

基于显著性剖面的高光谱图像分类算法

胡轩¹, 卢其楷^{2*}

¹武汉大学测绘遥感信息工程国家重点实验室, 湖北 武汉 430079;

²武汉大学电子信息学院, 湖北 武汉 430079

摘要 图像中的目标通常具有复杂的形状和尺寸, 现有方法难以充分挖掘地物的显著性空间信息。基于此, 提出一种基于显著性测度的形态学显著性剖面。首先, 根据图像区域内部灰度和轮廓信息计算显著性测度, 用于描述目标在场景中的重要程度, 然后提取具有显著性测度局部极大值的重要区域, 并通过多层级特征描述其空间信息。形态学显著性剖面的构造首先利用基于显著性测度的属性滤波滤除图像的冗余细节, 并保留图像的显著结构; 再根据图像中显著的组织结构生成层次化的空间特征。实验采用了两组高光谱数据集进行验证, 实验结果表明所提算法的分类效果优于其他形态学特征提取算法。

关键词 成像系统; 高光谱图像; 空谱联合分类; 数学形态学; 形态学显著性剖面

中图分类号 TP753

文献标志码 A

doi: 10.3788/AOS202040.1611001

Hyperspectral Image Classification Algorithm Based on Saliency Profile

Hu Xuan¹, Lu Qikai^{2*}

¹State Key Laboratory of Information Engineering in Surveying, Mapping and Remote Sensing,

Wuhan University, Wuhan, Hubei 430079, China;

²Electronic Information School, Wuhan University, Wuhan, Hubei 430079, China

Abstract Generally, the objects in an image have complex shapes and sizes. Therefore, it is difficult for the existing morphological features to completely describe the significant spatial information of the image. Hence, a morphological saliency profile is developed in this study based on the saliency measure. The grayscale and contour information of a particular area can be used to estimate the value of the saliency measure. This measure is used to describe the importance of a target in a scene. Thus, the important area of an image can be extracted based on the local maximum value of the saliency measure, and its spatial information can be obtained based on the multi-level features. When extracting the morphological saliency profile, attribute filtering based on the saliency measure is performed to eliminate redundant image details and retain the saliency profile of the image. Subsequently, the hierarchical spatial features are generated according to the saliency of the organization structure in the image. Two hyperspectral datasets are used in this experiment for verification. The experimental results demonstrate that the classification performance of the proposed algorithm is superior to those of the existing morphological feature extraction algorithms.

Key words imaging systems; hyperspectral images; spectral-spatial joint classification; mathematical morphology; morphological saliency profiles

OCIS codes 110.4234; 100.4145; 120.0280

1 引 言

高光谱传感器可以采集精细的地物光谱特征, 有利于精准区分地面覆盖物的类型^[1], 并在军事应用^[2]、精准农业^[3]和生态学^[4]等任务中得到了重视。高光谱遥感图像是地物信息提取的重要手段之一,

且分类算法能够根据图像特征获取地物的分布情况, 在遥感图像信息解译中发挥着举足轻重的作用。

近年来, 随着高光谱图像空间分辨率的不断提高, 结合图像空间信息和光谱信息的图像分类方法得到了研究者的广泛关注^[5]。其中, 形态学特征能够有效提取地物目标的空间结构信息, 是高光谱

收稿日期: 2020-04-03; 修回日期: 2020-04-26; 录用日期: 2020-05-06

基金项目: 国家重点研发计划(2018YFC0809100)

* E-mail: qikai_lu@hotmail.com

图像空间-光谱分类的研究热点^[6-7]。早期的形态学剖面^[8-9]利用一系列大小不同的结构元素对遥感图像进行重建开、闭运算以获取结构特征。尽管传统的形态学滤波器能够提取地物的空间结构特征,但其依赖于固定的结构元素,难以准确地表达图像场景中形状多变的地物。为了解决上述问题,研究者们近年来提出了基于属性滤波器的形态学属性剖面^[10]和消光剖面^[11],这两种方法能够较好地描述遥感图像的尺度、形状及灰度特征。属性滤波器^[12]通过直接合并原始图像的连通分量的方式来滤除图像中不满足预设准则的区域,因此能够更好地保持场景中的重要结构且不会引入原始图像中不存在的结构。属性剖面利用一系列不同阈值的属性滤波来提取空间特征,常用的属性有面积、标准差、最小包围盒对角线长度和几何不变矩。消光剖面引入消光值的概念来衡量图像中极值区域的稳定性,基于消光值的属性滤波器在保留最稳定极值区域的同时可以滤除其他极值区域,因此消光剖面利用一组不同阈值的消光滤波器来实现图像的多层级空间特征提取。

然而,场景中的对象在形状和尺寸上通常呈现复杂的变化情况,现有的方法难以完整地描述场景中的显著性空间信息^[13]。因此,本文提出了一种基

于显著性剖面(SP)的高光谱图像分类算法。该算法的核心思想:将遥感图像转化成由连通分量构成的形状树^[14]结构,根据形状树中节点的灰度对比度和轮廓信息计算一种用于描述节点重要性的显著性测度,进而依据显著性测度提取形状树中有意义的节点,最后根据场景中显著节点的组织结构自适应地生成 SP 特征。SP 既能保留所有不同形状的重要空间结构,又能移除同质区域内不重要的细节,从而达到简化图像和提取显著结构空间特征的目的。

2 算法介绍

图 1 为分类算法流程,构造 SP 主要有三个步骤:首先利用主成分分析(PCA)从高光谱图像中提取前三个主成分分量(PCs),将主成分分量的连通分量组织成形状树的形式,并计算形状树中节点的显著性测度;然后根据节点显著性测度提取形状树上重要的节点(A, B, C, ..., I),删除冗余节点(图中灰色节点 B, E, F, H);最后根据显著节点在形状树中的组织关系,自适应地构建多尺度特征图,将其串联(\oplus)成一组特征向量输入到支持向量机(SVM)中以生成分类图。其中 HSI 为数字图像的模式, i 的取值范围为 $[1, h-1]$, 其中 h 为新的树结构 T_0 的高度。

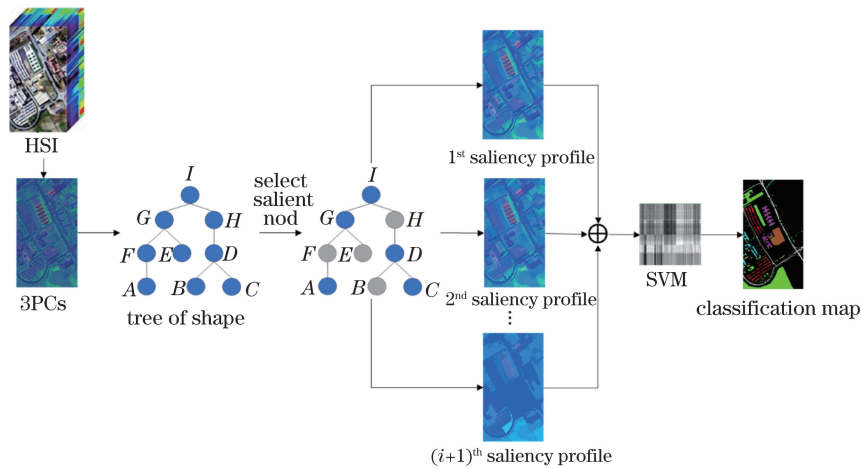


图 1 分类算法的流程

Fig. 1 Flowchart of classification algorithm

2.1 形状树

形状树是灰度图像的一种多层次表示形式,其可由两个简单的树结构 max-tree 和 min-tree^[12]合并而成。假设原始图像 $f: \Omega \rightarrow (E, \leq)$ 是一幅离散的灰度图像,其中 Ω 为图像的定义域, E 为灰度级的有序集合。对于任意一个给定的阈值 $\lambda \in E$, 对灰度图像进行阈值分割可以得到两幅二值图像,其

被称为上水平集 $X_{U,\lambda}(f) = \{p \in \Omega \mid f(p) \geq \lambda\}$ 和下水平集 $X_{D,\lambda}(f) = \{p \in \Omega \mid f(p) \leq \lambda\}$ 。max-tree 的节点就是上水平集中的连通分量 $C(X_{U,\lambda})$, min-tree 的节点就是下水平集中的连通分量 $C(X_{D,\lambda})$ 。对多个不同灰度级的阈值进行分割得到二值图像,并将其堆叠以形成灰度图像,因此灰度图像的连通分量就是这些二值图像连通分量的集合。根据不同

灰度级上的连通分量间包含与被包含的关系,就可以把连通分量组织成一个树结构,如图 2 所示。原始图像 f 由 4 个灰度级上 7 个灰度一致的平坦区域组成,如图 2(b)和 2(c)所示。max-tree 和 min-tree 中的叶子节点分别对应区域的极大值和极小

值。因此,max-tree 和 min-tree 上的滤波操作可以分别处理明、暗两类区域,但是遥感图像上存在众多亮背景中的暗对象和暗背景中的亮对象,为了能够同时处理明、暗两类区域,需要构造一种自对偶的树结构,即形状树^[15]。

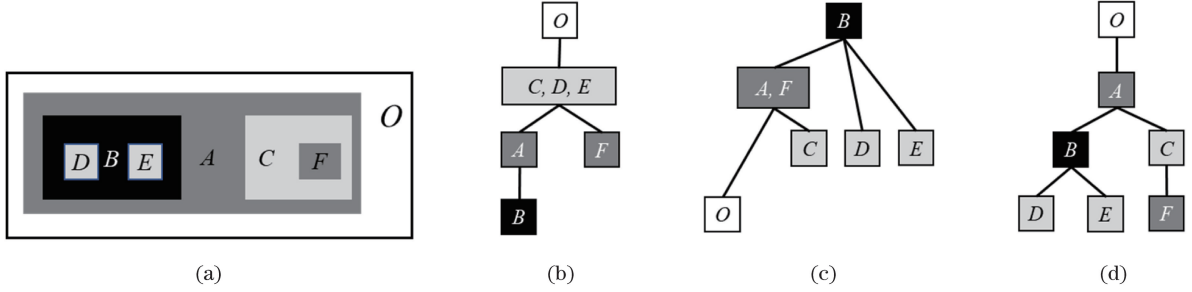


图 2 图像的树结构。(a)原始图像;(b) min-tree;(c) max-tree;(d)形状树

Fig. 2 Tree structure of image. (a) Original image; (b) min-tree; (c) max-tree; (d) tree of shape

形状树的节点可以表示为形状 $S[C(X)]$,节点对应的区域由连通分量 $C(X)$ 及其内部孔洞区域构成。由于灰度级定义在有序集合,因此形状树上任意两个节点的关系为不相交或者嵌套。根据节点的嵌套关系,可以把节点组织成树结构,如图 2(d)所示。形状树中叶子节点对应灰度图像的局部极值区域,这意味着形状树上的滤波器可以同时操作明、暗两种结构。

2.2 显著性测度

为了衡量节点在形状树中的重要程度,基于分段常数的 Mumford-Shah 能量函数提出了一种综合考虑灰度对比度和轮廓信息的显著性测度 \mathcal{A}_ν 。其中 ν 为正则化参数,其是一个人工设定的参数,用于控制图像分割的程度, ν 值越小,图像分割得越精细,反之亦然。基于分段常数的 Mumford-Shah 能量函数是 Mumford-Shah 模型的简化形式,其最初是一种用于图像分割的方法。假设 $(\partial R, \bar{f})$ 表示输入图像 $f: \Omega \rightarrow (E, \leq)$ 的一种划分方法,其中 \bar{f} 为各区域 $\Omega/\partial R$ 的平均灰度值, ∂R 为区域边缘的像素。原始图像 f 的划分可以通过对能量函数进行最小化来得到,表达式为

$$E(f, \partial R) = \iint_{\Omega} (\bar{f}_i - f)^2 dx dy + \nu |\partial R|, \quad (1)$$

式中: $|\partial R|$ 为 ∂R 的总数; (x, y) 为坐标。

ν 值能够决定图像分割的精细程度,因此可以根据 ν 对单个节点所处局部区域的能量函数的影响,获取衡量该节点重要程度的显著性测度。对于一个给定的 ν ,一个节点 τ 是否被移除取决于能量函数的变化,表达式为

$$\Delta E_\tau = \frac{S^2(f, R_\tau)}{|\partial R_\tau|} + \frac{S^2(f, R_{\tau_p})}{|\partial R_{\tau_p}|} - \frac{S^2(f, R'_{\tau_p})}{|\partial R'_{\tau_p}|} - \nu |\partial R_\tau|, \quad (2)$$

式中: τ_p 为 τ 的父节点; $S(\cdot)$ 为 τ 对应区域内所有像素的灰度值之和; R'_{τ_p} 为删除 τ 后, τ_p 对应的区域; R_{τ_p} 和 R_τ 为 τ_p 和 τ 对应的区域; $\partial R'_{\tau_p}$ 为删除 τ 后, τ_p 对应区域边缘的像素; ∂R_{τ_p} 和 ∂R_τ 为 τ_p 和 τ 对应区域边缘的像素。

假设 ν 的最小值 ν_{\min} 满足 $\Delta E_\tau = \frac{S^2(f, R_\tau)}{|\partial R_\tau|} + \frac{S^2(f, R_{\tau_p})}{|\partial R_{\tau_p}|} - \frac{S^2(f, R'_{\tau_p})}{|\partial R'_{\tau_p}|} - \nu_{\min} |\partial R_\tau|$ 。当 ν 值小于 ν_{\min} 值时, ΔE_τ 的符号为正,这说明删除 τ 会使图像的 ΔE_τ 值增加,因此需要保留该节点,随着 ν 值的增加, ΔE_τ 值会逐渐下降,直到 ν 值大于 ν_{\min} 值, ΔE_τ 的符号变为负,因此 ν_{\min} 是决定一个节点是否被删除的临界值。

假设 $\mathcal{A}_\nu(\tau)$ 决定 τ 是否被删除的临界值,表达式为

$$\mathcal{A}_\nu(\tau) = \left[\frac{S^2(f, R_\tau)}{|\partial R_\tau|} + \frac{S^2(f, R_{\tau_p})}{|\partial R_{\tau_p}|} - \frac{S^2(f, R'_{\tau_p})}{|\partial R'_{\tau_p}|} \right] / |\partial R_\tau|. \quad (3)$$

为了计算形状树上所有节点的 $\mathcal{A}_\nu(\tau)$,首先根据节点边缘的梯度平均值 \mathcal{A}_ν 对所有的结点进行升序排列。移除当前节点 B ,并更新其父节点与子节点的父子关系,移除节点 B 意味着 B 的子节点 D 和 E 直接成为节点 A 的子节点,并且属于节点 B

的像素会被合并到其父节点 A , 如图 3 所示。由此可见, Mumford-Shah 模型中, 节点是否被删除与其所处的局部区域有关, 节点 B 的父节点和子节点的 $\mathcal{A}_v(\tau)$ 会随着 B 被移除而改变。因此, 有必要在计算 $\mathcal{A}_v(\tau)$ 之前对所有的节点按合理的顺序进行排列。

$\mathcal{A}_v(\tau)$ 能够衡量节点重要性的原因: 一方面 Mumford-Shah 能量函数的保真项 $\iint_R (\bar{f}_i - f)^2 dx dy$ 倾向移除图像中局部区域之间对比度较低的细节; 另一方面, 正则项 $\nu |\partial R|$ 倾向抑制边缘复杂的形

状。实际上, 遥感图像中的地物通常具有清晰的边缘, 并且与周围类别不同的地物有较明显的差异。因此, $\mathcal{A}_v(\tau)$ 从区域边缘信息和同质性的角度衡量节点在形状树中的重要程度, 具有一定的合理性。图 4(b) 和图 4(c) 为遥感图像 Pavia 大学形状树 T 中的一个分支, 其属性 \mathcal{A}_v 和 \mathcal{A}_s 从叶子节点到根节点的变化曲线。从图 4(b) 和图 4(c) 可以看到, 房顶及作为其背景的一块空地对应 \mathcal{A}_s 曲线上明显的极大值点, \mathcal{A}_v 也能够反映形状的重要性, 说明其具有计算 \mathcal{A}_s 初始排序的合理性。




图 3 节点属性的计算过程。(a) 原始图像; (b) 移除节点 B ; (c) 移除节点 B 之前的形状树; (d) 移除节点 B 之后的形状树

Fig. 3 Calculation process of node attributes. (a) Original image; (b) remove node B ; (c) tree of shape before removing node B ; (d) tree of shape after removing node B

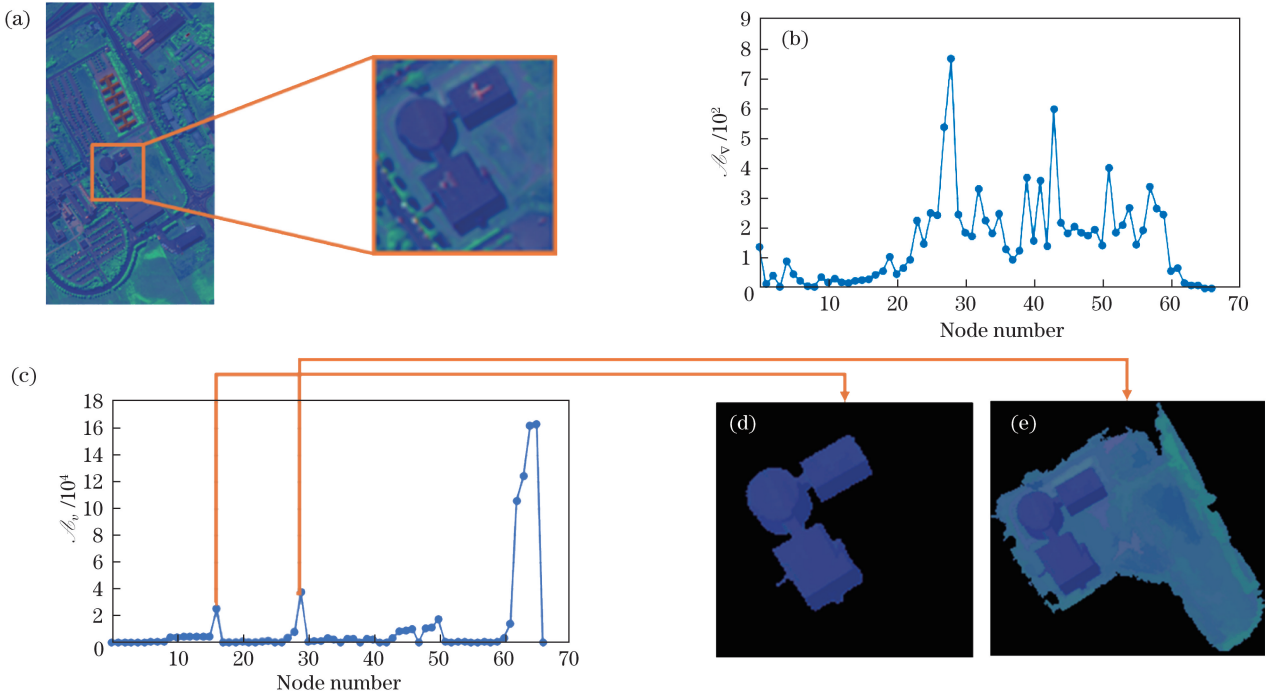


图 4 真实遥感图像。(a) \mathcal{A}_s 的示例图像; (b)(c) \mathcal{A}_v 和 \mathcal{A}_s 从叶子节点到根节点的变化曲线; (d)(e) 图(c)中两个显著极大值点对应的显著区域

Fig. 4 Real remote sensing image. (a) Sample images of \mathcal{A}_s ; (b)(c) change curves of \mathcal{A}_v and \mathcal{A}_s from leaf node to root node; (d)(e) significant areas corresponding to two significant maximum points in Fig. (c)

2.3 SP 的构造方法

为了提取形状树 T 中重要的节点, 需要设定一

个参数 h_v 用于提取 \mathcal{A}_s 曲线上明显的局部最大值点。对于一个节点 τ , 假设 τ_c 为 τ 的子节点, 如果满足

$$\mathcal{A}_v(\tau) - \mathcal{A}_v(\tau_p) \geq h_v, \quad (4)$$

$$\mathcal{A}_v(\tau) - \mathcal{A}_v(\tau_c) \geq h_v, \quad (5)$$

则认为 τ 是重要的节点,反之节点 τ 将作为冗余节点,从形状树中删除。

然后,创建一个新的树结构 T_0 。用于存储 T 的所有重要节点。SP 的第一个特征图 S_{P_0} 由 T_0 重建得到。接着定义 $L_F(T)$ 用于删除 T 中所有叶子节点的自对偶操作,通过逐层滤除叶子节点来得到不同尺度上重要结构的特征图。SP 的第 $i+1$ 个特征图 S_{P_i} 由第 i 个形状树 T_i 重建得到,其中 $T_i = L_F(T_{i-1})$ 。一个完整的 SP 可以表示为

$$S_{SP} = \{R_C(T_0), \dots, R_C[L_F(T_{i-1})], \dots, R_C[L_F(T_{h-2})]\}, \quad (6)$$

式中: $R_C(T)$ 为将 T 重建为图像的操作。

构造 SP 的算法步骤如下。

1) 使用 PCA 对高光谱图像进行降维,得到前 c 个包含原始数据的总方差至少为 99% 的主成分分量。

2) 对每个主成分分量都生成对应的 T 。

3) 利用(3)式计算 T 的 \mathcal{A}_v 。

4) 逐个判断节点是否满足(4)式和(5)式的条件,删除不满足(4)式和(5)式的冗余节点。

5) 创建一个 T_0 以保存 T 中所有的重要节点,利用(6)式对 T_0 重复进行重建和滤波操作,直到根节点结束,从而得到一个完整的 SP。

3 实验结果与分析

3.1 实验数据的描述

Indian Pines 数据集是 AVIRIS 传感器在美国 Indiana 上空拍摄尺寸为 $145 \text{ pixel} \times 145 \text{ pixel}$ 的高光谱图像。AVIRIS 传感器能够捕获 224 个波段的高光谱图像,覆盖的光谱范围为 $0.4 \sim 2.5 \mu\text{m}$,其空间分辨率为 20 m。剔除部分水吸收波段后,该数据集中实际可用的波段数为 200 个。该场景主要包含农作物、林木和其他一些植被,共有 16 类。从中选择样本数量超过 300 的 10 个主要类型进行分类实验。图 5 为该数据集的假彩色合成图像及其地物类型调查结果,各类地物的样本数量如表 1 所示。

表 1 Indian Pines 数据集的样本数量

Table 1 Number of samples in Indian Pines dataset

No.	Name	Number of samples
1	Corn-notill	1428
2	Corn-mintill	830
3	Grass-pasture	483
4	Grass-tree	730
5	Hay-windrow	478
6	Soybean-notill	972
7	Soybean-mintill	2455
8	Soybean-clean	593
9	Wood	1265
10	Building-grass-tree-drive	386
Total		9620




图 5 Indian Pines 数据集的高光谱图像。(a)假彩色合成图像;(b)地物类型调查结果

Fig. 5 Hyperspectral images of Indian Pines dataset. (a) False color composite image; (b) survey results of feature types

Pavia 大学数据集是 ROSIS-03 传感器在意大利 Pavia 大学校园上空捕获的高光谱图像。图像的尺寸为 $610 \text{ pixel} \times 340 \text{ pixel}$,空间分辨率为 1.3 m,共有 103 个波段。该场景的地物共有 9 类,其假彩色合成图像和对应的地物类型调查结果如图 6 所示,各类地物的样本数量如表 2 所示。

3.2 实验设置

为了验证扩展显著性剖面(ESP)算法的有效性,采用 SVM^[16]、扩展形态学剖面(EMP)^[17]、扩展

形态学属性剖面(EMAP)^[18]、扩展形态学消光剖面(EEP)^[19]和基于超像素的多核分类(SC-MK)^[20]进行对比实验。其中 SVM 在分类时仅考虑原始图像的光谱信息,其核函数为高斯核函数;EMP 和 EMAP 分别使用形态学开、闭重建运算和属性滤波器来提取多层次的空间信息;EEP 通过使用面向极值的消光滤波器来提取图像中最主要极值区域的空间信息;SC-MK 利用超像素来提取超像素内特征和超像素间特征,并使用多核 SVM 进行空谱联合分类。

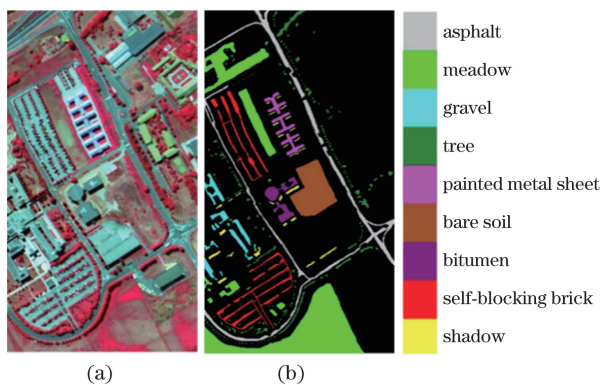


图 6 Pavia 大学数据集的高光谱图像。
 (a)假彩色合成图像;(b)地物类型调查结果
 Fig. 6 Hyperspectral images of Pavia university dataset.
 (a) False color composite image; (b) survey results of feature types

表 2 Pavia 大学数据集的样本数量
 Table 2 Number of samples in Pavia university dataset

No.	Name	Number of samples
1	Asphalt	6631
2	Meadow	18649
3	Gravel	2099
4	Tree	3064
5	Painted metal sheet	1345
6	Bare soil	5029
7	Bitumen	1330
8	Self-blocking brick	3682
9	Shadow	947
Total		42776

实验中,两个数据集在提取 SP, h_v 值被固定为 20;对于所有使用 SVM 的方法,SVM 参数都是由 5 次交叉验证得到优化后的值;EMP、EEP 和 SC-MK 参数分别参考文献[17,19-20]中建议值来设置;对于 EMAP 算法,采用最常用的两个属性面积和标准差,面积的 5 个阈值为 [50,100,200,500,1000],标准差的 8 个阈值为 [10,20,30,40,50,60,70,80]。

对于所有数据集,训练样本都是从各个类别中随机挑选的 50 个样本,实验最终结果是 10 次重复结果的平均值。实验的定量分析指标有总体精度(OA),平均精度(AA)及 Kappa 系数(K)。

3.3 实验结果分析

各个算法在 Indian Pines 数据集获得的分类结果如图 7 所示。从图 7 可以看到,SVM 分类图上存在较严重的椒盐噪声,这是因为 SVM 仅利用原始的光谱信息;相对于 SVM,EMP 的分类结果有轻微改善,但依然存在较严重的误分类;EMAP、EEP、SC-MK 及 ESP 的分类图比 SVM 更平滑,因为利用以上方法提取的空间信息,减少了噪声和同物异谱的影响,从而改善了分类图中区域内部的分类效果。ESP 的 OA 分别比 EMP、EMAP、EEP 高出 20.80,12.67,11.12 个百分点,如表 3 所示。原因是 SP 能够提取图像中显著结构的空 间信息,并且极大地简化图像中不重要的细节,从而提高分类图中区域内部 的同质性,减少同质区 域内部的误分类现象。

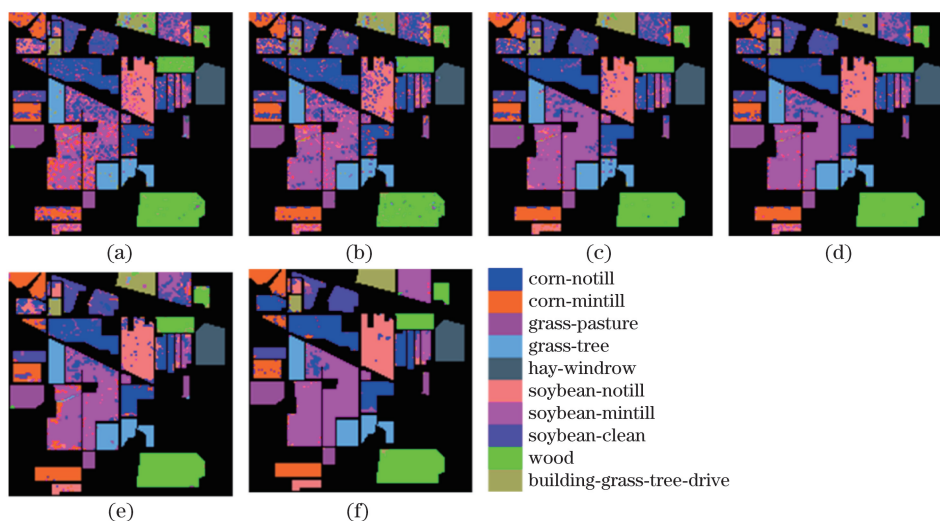


图 7 不同算法在 Indian Pines 数据集上的分类结果。(a) SVM; (b) EMP; (c) EMAP; (d) EEP; (e) SC-MK; (f) ESP
 Fig. 7 Classification results of different algorithms on Indian Pines dataset. (a) SVM; (b) EMP; (c) EMAP; (d) EEP; (e) SC-MK; (f) ESP

表 3 Indian Pines 数据集的分类精度

Table 3 Classification accuracy of Indian Pines dataset

Class	SVM	EMP	EMAP	EEP	SC-MK	ESP
1	66.99	70.29	76.79	79.30	81.00	92.54
2	67.59	70.92	78.60	79.28	87.78	94.88
3	91.48	90.81	91.34	92.24	95.61	97.71
4	93.71	94.81	96.65	97.40	97.32	99.94
5	99.44	99.39	99.65	99.51	99.98	100.00
6	74.32	69.92	82.66	84.39	85.80	94.08
7	55.89	60.64	72.67	74.02	77.09	91.86
8	72.69	67.66	74.99	79.96	88.03	93.08
9	84.32	85.88	92.91	93.79	94.04	99.10
10	73.27	79.58	92.77	94.88	94.67	98.87
OA / %	72.41	74.20	82.33	83.88	86.50	95.00
AA / %	77.97	78.99	85.90	87.48	90.13	96.20
K	68.38	70.40	79.63	81.42	84.40	94.19

表 4 Pavia 大学数据集的分类精度

Table 4 Classification accuracy of Pavia university dataset

Class	SVM	EMP	EMAP	EEP	SC-MK	ESP
1	93.76	98.17	93.46	94.48	95.37	98.27
2	94.48	98.47	90.88	95.79	95.62	97.65
3	67.72	73.85	89.47	97.40	97.76	96.10
4	81.87	96.86	97.07	98.79	96.34	86.84
5	95.78	98.89	99.20	99.52	99.96	99.82
6	62.66	85.03	95.68	96.65	97.78	99.99
7	60.36	94.66	97.38	97.62	99.95	100.00
8	81.19	92.51	85.97	97.16	94.84	97.65
9	99.53	99.69	100.00	98.13	99.99	98.22
OA / %	84.24	94.43	92.44	96.76	96.28	97.33
AA / %	79.72	92.76	94.35	97.53	97.51	97.17
K	82.52	93.01	90.12	95.68	95.11	96.45

图 8 和表 4 分别为各算法在 Pavia 大学数据集上的分类结果和精度。与 Indian Pines 数据集的实验结果类似,ESP 的 OA 及 Kappa 系数均高于其他方法,相比 EMP、EMAP、EEP 和 SC-MK,ESP 的 OA 分别提高 2.90,4.89,0.57 和 1.05 个百分点。从图 8 可以看到,EMP、EMAP、EEP 和 SC-MK 的分类结果存在较明显的误分类,如图中底部的草地

和中部的裸土区域内部有许多像素被识别为其他类别;ESP 的分类图在这些区域有明显改善,这是因为基于显著性测度的滤波器极大地简化了图像,滤除大量区域内部的冗余细节。

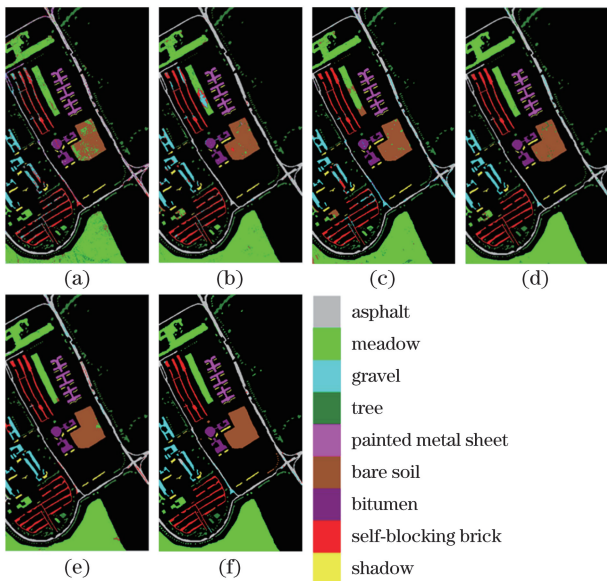


图 8 不同算法在 Pavia 大学数据集上的分类结果。
(a) SVM; (b) EMP; (c) EMAP; (d) EEP;
(e) SC-MK; (f) ESP

Fig. 8 Classification results of different algorithms on Pavia university dataset. (a) SVM; (b) EMP; (c) EMAP; (d) EEP; (e) SC-MK; (f) ESP

和图 9 为在 Pavia 大学数据集中前三个主成分分量上计算得到的 SP,表 5 为不同尺度的形状数量。从图 9 可以看到, S_{P_i} 对原始图像的简化程度随着滤波次数的增加而增大,当 i 值较小时, S_{P_i} 包含原始图像更多的细节;当 i 值较大时, S_{P_i} 更靠近形状树的根节点,能够简化原始图像中的结构。从表 5 可以看到,在保留显著形状的同时,形状树上大部分的节点都被删除,如原始图像有 53653 个节点,而 S_{P_0} 只保留 2259 个节点。由于 SP 是对形状树进行逐层滤波而得到,因此其满足多尺度分析中“因果关系原则”的多层级特征,即在精细尺度下消失的结构不会出现在后面粗糙尺度的特征图上。实验结果证明了 SP 可以根据 \mathcal{A}_i 来捕获场景中不同尺度下显著结构的空信息,从而得到令人满意的分类结果。

h_v 对 OA 的影响如图 10 所示。从图 10 可以看到,当 h_v 在 $[10,200]$ 范围内变化时,ESP 在两个数据集上的 OA 值都比较稳定,波动范围在 0.5 个百分点以内。从图 10 可以看到,设置一个较小的 h_v 值,足以删除形状树上大量不重要的节点,当 h_v 值增大时,形状树上越来越多的节点被删除,则会丢失过多的细节信息,反而会引起 OA 值的降低。因此,对于两幅图像, h_v 都设置为 20。




图 9 在 Pavia 大学数据集上不同特征图的 SP。(a)原始图像；(b) S_{P_0} ；(c) S_{P_1} ；(d) S_{P_2} ；(e) S_{P_3} ；(f) S_{P_4} ；(g) S_{P_5} ；(h) S_{P_6} ；(i) S_{P_7} ；(j) S_{P_8} ；(k) S_{P_9} ；(l) $S_{P_{10}}$

Fig. 9 SP of different feature images on Pavia university dataset. (a) Original image; (b) S_{P_0} ; (c) S_{P_1} ; (d) S_{P_2} ; (e) S_{P_3} ; (f) S_{P_4} ; (g) S_{P_5} ; (h) S_{P_6} ; (i) S_{P_7} ; (j) S_{P_8} ; (k) S_{P_9} ; (l) $S_{P_{10}}$

表 5 不同特征图的尺度形状数量对比

Table 5 Comparison of number of scale shapes of different feature images

Feature map	Number of scale shapes
Original image	53653
S_{P_0}	2259
S_{P_1}	1072
S_{P_2}	645
S_{P_3}	416
S_{P_4}	242
S_{P_5}	170
S_{P_6}	120
S_{P_7}	103
S_{P_8}	85
S_{P_9}	60
$S_{P_{10}}$	41

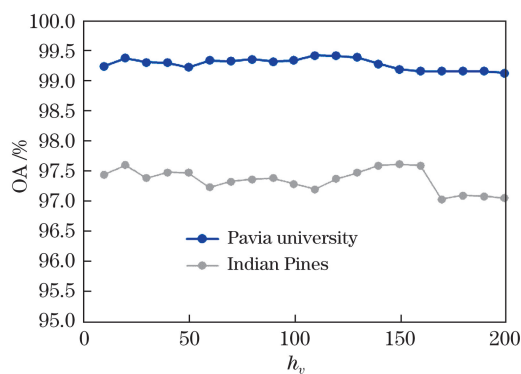


图 10 h_v 与 OA 的关系曲线

Fig. 10 Relationship curves between h_v and OA

4 结 论

提出一种基于 SP 的高光谱图像分类算法。SP 利用 \mathcal{A}_v 简化形状树,根据显著节点的组织结构,自动生成多尺度特征。该算法利用灰度对比度和轮廓信息衡量形状树节点的重要程度,能够在保留图像中关键结构的同时滤除大量冗余的细节。此外,现有的形态学特征通常需要设置一组阈值用于提取多尺度特征,而 SP 能够根据显著节点在形状树中的组织结构自适应地生成多尺度特征。这种特征构造方式不仅能为不同尺度上的空间信息提供更连续、更完整的特征描述,而且大大减少现有形态学特征中阈值设置的负担。实验结果表明:相对于其他形态学特征,SP 在精度指标和分类图目视效果方面均有较大提高。未来会考虑将区域的纹理信息引入形态学特征中,进而构造更具判别力的空间特征。

参 考 文 献

- [1] Yu C Y, Zhao M, Song M P, et al. Hyperspectral image classification method based on targets constraint and spectral-spatial iteration[J]. Acta Optica Sinica, 2018, 38(6): 0628003.
于纯妍, 赵猛, 宋梅萍, 等. 基于目标约束与谱空迭代的高光谱图像分类方法 [J]. 光学学报, 2018, 38(6): 0628003.

- [2] Zhao C H, You W, Qi B, et al. Real-time anomaly detection algorithm for hyperspectral remote sensing by using recursive polynomial kernel function [J]. *Acta Optica Sinica*, 2016, 36(2): 0228002.
赵春晖, 尤伟, 齐滨, 等. 采用多项式递归核的高光谱遥感异常实时检测算法 [J]. *光学学报*, 2016, 36(2): 0228002.
- [3] Haboudane D, Miller J R, Pattey E, et al. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: modeling and validation in the context of precision agriculture [J]. *Remote Sensing of Environment*, 2004, 90(3): 337-352.
- [4] Jiang X Q, Ye Q, Lin Y, et al. Inverting study on soil water content based on harmonic analysis and hyperspectral remote sensing [J]. *Acta Optica Sinica*, 2017, 37(10): 1028001.
姜雪芹, 叶勤, 林怡, 等. 基于谐波分析和高光谱遥感的土壤含水量反演研究 [J]. *光学学报*, 2017, 37(10): 1028001.
- [5] Liu T Z, Gu Y F, Chanussot J, et al. Multimorphological superpixel model for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(12): 6950-6963.
- [6] Ghamisi P, Dalla Mura M, Benediktsson J A. A survey on spectral-spatial classification techniques based on attribute profiles [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(5): 2335-2353.
- [7] Ma L, Li M C, Ma X X, et al. A review of supervised object-based land-cover image classification [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2017, 130: 277-293.
- [8] Pesaresi M, Benediktsson J A. A new approach for the morphological segmentation of high-resolution satellite imagery [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2001, 39(2): 309-320.
- [9] Palmason J A, Benediktsson J A, Sveinsson J R, et al. Classification of hyperspectral data from urban areas using morphological preprocessing and independent component analysis [C] // *Proceedings of 2005 IEEE International Geoscience and Remote Sensing Symposium*, 2005, July 29-29, 2005, Seoul, Korea. New York: IEEE, 2005: 8884363.
- [10] Dalla Mura M, Villa A, Benediktsson J A, et al. Classification of hyperspectral images by using extended morphological attribute profiles and independent component analysis [J]. *IEEE Geoscience and Remote Sensing Letters*, 2011, 8(3): 542-546.
- [11] Ghamisi P, Souza R, Benediktsson J A, et al. Extinction profiles for the classification of remote sensing data [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(10): 5631-5645.
- [12] Salembier P, Wilkinson M H F. Connected operators: a review of region-based morphological image processing techniques [J]. *IEEE Signal Processing Magazine*, 2009, 26(6): 136-157.
- [13] Demir B, Bruzzone L. Histogram-based attribute profiles for classification of very high resolution remote sensing images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(4): 2096-2107.
- [14] Xu Y C, Géraud T, Najman L. Salient level lines selection using the Mumford-Shah functional [C] // *2013 IEEE International Conference on Image Processing*, September 15-18, 2013, Melbourne, VIC, Australia. New York: IEEE, 2013: 1227-1231.
- [15] Dalla Mura M, Benediktsson J A, Bruzzone L. Self-dual attribute profiles for the analysis of remote sensing images [M] // Soille P, Pesaresi M, Ouzounis G K. *Mathematical morphology and its applications to image and signal processing. Lecture notes in computer science*. Heidelberg: Springer, 2011, 6671: 320-330.
- [16] Mountrakis G, Im J, Ogole C. Support vector machines in remote sensing: a review [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2011, 66(3): 247-259.
- [17] Benediktsson J A, Palmason J A, Sveinsson J R. Classification of hyperspectral data from urban areas based on extended morphological profiles [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, 43(3): 480-491.
- [18] Marpu P R, Pedergnana M, Mura M D, et al. Classification of hyperspectral data using extended attribute profiles based on supervised and unsupervised feature extraction techniques [J]. *International Journal of Image and Data Fusion*, 2012, 3(3): 269-298.
- [19] Ghamisi P, Souza R, Benediktsson J A, et al. Hyperspectral data classification using extended extinction profiles [J]. *IEEE Geoscience and Remote Sensing Letters*, 2016, 13(11): 1641-1645.
- [20] Fang L Y, Li S T, Duan W H, et al. Classification of hyperspectral images by exploiting spectral-spatial information of superpixel via multiple kernels [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(12): 6663-6674.