

# 基于自动阈值属性形态剖面光谱空间联合特征编码的高光谱图像分类

杨培琦\*, 王明军

西安理工大学自动化与信息工程学院, 陕西 西安 710048

**摘要** 高光谱图像分类的有效特征提取仍然是遥感中具有挑战性的研究课题。为了解决这个问题,提出一种基于自动阈值属性形态剖面的光谱空间特征框架用于高光谱图像分类。它包含两个阶段:1)将高光谱图像灰度值转化为树形结构的属性形态剖面,利用所提自动阈值方法进行过滤树操作,以创建最终的扩展多元属性形态剖面,获得空谱特征数据。这种方法不需要自定义任何阈值,仅需要少量的过滤操作就可以获得最大的空间信息。2)将获得的空谱特征数据通过训练的光谱角度映射堆叠式自动编码器网络来创建有效的分类器,得到最终的分类结果。通过在两个真实的高光谱图像数据集上应用这种改进方法并将结果与现有方法进行比较,证明了该方法的有效性。

**关键词** 图像处理; 高光谱图像; 属性形态剖面; 自动阈值; 深度特征

中图分类号 O436

文献标志码 A

DOI: 10.3788/LOP220589

## Hyperspectral Image Classification Based on Automatic Threshold Attribute Profiles and Spatial-Spectral Encoding Union Features

Yang Peiqi\*, Wang Mingjun

School of Automation and Information Engineering, Xi'an University of Technology,  
Xi'an 710048, Shaanxi, China

**Abstract** The effective extraction of features for hyperspectral image classification is a challenging research topic in remote sensing. To solve this problem, a spatial-spectral feature framework with an automatic threshold attribute profile is proposed for hyperspectral image classification. The framework includes two stages. The first stage involves conversion of the grayscale value of the hyperspectral image into an attribute morphological profile of the tree structure, filtering the tree using the proposed automatic threshold method to create the final extended multivariate attribute morphological profile, and using the profile to obtain the spatial-spectral feature data. The proposed method does not require the customization of any thresholds and only requires a few filtering operations to obtain the maximum spatial information. Then, in the second stage, the derived spatial-spectral feature data are used to create an effective classifier using a trained spectral angle mapping stackable automatic encoder network to obtain the final classification result. Finally, the effectiveness of the method is verified by applying it to two real hyperspectral image datasets and comparing the results with those of existing methods.

**Key words** image processing; hyperspectral image; attribute profile; threshold-free; deep feature

## 1 引言

高光谱图像(HSI)分类在遥感中至关重要,被用于各种应用<sup>[1-4]</sup>,如地质勘探、植被生态监测、灾害监测和风险管理<sup>[5]</sup>等。高光谱传感器从数百个相邻波段场景中获取反射光强度,波段范围可以从可见光到近红

外、中红外等部分,具有更多波段信息。由于嵌入了丰富的光谱内容,如果处理得当,HSI可以在土地覆盖图像分类和识别方面提供比多光谱图像更高的准确性和细节。在相邻位置捕获的信息可以在像素分析中产生额外的信息。因此,关联空间特征和光谱信息可以提高图像边界的确定性,进一步改善分类结果。

收稿日期: 2022-01-20; 修回日期: 2022-04-13; 录用日期: 2022-06-28; 网络首发时间: 2022-07-08

基金项目: 国家自然科学基金重大研究计划培育项目(92052106)、陕西省杰出青年科学基金(2020JC-42)

通信作者: \*2180321225@stu.xaut.edu.cn

属性形态剖面(AP)<sup>[6]</sup>是这方面的突出技术,它可以利用任何可计算的属性来实现对图像的多尺度分析。AP是基于灰度图像的连通分量形态属性过滤器而不是基于单独像素进行的。此外,基于AP的算法可以为分类器获取高质量的样本,这在样本有限的情况下作用非常大,最终将生成的结果图像堆叠起来称为扩展多元属性形态剖面(EMAP)。EMAP<sup>[6-8]</sup>可以对不同尺度级别连通区域的土地覆盖信息进行建模。因此,可以通过连续应用EMAP来创建图像的多尺度空间特征。这一特性使得AP成为高光谱数据获取空间特征的有效方式。当使用EMAP结合原始光谱数据作为网络输入特征时,输出在分类方面具有更好的性能<sup>[9-10]</sup>,因此在高光谱分类中结合EMAP和深度学习具有很大的应用前景<sup>[11-12]</sup>。AP因为它的灵活性常被用来进行数据增强,它可以处理具有各种属性和阈值的图像,这些属性剖面是基于不同连通分量的属性过滤器计算得到的。传统的阈值是通过人工经验给出的,目前对调整属性过滤器参数进行自动阈值获取的研究很少。2014年,Chen等<sup>[13]</sup>提出一种基于遗传算法的自动特征选择算法来调整属性过滤器中的阈值;2009年,Mura等<sup>[14]</sup>证明了使用两个属性(面积和标准差)自动获取阈值方法的有效性。基于此,本研究给出一种更简单有效的算法来获得属性阈值。

自动编码器(AE)<sup>[15-16]</sup>是处理分类相关任务中最主要的体系结构之一。最近用于HSI分类的AE研究大多选择原始光谱数据与处理过后的图像相融合,中心像素的空间信息由该区域内的所有像素表征,并

作为AE网络的输入学习空间-光谱特征<sup>[17-18]</sup>。由于HSI数据的维数很高,在对HSI进行属性过滤之前总会先降维<sup>[19]</sup>。并且原始光谱数据编码后的数据特征可以使分类的效果更好<sup>[9]</sup>。AE在HSI数据分类中的优越表现,促使其在与AP结合的同时探索更好性能的潜在可能性。在生成配置形态剖面时,选择属性过滤器的阈值是主要问题,然而对这一问题的研究相对较少<sup>[14-15,17]</sup>。

本文在选择属性过滤器的阈值构建区域AP后,使用AE进行HSI分类编码。所提方法首先通过选择基于不同属性生成AP的方式生成EMAP得到大量滤波图像,最大程度解析图像上临近分量的地理信息;其次,利用AE进行编码获得有效分类器,即通过将EMAP提取的联合特征与从AE学到的潜在特征相结合,带来更好的分类结果;最后,在两个著名的高光谱数据集上进行实验,来验证所提方法的分类效果。

## 2 自动阈值处理

高光谱分类的一般流程<sup>[20]</sup>如图1所示。该框架包含两个学习阶段:1)对原始高光谱数据使用主成分分析法(PCA)进行降维操作,然后基于不同属性值自动阈值处理操作选择的多个阈值分别对每个主成分(PC)进行AP操作。实验中采用面积和标准差这两个属性,最后得到可以表征HSI空间特征的EMAP。2)将获得的空谱特征数据与原始数据融合,得到空谱结合的特征,将其特征数据作为分类器的输入,经过分类器获得最终的分类结果图。

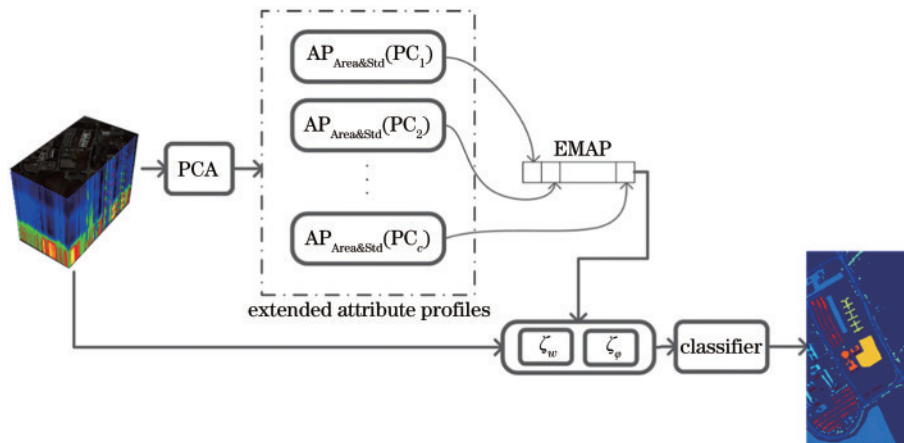


图1 高光谱分类的一般流程图

Fig. 1 General flow chart of hyperspectral classification

基于树结构构建AP是最常用的方法,主要包括4个步骤:1)建立树形结构;2)计算树结构中每个节点对应连通域的属性值;3)根据所选择的属性和阈值进行属性滤波;4)将过滤后的树形结构转换为图像。这就是图像重建的步骤。

为了在没有人工确定任何阈值的情况下过滤给定图像、合并最大空间信息,提出一种新的自动阈值方法

来构建光谱空间轮廓。基于自动阈值属性形态剖面的具体步骤如下:

1)建立叶节点属性函数(LAF)<sup>[21]</sup>。这个函数主要用于表示图像最大的深遍历树结构,记录所有节点的属性值从叶节点到根节点的路径并存储在列表中。假设有 $P$ 个节点从叶节点 $N_1$ 到根节点 $N_{root}$ ,LAF的建立过程可以表示为

$$\text{LAF}_{N_i}(i) = A(N_i), \quad i = 1, 2, \dots, P, \quad (1)$$

式中:  $N_i$  为从叶节点到根节点的所有节点;  $N_i$  为从叶节点到根节点路径上的第  $i$  个节点;  $A(N_i)$  表示该节点对应的属性值。

2) 根据 LAF 构造相应的梯度曲线 (GC) 和属性差曲线 (ADC)。GC 表征从叶节点到根节点的全局变化梯度, 所有节点  $N_i$  的 GC 可表示为

$$\text{GC}_{N_i}(i) = \left\{ \frac{\text{LAF}_{N_i}(i+1) - \text{LAF}_{N_i}(1)}{i} \right\}, \quad i = 1, 2, \dots, P-1. \quad (2)$$

ADC 表征从叶节点到根节点的局部变化梯度。所有叶节点  $N_i$  的 ADC 表示为

$$\text{ADC}_{N_i}(i) = \text{LAF}_{N_i}(i+1) - \text{LAF}_{N_i}(i), \quad i = 1, 2, \dots, P-1. \quad (3)$$

图 2(a) 是生成的 GC 和 ADC 构造图。从图 2 可以看出, GC 和 ADC 中都会有一个位置, 这两条曲线同时发生突变。这个位置对应的节点就是需要找到的阈值对应的节点。

3) 基于 GC 和 ADC 的构建, 能够检测相应树剪枝节点的最大适宜性曲线 (MSC)。通过获取 GC 和 ADC 的突变位置节点的方式来计算:

$$\text{MSC}_{N_i}(i) = \text{GC}_{N_i}(i) \cdot \text{ADC}_{N_i}(i), \quad i = 1, 2, \dots, P-1. \quad (4)$$

也就是说, 两条曲线弧是受到一个“和”操作找到使两条曲线在同一时间突变的节点的。图 2(b) 是根据 GC 曲线和 ADC 曲线得到的 MSC 样例图。

将式(2)和式(3)代入式(4)可得:

$$\text{MSC}_{N_i} = \left[ \frac{\text{LAF}_{N_i}(i+1) - \text{LAF}_{N_i}(1)}{i} \right] \cdot [\text{LAF}_{N_i}(i+1) - \text{LAF}_{N_i}(i)]. \quad (5)$$

4) 确定阈值, 可用图 2(c) 表示。每个叶节点都找

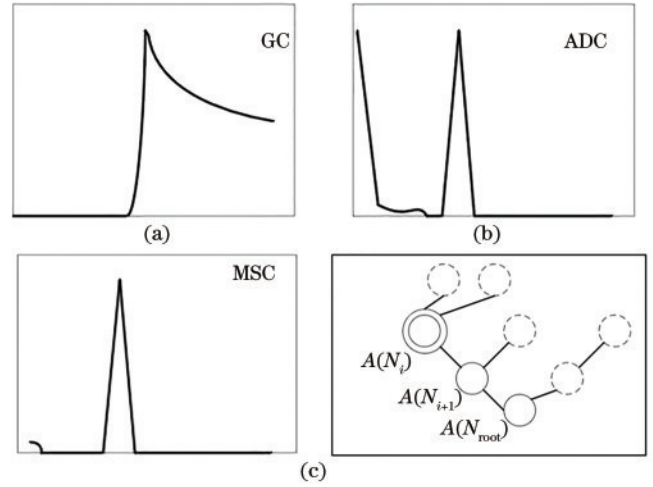


图 2 自动阈值属性配置文件构建。(a) GC 和 ADC 的构建; (b) MSC 的构建; (c) 树过滤

Fig. 2 Construction of automatic threshold attribute profiles. (a) Construction of GD and ADC; (b) construction of MSC; (c) tree filtering

到需要剪切的节点对应的属性值, 并记录它。遍历所有叶节点后, 统计路径上 MSC 全局最大值相关节点, 并将其属性值作为自动确定阈值。

这种使用 max-tree 在灰度图像上处理的无阈值属性过滤技术, 通过属性减薄操作过滤掉明亮的目标。因此, 通过所提自动阈值算法产生的过滤最大树, 来获得滤波后的图像。在获得的最大树上重复进行属性滤波操作, 最终生成一组滤波之后的图像数据。

其中, AP 是通过使用带有一系列属性滤波器 (AFs) 来实现的。给定一组  $L$  有序集合  $P_\lambda: \{P_\lambda\}, i = 1, \dots, L, \phi^{P_\lambda}$  和  $\gamma^{P_\lambda}$  分别表示属性的增厚和减薄操作。  $f$  的灰度图像的 AP 定义为

$$\text{AP}(f) = \left\{ \underbrace{\phi^{P_\lambda}(f), \phi^{P_{\lambda-1}}(f), \dots, \phi^{P_1}(f)}_{\text{thickening profile}}, f, \underbrace{\gamma^{P_\lambda}(f), \dots, \gamma^{P_{\lambda-1}}(f), \dots, \gamma^{P_1}(f)}_{\text{thinning profile}} \right\}. \quad (6)$$

由式(6)可以看出, AP 是增厚和减薄剖面的叠加。原始图像  $f$  既可以看作是增厚轮廓的零级, 也可以看作是减薄轮廓的零级。显然, 给定原始图像  $f$  作为输入, 经过属性过滤后, 有  $2L + 1$  个输出图像作为 AP。

为了将 AP 扩展到 HSI 空间信息提取领域, 扩展属性剖面 (EAP) 的概念被提出。EAP 是在 HSI 数据经过 PCA 降维后得到的  $m$  个 PC 堆叠在一起的集合。使用属性过滤后的 PC 来构造 EAP, 用  $g$  表示所有的 PC, 生成 EAP 的过程可以形式化为

$$\text{EAP}(g) = \{ \text{AP}(g_1), \text{AP}(g_2), \dots, \text{AP}(g_m) \}. \quad (7)$$

EAP 的生成过程如图 3 所示。当使用 2 个或更多的属性时, 可以得到 EMAP。假设选择了  $k$  个属性, EMAP 可以表示为

$$\text{EMAP}(g) = \{ \text{EAP}_{A_1}(g), \text{EAP}'_{A_2}(g), \dots, \text{EAP}'_{A_k}(g) \}, \quad (8)$$

式中:  $\text{EAP}_{A_i}$  为属性  $A_i$  计算出的一系列 AP。因为原始分量  $g_i$  被表征在每一个 EAP 中, 为了避免冗余, 则  $\text{EAP}' = \text{EAP} \setminus \{g_i\}_{i=1, \dots, m}$  为分量去除操作。

将获得的空谱特征数据通过训练的光谱角度映射堆叠式自动编码器 (S-SFMSAE) 网络来创建有效的分类器, 记 S-SFMSAE 模型总共有  $L$  个 S-SFMAE 结构。对于第  $l$  个 S-SFMAE, 令  $H^{(l)}(\mathbf{x}_i)$  为隐藏层的响应,  $I^{(l)}(\mathbf{x}_i)$  记为第  $l$  层的 S-SFMAE 的输入数据 ( $l = 1$  时,  $I^{(l)}(\mathbf{x}_i) = \mathbf{x}_i$ ), 等价于  $H^{(l-1)}(\mathbf{x}_i)$ ,  $\hat{H}^{(l)}(\mathbf{x}_i)$  为解码器对  $I^{(l)}(\mathbf{x}_i)$  的重建数据。使用以下目标函数训练第  $l$  个 S-SFMAE:




图 3 EAP 生成

Fig. 3 Generation of EAP

$$J(\mathbf{W}_E^{(l)}, \mathbf{b}_E^{(l)}, \mathbf{W}_D^{(l)}, \mathbf{b}_D^{(l)}) = \min [L(I^{(l)}, \hat{H}^{(l)}) + \lambda \Psi(I^{(l)}, \hat{H}^{(l)})], \quad (9)$$

式中： $\mathbf{W}_E^{(l)}$ 和 $\mathbf{b}_E^{(l)}$ 分别为在第 $l$ 个S-SFMAE中需要学习的编码器的映射矩阵和偏置矢量， $\mathbf{W}_E^{(l)} \in \mathbf{R}^{d^{(l)} \times d^{(l-1)}}$ ， $\mathbf{b}_E^{(l)} \in \mathbf{R}^{d^{(l)}}$ ； $\mathbf{W}_D^{(l)}$ 和 $\mathbf{b}_D^{(l)}$ 分别为在第 $l$ 个S-SFMAE中需要学习的解码器的映射矩阵和偏置矢量， $\mathbf{W}_D^{(l)} \in \mathbf{R}^{d^{(l-1)} \times d^{(l)}}$ ， $\mathbf{b}_D^{(l)} \in \mathbf{R}^{d^{(l-1)}}$ ； $\lambda$ 为权衡参数； $\Psi(\cdot)$ 为判别

正则化项。

式(9)中第1项表征的是输入数据与其对应的重构数据之间的重构成本,其计算公式为

$$L(I^{(l)}, \hat{H}^{(l)}) = \frac{1}{2} \sum_{i=1}^N \|I^{(l)}(\mathbf{x}_i) - \hat{H}^{(l)}(\mathbf{x}_i)\|^2 = \frac{1}{2} \sum_{i=1}^N \|H^{(l-1)}(\mathbf{x}_i) - f[\mathbf{W}_D^{(l)} H^{(l)}(\mathbf{x}_i) + \mathbf{b}_D^{(l)}]\|^2. \quad (10)$$

式(9)中第2项为判别正则化项,其表达式为

$$\Psi(I^{(l)}, \hat{H}^{(l)}) = \arccos \left[ \frac{\langle I^{(l)}(\mathbf{x}_i), \hat{H}^{(l)}(\mathbf{x}_i) \rangle}{\|I^{(l)}(\mathbf{x}_i)\| \times \|\hat{H}^{(l)}(\mathbf{x}_i)\|} \right] = \arccos \left\{ \frac{\sum_{j=1}^{d^{(l-1)}} I^{(l)}(\mathbf{x}_i)^j \cdot \hat{H}^{(l)}(\mathbf{x}_i)^j}{\left\{ \sum_{j=1}^{d^{(l-1)}} [I^{(l)}(\mathbf{x}_i)^j]^2 \right\}^{1/2} \times \left\{ \sum_{j=1}^{d^{(l-1)}} [\hat{H}^{(l)}(\mathbf{x}_i)^j]^2 \right\}^{1/2}} \right\}. \quad (11)$$

将式(10)、(11)代入式(9)中以获得S-SFMSAE的目标函数:

$$J(\mathbf{W}_E^{(l)}, \mathbf{b}_E^{(l)}, \mathbf{W}_D^{(l)}, \mathbf{b}_D^{(l)}) = \min \left\{ \frac{1}{2} \sum_{i=1}^N \|H^{(l-1)}(\mathbf{x}_i) - f[\mathbf{W}_D^{(l)} H^{(l)}(\mathbf{x}_i) + \mathbf{b}_D^{(l)}]\|^2, \right. \\ \left. + \lambda \arccos \left[ \langle I^{(l)}(\mathbf{x}_i), \hat{H}^{(l)}(\mathbf{x}_i) \rangle / \|I^{(l)}(\mathbf{x}_i)\| \times \|\hat{H}^{(l)}(\mathbf{x}_i)\| \right] \right\}. \quad (12)$$

### 3 实验结果及分析讨论

#### 3.1 数据集

通过两个高光谱数据集评估所提算法的性能。第1个数据集是Pavia University, 它的数据来自机载反射光学光谱成像仪在2003年对意大利的帕维亚城所成的像的一部分高光谱数据。该光谱成像仪对0.43~0.86 μm 波长范围内的115个波段连续成像, 所成图像的空间分辨率为1.3 m。其中, 12个波段由于受噪声影响被剔除。该数据的尺寸为610 pixel × 340 pixel, 共包含2207400个像素。其中包含大量的背景像素, 包含地物的像素共有42776个, 该数据集选择了9个土地覆盖类别, 包括树、沥青道路、砖块、牧场等。图4显示了其伪彩色图像和真实情况图。




图 4 Pavia University 数据集图像数据

Fig. 4 Image data of Pavia University dataset

Salinas 是实验中用于 HSI 分类的第 2 个高光谱数据集。Salinas 数据是由机载可见红外成像光谱仪 (AVIRIS) 拍摄的, AVIRIS 成像波长范围为  $0.4 \sim 2.5 \mu\text{m}$ 。它是对美国加利福尼亚州的 Salinas 山谷所成的像, 空间分辨率达到  $3.7 \text{ m}$ 。该图像原本有 224 个波段, 一般使用的是剔除了第 108~112、154~167 和第 224 个不能被水反射的波段后剩下的 204 个波段的图像。该图像的尺寸为  $512 \text{ pixel} \times 217 \text{ pixel}$ , 共包含 111104 个像素, 其中有 56975 个像素是背景像素, 可应用于分类的像素有 54129 个, 这些像素共分为 16 个代表性类别, 包括野草 (weeds)、休耕地 (fallow)、谷物 (corn)、葡萄园 (vinyard) 等。图 5 显示了其伪彩色图像和真实情况图。

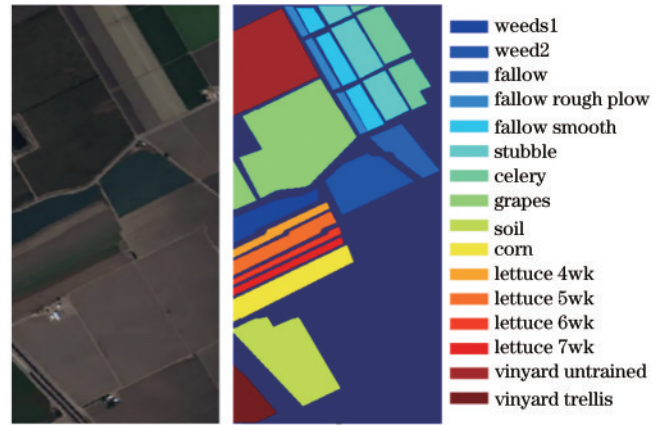


图 5 Salinas 数据集图像数据

Fig. 5 Image data of Salinas dataset

### 3.2 实验结果与分析

为了实现  $n$  波段 HSI 的分类, 将频谱尺寸从  $n$  减小到  $r$  ( $r \ll n$ )。在多种降维技术中, 首先选择 PCA 进行降维, 保留约 99% 的数据集总方差的主成分信息, 其次为每个 PC 构造树结构, 通过自动阈值方法确定阈值, 如表 1 所示。选择面积和标准差作为属性, 基于某个属性具有的  $L$  个阈值应用于  $r$  个 PC 中, 基于某个属性可以获得  $c[(2 \times L + 1) \times r]$  个 AP, 最终基于不同属性获取的 EMAP 融合原始数据作为下一阶段分类器训练的输入数据。

图 6 为使用人工阈值<sup>[22]</sup>和所提自动阈值方法在

Pavia University 数据集的第 1 个 PC 上使用面积属性进行滤波操作所获得的滤波图像。其中, 图 6(a)、(b)、(c) 分别表示使用人工阈值方法进行第 1 次、第 2 次、第 3 次操作所获得的滤波图像, 图 6(e)、(f)、(g) 分别表示使用自动阈值方法进行第 1 次、第 2 次、第 3 次操作所获得的滤波图像, 图 6(d) 表示在对原图进行 PCA 降维之后的第 1 个 PC。通过图 6 可以看出, 所提自动阈值方法可以表征绝大部分信息。通过对经过 PCA 处理的 HSI 的每一个 PC 进行最大树和最小树操作, 可以有效提取和增强数据中的信息, 如图 6 所示。

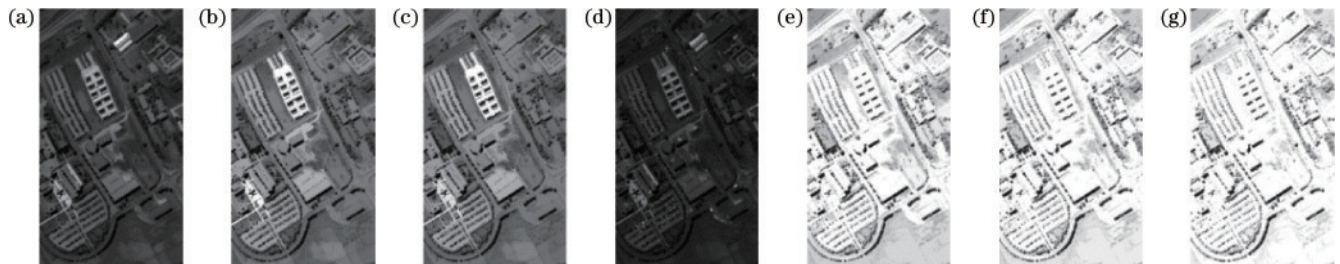


图 6 过滤图像。(a)第 3 次滤波;(b)第 2 次滤波;(c)第 1 次滤波;(d)第 1 个 PC;(e)第 1 次滤波;(f)第 2 次滤波;(g)第 3 次滤波

Fig. 6 Filtered images. (a) Third filtering; (b) second filtering; (c) first filtering; (d) first PC; (e) first filtering; (f) second filtering; (g) third filtering

表 1 为 Pavia University 和 Salinas 这 2 个数据集的属性和阈值。将所有可用的标记集随机分为 5:2:3 的训练集、验证集和测试集。通过实验分析网络的表现并获得隐藏神经元的最佳参数。对于每个数据集和每种特征, 将 S-SFMSAE 的隐藏层数设置为 2 (即  $L=2$ )。此外, 将第 1 个隐藏层中的神经元数量设置为原始输入特征尺寸的 50% 左右。由于 Pavia University

表 1 属性和阈值

Table 1 Attribute and threshold

Dataset	Pavia University	Salinas
Area	55879, 93720, 131561, 169402	24174, 45732, 67290, 88848
Standard deviation	14, 26, 39, 52	12, 22, 32, 42

和 Salinas 这 2 个数据集的光谱空间特征维数分别为 171 和 255, 则将 Pavia University 第 1 个隐藏层中的神经元数量设置为 100, Salinas 设置为 140。2 个数据集上第 2 个隐藏层中神经元的数量分别设置为  $\{40, 60, 80, 100\}$ 。预训练和微调周期都设置为 1000, 批大小选择 128, 学习率设置为 0.05。为了优化权重参数  $\lambda$ , 将其值设置为  $\{0.001, 0.01, 0.1\}$ 。在 2 个广泛使用的 HSI 分类数据集上, 通过改变第 2 个隐藏层中不同神经元的数量和不同的权重参数进行训练以获得最佳参数, 如表 2 所示。

为了定量评估所提 S-SFMSAE 模型的有效性, 将所提方法与一些最新的 HSI 分类方法进行比较, 以验证所提结合空间特征和光谱特征方法的有效性。最新

表 2 不同数据集的参数设置

Table 2 Parameter settings of different datasets

Dataset	$\lambda$	Number of hidden layer neurons	S-SFMSAE structure
Pavia University	0.1	80	171-100-80-9
Salinas	0.001	80	255-120-80-16

的 HSI 分类方法有紧凑型 and 判别堆叠式自动编码器 (CDASAE)、局部二进制模式-极限学习机 (LBP-ELM)、卷积神经网络 (CNN)、支持向量机-随机特征选择 (SVM-RFS) 以及卷积神经网络-像素对特征 (CNN-PPF) 方法。其中, CDASAE<sup>[23]</sup> 在自编码器结构中每个隐藏层增加局部判别正则化和正则化多样性约束, 以平衡特征维数和特征表示能力。LBP-ELM<sup>[24]</sup> 使用局部二值模式 (LBP) 提取图像的局部特征, 如边缘、角和斑点, 并使用 ELM 分类器对提取的特征进行分类。SVM-RFS<sup>[25]</sup> 使用基于随机特征选择的支持向量机来实现 HSI 分类。CNN<sup>[26]</sup> 直接提取高光光谱数据的光谱信息来实现分类。CNN-PPF<sup>[27]</sup> 使用 CNN 学习 HSI 的像素对特征 (PPF), 其中 PPF 是根据像素及其邻近像素的特征信息来获取的。

表 3、表 4 记录了 2 种数据集在所提方法与最新 HSI 分类方法结果之间的比较。从表 3 和表 4 可以看出, 所提方法在总体精度 (OA)、平均精度 (AA) 和 Kappa 系数这 3 个评估标准上均取得了最佳结果, 也就是说, 所提模型可以有效地改善 HSI 的分类准确性。这进一步证实了所提方法的有效性和优越性。

表 3 Pavia University 上的各种方法对比

Table 3 Comparison of various methods on Pavia University

Dataset	S-SFM SAE	CDA SAE	SVM-RFS	1-D CNN	CNN-PPF	LBP-ELM
OA	99.28	97.59	97.59	91.10	92.27	96.48
AA	99.01	97.66	92.92	93.30	96.98	91.81
Kappa	99.05	96.86	96.90	88.53	89.89	95.48

表 4 Salinas 上的各种方法对比

Table 4 Comparison of various methods on Salinas

Dataset	S-SFM SAE	CDA SAE	SVM-RFS	1-D CNN	CNN-PPF	LBP-ELM
OA	98.32	96.07	93.15	89.28	94.80	92.42
AA	98.91	97.56	96.87	94.83	97.73	96.31
Kappa	98.13	96.78	92.35	88.13	94.17	91.55

为了更直观地显示不同特征类别上各种方法的分类, 给出针对 Pavia University 数据集比较的 6 种方法中每种方法的分类准确性折线图, 如图 7 所示。每个类别准确度的准确度值以百分比显示。从直方图可以看出: 所提 S-SFMSAE 模型的分分类效果在第 1 类 (柏油路) 和第 5 类 (金属板) 的分类精度上稍逊于 CDASAE; 但其余 7 个类别的分类精度, 所提方法均达到了最好的分类精度; 在第 3 类 (碎石) 的分类精度上,

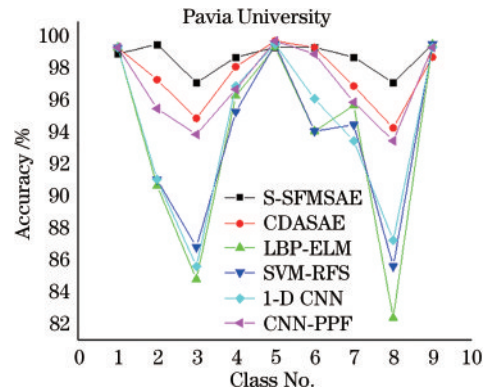


图 7 Pavia University 数据集用不同方法在 9 种类别的准确性比较结果

Fig. 7 Accuracy comparison results of different methods on 9 categories for Pavia University dataset

S-SFMSAE > SVM-RFS > CNN > LBP-ELM; 在第 8 类 (砖块) 的分类精度上, S-SFMSAE > CNN > SVM-RFS > LBP-ELM。所提方法远高于其他 3 种 HSI 分类方法, 这与评价指标显示出来的结果基本一致。

图 8 显示了针对 Salinas 数据集进行比较的 6 种方法的每个类别的分类准确性折线图。在图 8 中, 横坐标代表不同的特征类别编号, Salinas 数据集共有 16 个要素类别。纵坐标表示每个类别的分类精度, 精度值以百分比显示。从直方图可以看出, 在第 8 类 (无果葡萄) 和第 15 类 (无果葡萄) 分类精度上, 所提 S-SFMSAE 模型的分分类精度得到了明显改善, 但其余 13 个类别的分类准确性与其他模型相似。

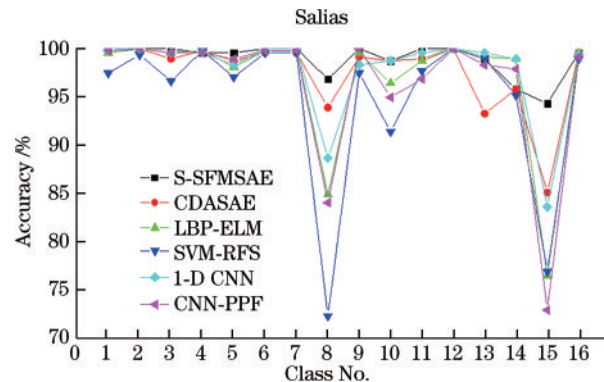


图 8 Salinas 数据集用不同方法在 16 种类别的准确性比较结果

所提 HSI 分类方法是基于空谱和光谱这 2 个维度进行的分析实验, 在 CDASAE 方法的基础上优化自编码器的正则约束项, 提升其分类效果。由于目前高光

谱数据集获取困难以及样本量少等原因,用添加空谱空间特征处理的方法提取图像的深层次空间信息、增大样本量。与 CNN-PPF 方法相比,其空谱特征的提取采用自动阈值处理方法获取图像的 AP,采用此种方法提取的空谱信息更丰富,具有更广泛的适用性。

## 4 结 论

针对 HSI 分类中类内多样性和类间相似性的问题,提出一种有效的 HSI 分类模型——自动阈值属性光谱空间联合特征编码模型。该方法包括 2 个逐步优化的学习阶段:一是空间特征提取,二是光谱特征学习和 HSI 分类器的训练。在 2 个广泛使用的 HSI 数据集上进行实验并与其他 4 方法进行比较,该方法在 OA、AA 和 Kappa 系数这 3 个评价指标上都取得了最优结果,其中, Pavia University 数据集在 OA 指标上达到 99.28% 的分类效果,证明空谱特征和光谱特征相结合的高光谱分类方法具有显著的分类效果。与人工阈值相比,所提自动阈值处理方法仍有不足之处,如何进一步提高自动阈值的处理精度是将来需要进一步研究的内容。本研究可以应用于其他更广泛的高光谱数据集,以提高模型的泛化能力。

## 参 考 文 献

- [1] Majozi N P, Salama M S, Bernard S, et al. Remote sensing of euphotic depth in shallow tropical inland waters of Lake Naivasha using MERIS data[J]. *Remote Sensing of Environment*, 2014, 148: 178-189.
- [2] 李非燕, 霍宏涛, 李静, 等. 基于多特征和改进稀疏表示的高光谱图像分类[J]. *光学学报*, 2019, 39(5): 0528004. Li F Y, Huo H T, Li J, et al. Hyperspectral image classification via multiple-feature-based improved sparse representation[J]. *Acta Optica Sinica*, 2019, 39(5): 0528004.
- [3] 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. 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.
- [4] 侯榜煊, 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. 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.
- [5] 王立国, 赵春晖. 高光谱图像处理技术[M]. 北京: 国防工业出版社, 2013. Wang L G, Zhao C H. *Processing techniques of hyperspectral imagery*[M]. Beijing: National Defense Industry Press, 2013.
- [6] Dalla Mura M, Benediktsson J A, Waske B, et al. Morphological attribute profiles for the analysis of very high resolution images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2010, 48(10): 3747-3762.
- [7] 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.
- [8] Dalla Mura M, Atli Benediktsson J, Waske B, et al. Extended profiles with morphological attribute filters for the analysis of hyperspectral data[J]. *International Journal of Remote Sensing*, 2010, 31(22): 5975-5991.
- [9] Cavallaro G, Falco N, Dalla Mura M, et al. Automatic attribute profiles[J]. *IEEE Transactions on Image Processing*, 2017, 26(4): 1859-1872.
- [10] Aptoula E, Ozdemir M C, Yanikoglu B. Deep learning with attribute profiles for hyperspectral image classification [J]. *IEEE Geoscience and Remote Sensing Letters*, 2016, 13(12): 1970-1974.
- [11] Wang L B, Zhen H, Fang X Y, et al. A unified two-parallel-branch deep neural network for joint gland contour and segmentation learning[J]. *Future Generation Computer Systems*, 2019, 100: 316-324.
- [12] Kim R, Kim G, Kim H, et al. A method for optimizing deep learning object detection in edge computing[C]// 2020 International Conference on Information and Communication Technology Convergence (ICTC), October 21-23, 2020, Jeju, Korea (South). New York: IEEE Press, 2020: 1164-1167.
- [13] Chen Y S, Lin Z H, Zhao X, et al. Deep learning-based classification of hyperspectral data[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(6): 2094-2107.
- [14] Mura M D, Benediktsson J A, Bruzzone L. Modeling structural information for building extraction with morphological attribute filters[J]. *Proceedings of SPIE*, 2009, 7477: 747703.
- [15] Zhang X R, Liang Y J, Li C, et al. Recursive autoencoders-based unsupervised feature learning for hyperspectral image classification[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(11): 1928-1932.
- [16] Geng J, Wang H Y, Fan J C, et al. Change detection of SAR images based on supervised contractive autoencoders and fuzzy clustering[C]// 2017 International Workshop on Remote Sensing with Intelligent Processing (RSIP), May 18-21, 2017, Shanghai, China. New York: IEEE Press, 2017.
- [17] Vincent P, Larochelle H, Lajoie I, et al. Stacked denoising autoencoders: learning useful representations in a deep network with a local denoising criterion[J]. *Journal of Machine Learning Research*, 2010, 11: 3371-3408.
- [18] Lin Z H, Chen Y S, Zhao X, et al. Spectral-spatial classification of hyperspectral image using autoencoders [C]// 2013 9th International Conference on Information, Communications & Signal Processing, December 10-13, 2013, Tainan. New York: IEEE Press, 2013.
- [19] Sun X, Zhou F, Dong J Y, et al. Encoding spectral and spatial context information for hyperspectral image classification[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(12): 2250-2254.

- [20] Ghamisi P, Benediktsson J A, Sveinsson J R. Automatic spectral-spatial classification framework based on attribute profiles and supervised feature extraction[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(9): 5771-5782.
- [21] Bhardwaj K, Patra S, Bruzzone L. Threshold-free attribute profile for classification of hyperspectral images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(10): 7731-7742.
- [22] Cavallaro G, Dalla Mura M, Benediktsson J A, et al. Extended self-dual attribute profiles for the classification of hyperspectral images[J]. *IEEE Geoscience and Remote Sensing Letters*, 2015, 12(8): 1690-1694.
- [23] Zhou P C, Han J W, Cheng G, et al. Learning compact and discriminative stacked autoencoder for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(7): 4823-4833.
- [24] Li W, Chen C, Su H J, et al. Local binary patterns and extreme learning machine for hyperspectral imagery classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(7): 3681-3693.
- [25] Waske B, van der Linden S, Benediktsson J A, et al. Sensitivity of support vector machines to random feature selection in classification of hyperspectral data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2010, 48(7): 2880-2889.
- [26] Hu W, Huang Y Y, Wei L, et al. Deep convolutional neural networks for hyperspectral image classification[J]. *Journal of Sensors*, 2015, 2015: 258619.
- [27] Jiao L C, Liang M M, Chen H, et al. Deep fully convolutional network-based spatial distribution prediction for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(10): 5585-5599.