别的方式完成类别地物与背景的区别,达到高光谱地物分类的目的。值得一提的是,文中地物的光谱特征可以来自于光谱特征库,也可从采用监督式方式利用图像样本中的类别像元进行计算。实验结果表明,所提分类方法消除了复杂背景数据对分类效果的影响,并通过多类别分类器实现了高光谱亚像元分类,在分类精度与精确度方面均有不错的性能,具有较高的通用性与泛化能力。

参 考 文 献

- [1] Tong Q X, Zhang B, Zheng L F. Hyperspectral remote sensing: principles, techniques and applications[M]. Beijing: Higher Education Press, 2006.
童庆禧, 张兵, 郑兰芬. 高光谱遥感——原理、技术与应用[M]. 北京: 高等教育出版社, 2006.
- [2] Du P J, Xia J S, Xue Z H, *et al.* Review of hyperspectral remote sensing image classification[J]. Journal of Remote Sensing, 2016, 20(2): 236-256.
杜培军, 夏俊士, 薛朝辉, 等. 高光谱遥感影像分类研究进展[J]. 遥感学报, 2016, 20(2): 236-256.
- [3] Du B, Zhao R, Zhang L P, *et al.* A spectral-spatial based local summation anomaly detection method for hyperspectral images[J]. Signal Processing, 2016, 124(C): 115-131.
- [4] Dong A G, Li J C, Zhang B, *et al.* Hyperspectral image classification algorithm based on spectral clustering and sparse representation[J]. Acta Optica Sinica, 2017, 37(8): 0828005.
董安国, 李佳逊, 张蓓, 等. 基于谱聚类和稀疏表示的高光谱图像分类方法[J]. 光学学报, 2017, 38(8): 0828005.
- [5] Hou B H, Yao M L, Wang R, *et al.* Spatial-spectral semi-supervised local discriminant analysis for hyperspectral image classification[J]. Acta Optica Sinica, 2017, 37(7): 0728002.
侯榜焕, 姚敏立, 王榕, 等. 面向高光谱图像分类的空谱半监督局部判别分析[J]. 光学学报, 2017, 37(7): 0728002.
- [6] Theodoridis S, Koutroumbas K. Pattern recognition[M]. New York: Academic Press, 1999: 366.
- [7] Zhao Y Q, Zhang L, Kong S G. Band-subset-based clustering and fusion for hyperspectral imagery classification[J]. IEEE Transactions on Geoscience & Remote Sensing, 2011, 49(2): 747-756.
- [8] Gao H M, Li C M, Zhou H, *et al.* Dimension reduction and classification of hyperspectral remote sensing images based on sensitivity analysis of artificial neural network[J]. Journal of Electronics & Information Technology, 2016, 38(11): 2715-2723.
高红民, 李臣明, 周惠, 等. 神经网络敏感性分析的高光谱遥感影像降维与分类方法[J]. 电子与信息学报, 2016, 38(11): 2715-2723.
- [9] Fu L T, Deng H, Liu C H. Novel fast real-time target detection and classification algorithms for hyperspectral imagery[J]. Acta Optica Sinica, 2017, 37(2): 0230002.
付立婷, 邓河, 刘春红. 新型高光谱图像快速实时目标检测与分类方法[J]. 光学学报, 2017, 37(2): 0230002.
- [10] Su H J, Yong B, Du P J, *et al.* Dynamic classifier selection using spectral-spatial information for hyperspectral image classification[J]. Journal of Applied Remote Sensing, 2014, 8(1): 085095.

- [11] Zhang B, Li S S, Jia X P, *et al.* Adaptive Markov random field approach for classification of hyperspectral imagery[J]. *IEEE Geoscience & Remote Sensing Letters*, 2011, 8(5): 973-977.
- [12] Kang X D, Li S T, Benediktsson J A. Spectral-spatial hyperspectral image classification with edge-preserving filtering[J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2014, 52(5): 2666-2677.
- [13] Chen Y, Nasrabadi N M, Tran T D. Hyperspectral image classification using dictionary-based sparse representation[J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2011, 49(10): 3973-3985.
- [14] Guo X, Huang X, Zhang L F, *et al.* Support tensor machines for classification of hyperspectral remote sensing imagery[J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2016, 54(6): 3248-3264.
- [15] Chang C I, Liu J M, Chieu B C, *et al.* Generalized constrain edenergy minimization approach to subpixel target detection for multispectral imagery[J]. *Optical Engineering*, 2000, 39(5): 1275-1281.
- [16] Soille P. *Morphological image analysis*[M]. Berlin: Springer, 1999.
- [17] Otsu N. A threshold selection method from gray level histogram[J]. *IEEE Transactions on Systems, Man, and Cybernetics*, 1979, 9(2): 62-66.
- [18] Real R, Vargas J M. The probabilistic basis of Jaccard's index of similarity[J]. *Systematic Biology*, 1996, 45(3): 380-385.