

基于分层稀疏表示特征学习的高光谱图像分类研究

李 铁¹ 孙劲光¹ 张新君² 王 星¹

¹辽宁工程技术大学电子与信息工程学院, 辽宁 葫芦岛 125105

²大连理工大学计算机科学与技术学院, 辽宁 大连 116024

摘要 提出一种基于分层稀疏表示特征学习的方法即分层判别特征学习算法对高光谱图像进行分类,在两层的分层结构中用空间金字塔匹配模型在每层的稀疏编码上用最大池化方法学习得到判别特征,用分层判别特征学习得到的特征表示对于分类更稳健、判别性更好。在两个高光谱数据集上评价该方法,结果表明,该方法具有更好的分类精度。

关键词 遥感; 高光谱图像分类; 特征学习; 稀疏表示

中图分类号 TP751 文献标识码 A

doi: 10.3788/LOP53.091001

Research of Hyperspectral Image Classification Based on Hierarchical Sparse Representation Feature Learning

Li Tie¹ Sun Jinguang¹ Zhang Xinjun² Wang Xing¹

¹School of Electronic and Information Engineering, Liaoning Technical University, Huludao, Liaoning 125105, China

²School of Computer Science and Technology, Dalian University of Technology, Dalian, Liaoning 116024, China

Abstract A method of classification based on hierarchical sparse representation feature learning as hierarchical discriminative feature learning algorithm is developed for hyperspectral image classification. The spatial-pyramid-matching model is used, and the sparse codes learned from the discriminative features are obtained by max pooling in each layer of the two-layer hierarchical structure. The representation of features achieved by the proposed method are more robust and discriminative for the classification. The proposed method is evaluated on two hyperspectral datasets, and the results show that the proposed method has good classification accuracy.

Key words remote sensing; hyperspectral image classification; feature learning; sparse representation

OCIS codes 100.4145; 100.3008; 100.5010; 110.4234

1 引 言

高光谱传感器的发展取得了显著的进步,带来了农业监控、环境污染监测和目标检测方面的革命^[1-2]。利用高光谱图像进行土地覆盖分类是各种应用中一个重要的任务。然而高光谱数据的复杂特性给高光谱图像分类的准确性带来挑战。大量的光谱波段与相应的光谱信息给高光谱图像分类带来了冗余和噪声。因此原始特征不适合直接用来作高光谱图像分类。为了找到高光谱图像分类更有效的特征,现已提出很多特征提取方法^[3-7]用来提取既简洁又有判别性的特征。Song等^[8]提出一种新的基于三维滤波器特征提取方法,即挖掘高光谱图像的特定方向、尺度和波长相关的属性保留高光谱图像的三维结构。用该方法得到新的特征,证明了简洁有效性。Pan等^[9]提出三维灰度级同现特征提取方法,它是灰度级同现矩阵派生方法,能得到真实的高光谱图像的三维纹理特征。

除了早期的特征提取方法之外,稀疏表示(SR)作为一种特征学习方法已经成功用于解决计算机视觉中的各种问题,例如人脸识别、行为识别、高光谱图像分类等^[10]。稀疏表示的理论证明池化运算可以通过线性

收稿日期: 2016-04-20; 收到修改稿日期: 2016-05-17; 网络出版日期: 2016-08-29

基金项目: 国家自然科学基金(61402212)、国家科技支撑计划(2013BAH12F00)

作者简介: 李 铁(1978—),男,博士,讲师,主要从事遥感影像、模式识别方面的研究。E-mail: lthero@163.com

组合方式以最小重建误差的方式重建输入信号,且得到的编码是稀疏的。为了扩展 SR 到实际应用中如非线性的情况,一些研究者提出核稀疏表示(KSR)^[11],即将特征映射到一个高维空间,在高维空间中不同的类别变得线性可分,提高了分类的性能。

空间金字塔匹配模型(SPM)^[12]已引起很多学者的研究兴趣。这个模型从小的图像块到整个图像结合 SPM 逐层运行来提取特征。利用该模型可以对高光谱图像的结构和纹理信息进行深入挖掘。作为 SPM 的变体之一,分层模型已经成为图像分类的流行方法^[13]。Zhou 等^[14]提出了一种基于分层稀疏编码的方法,取得了与传统稀疏编码的单层结构相似的性能结果。Kang 等^[15]提出了分层匹配追踪架构(HMP),包括三个模块分别为批处理(树型)正交匹配追踪(OMP)、空间金字塔最大池化、对比度归一化。实验表明对于完整尺寸的图像分类,分层稀疏编码的方法明显优于传统的稀疏编码方法。在三种类型的图像分类问题即目标识别、场景识别、静态事件识别中,HMP 始终取得较高的精度。

但是 HMP 模型是在无监督的方式下学习特征,没有考虑有监督的信息,该信息能使特征学习方法更准确。本文引入分层判别特征学习的方法使用标签信息来提高高光谱图像的分类性能。该特征学习算法基于两层稀疏模型,而且在分类阶段空间信息有助于学习到更稳健的特征子集。在第一层挖掘空间信息,对每个像素建立以原始像素为中心的空间邻域块。同时为了得到更有判别性的特征,采用判别字典学习算法,类标一致性 K-SVD 方法得到每个图像块的稀疏编码,对这些稀疏编码用空间金字塔最大池化来得到第一层特征。在第二层中将第一层的特征作为输入数据的表示,重复和第一层类似的算法步骤。最后将两个层得到的特征连在一起得到最终的特征表示。

2 分层判别特征学习算法

2.1 类标一致性 K-SVD

作为稀疏表示中最流行的过完备字典学习方法之一,K 奇异值分解(K-SVD)被广泛地应用到很多应用中。然而字典原子的标签信息在学习过程中没有被使用。为了解决这个问题,Jiang 等将标签一致性的约束与 K-SVD 相结合,使学习得到的字典更有判别性。在分层特征学习算法中使用类标一致性 K-SVD 来学习判别字典。

K-SVD 是一种迭代算法,一般用于稀疏表示问题中的字典训练方面。这里的字典是一个过完备的矩阵,将一个信号向量表示成字典中原子(字典的列向量)的稀疏线性组合。主要包含两个步骤:1)稀疏编码;2)字典更新。在 K-SVD 中,稀疏编码可以采用最大池化方法,而字典更新采用奇异值分解。

给定一幅包含 C 类地物的高光谱遥感图像数据,每个像素即样本用光谱特征向量表示,样本的特征维数为 h ,所有样本构成样本集 $\mathbf{Y} = \{\mathbf{y}_i\}_{i=1}^N \in \mathbf{R}^{h \times N}$,其中 \mathbf{y}_i 为第 i 个样本, N 为样本总个数, \mathbf{R} 表示实数域。为了得到判别稀疏编码,类标一致性 K-SVD 首先训练一个包含 K_1 个原子的过完备字典 \mathbf{D} ,原子有一部分从高光谱图像的训练集 $\mathbf{Y}_{\text{train}}$ 中用同时最小化重建误差和判别稀疏编码误差来选择。

基于训练集 $\mathbf{Y}_{\text{train}}$,判别 K-SVD 字典学习方法的目标函数为

$$\arg \min_{\mathbf{D}, \mathbf{W}, \mathbf{A}, \mathbf{X}} \|\mathbf{Y}_{\text{train}} - \mathbf{D}\mathbf{X}\|_2^2 + \alpha \|\mathbf{Q} - \mathbf{A}\mathbf{X}\|_2^2 + \beta \|\mathbf{H} - \mathbf{W}\mathbf{X}\|_2^2, \text{ s.t. } \forall i, \|\mathbf{x}_i\|_0 \leq T, \quad (1)$$

式中第一项为重构误差项,第二项为判别稀疏编码约束项,第三项为分类误差项, $\mathbf{Y}_{\text{train}} \in \mathbf{R}^{h \times n_1}$ 表示训练集, n_1 表示训练集样本数目, \mathbf{D} 表示判别字典,包含 K_1 个字典原子,每个原子维数为 d , \mathbf{W} 表示分类变换矩阵, \mathbf{A} 表示线性变换矩阵, \mathbf{X} 表示稀疏编码系数矩阵, $\|\cdot\|_2^2$ 表示 l_2 范数的平方和, α 和 β 表示平衡类标判别项和分类误差项的正则参数,取值范围是 $1 \sim 5$, $\mathbf{Q} \in \mathbf{R}^{K_1 \times n_1}$ 表示理想状况下的判别稀疏编码系数矩阵,若 \mathbf{D} 中第 k 个字典原子与训练样本集 $\mathbf{Y}_{\text{train}}$ 中第 i 个样本属于同一类时,则 $Q_{ki} = 1$,不同类时为 0 , $\mathbf{H} \in \mathbf{R}^{C \times n_1}$ 表示训练样本的类标矩阵,若 $\mathbf{Y}_{\text{train}}$ 中第 i 个样本属于第 c ($c = 1, 2, \dots, C$) 类, $H_{ci} = 1$,否则为 0 , \mathbf{x}_i 表示稀疏编码系数矩阵 \mathbf{X} 的第 i 类向量, $\|\cdot\|_0$ 表示 l_0 范数, T 表示稀疏度阈值。

为了求解判别 K-SVD 字典学习方法的目标函数,将(1)式改写为

$$\arg \min \{ \|\mathbf{Y}_{\text{new}} - \mathbf{D}_{\text{new}}\mathbf{X}\|_2^2 \}, \text{ s.t. } \forall i, \|\mathbf{x}_i\|_0 \leq T, \quad (2)$$

式中 $\mathbf{Y}_{\text{new}} = (\mathbf{Y}_{\text{train}}^T, \sqrt{\alpha}\mathbf{Q}^T, \sqrt{\beta}\mathbf{H}^T)^T$, $\mathbf{D}_{\text{new}} = (\mathbf{D}^T, \sqrt{\alpha}\mathbf{A}^T, \sqrt{\beta}\mathbf{W}^T)^T$, $(\cdot)^T$ 表示矩阵的转置,对该目标函数利用 K-

SVD 字典学习方法进行求解,从而得到判别字典 D 。

2.2 空间金字塔最大池化

近年来空间金字塔最大池化算法已经成为一个流行的学习有效图像特征表示的模型。它共包含两部分:1)空间金字塔模型;2)最大池化算法。空间金字塔模型在不同的层上 $l=1,2,\dots,L$ 把一个像素块分成 $2^{l-1} \times 2^{l-1}$ 子块。在第一层上,块的表示是基于整个图像块的。在第二层,整个图像块分成 4 个金字塔块。在金字塔的第 l 层,整个图像块包含 4^{l-1} 个子块。

最大池化方法在一个图像子块区域内通过计算编码的最大值来得到有效的特征。基于空间金字塔模型,空间金字塔最大池化是在一个块内的像素稀疏编码上作最大池化。因为这些像素是空间相邻的。

假设 L 是金字塔的层数, V_l 是第 l 层金字塔空间块的数量,基于空间金字塔最大池化的像素块 P 的特征表示为

$$S(P) = [M(P_1^1), \dots, M(P_{V_1}^1), \dots, M(P_1^L), \dots, M(P_{V_L}^L)], \quad (3)$$

式中 P_j^l 表示第 l 层金字塔的第 j 个子块, P_j^l 的最大池化特征可以表示为

$$M(P_j^l) = [\max_{i \in P_j^l} |x_{i1}|, \dots, \max_{i \in P_j^l} |x_{in}|], \quad (4)$$

式中 n 表示学习的稀疏编码的维度。

2.3 分层判别特征学习算法

受 SPM 和 HMP 在目标识别、场景识别、静态事件识别成功的启发,提出了分层判别特征学习方法用于高光谱图像分类。普通图像分类与高光谱图像分类之间的区别在于前者是对于每个图像得到一个特征表示,而后者是对于高光谱图像的每个像素得到一个有效的特征表示。而且在空间块内的像素可以认为在亮度和纹理上有相似的特征,后面的处理是基于空间邻域块的。所提出的分层判别特征学习方法的架构如图 1 所示,图中的每个黑点表示块中的一个稀疏编码向量。

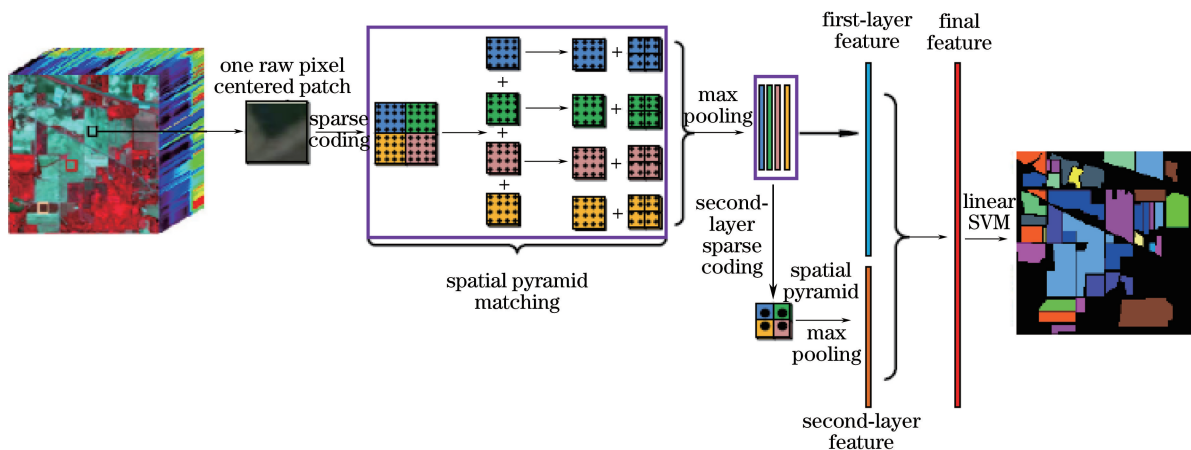


图 1 分层特征学习方法的架构

Fig. 1 Framework of the hierarchical feature learning method

首先高光谱图像中每个像素第一层稀疏编码通过 OMP 结合学到的字典 D_1 通过类标一致性字典学习算法来得到。

$$\min_{x_i} \|y_i - D_1 x_i\|_2^2, \text{ s.t. } \|x_i\|_0 \leq T_0, i = 1, 2, \dots, N. \quad (5)$$

后续的过程在基于邻域块 Z_i ($i = 1, 2, \dots, N$) 的第一层稀疏编码上运行,邻域块的大小为 $(2m+1) \times (2m+1)$,其中 m 是每个块的大小。

对每个块 Z_i 提取 4 个 $(m+1) \times (m+1)$ 子块,分别为 $Z_i^{(1)}, Z_i^{(2)}, Z_i^{(3)}, Z_i^{(4)}$ 步长为 m ,遍历的顺序为从上到下,从左到右。在提取的 4 个子块上作空间金字塔最大池化来得到子块的池化特征,然后串联在一起形成 Z_i 的第一层特征 \hat{F}_i 。在空间金字塔模型中采用两层的金字塔 ($L=2$), \hat{F}_i 是 $[4 \times (1+4)] \times K_1$ 维向量。表示为

$$\hat{F}_i = \{S[Z_i^{(1)}], S[Z_i^{(2)}], S[Z_i^{(3)}], S[Z_i^{(4)}]\}, \quad (6)$$

式中 $S[Z_i^{(j)}]$, $j = 1, 2, 3, 4$ 表示子块 $Z_i^{(j)}$ ($j = 1, 2, 3, 4$) 的池化特征。在第一层得到的池化特征 $S[Z_i^{(j)}]$,

$j=1,2,3,4$ 用来学习第二层的字典 D_2 。

在第二层中学到的特征 \hat{F}_i 上再作类标一致性 K-SVD 和空间金字塔最大池化。第二层空间编码的大小为 K_2 , 第二层稀疏编码的过程与第一层相同。最后第二层特征 \hat{F}_i 与第一层的特征 \hat{F}_i 串联在一起形成最后的表示特征

$$F_i = [\hat{F}_i, \hat{F}_i], \quad 1 \leq i \leq N. \quad (7)$$

2.4 算法复杂度

根据训练样本的数量来分析分层判别学习算法的计算复杂度。假设有 N 个训练样本, 训练数据集的维度是 R^d 。类标一致性 K-SVD 方法的计算复杂度为 $O(d^2 N)$ 。然后用空间金字塔最大池化算法提取空间特征, 单层计算的计算复杂度为 $O(d^2 N^3)$ 。两层架构的完整的复杂度为 $O(d^2 N^3) \times T$, 其中 T 是迭代次数。最后用支持向量机的方法来分类输入样本的特征, 计算复杂度为 $O(d^2 N^2)$ 。一般来说需要花费更长的时间运行本文方法来分类高光谱图像, 但是在特征提取方面该方法比传统的方法更准确、更有效。

采用两层判别字典学习和空间金字塔最大池化而不使用单层, 是因为第一层特征学习的目的是挖掘高光谱数据的光谱与空间信息, 第二层特征学习的目的是挖掘高光谱数据的纹理信息。结合两层的特征在理论上能提高分类精度。如果层数继续增加, 有可能会引入 Hughes 现象, 造成精度提高不明显或精度下降, 而且层数增多会带来计算时间和计算量的大大增加。因此综合考虑精度与计算复杂度的关系采用两层的结构。

有了学习到的特征, 采用线性支持向量机(SVM)作为分类器完成高光谱图像的分类。

3 实验

在实验中使用两个高光谱数据集来证明本文方法的有效性。

第一个数据集是印第安松林数据集, 由 NASA 机载可见光/红外成像光谱仪(AVIRIS)传感器于 1992 年获得。包含 220 个光谱波段, 10 nm 宽度从 $0.4 \mu\text{m}$ 到 $2.45 \mu\text{m}$, 包含 16 个不同的地物类别, $145 \text{ pixel} \times 145 \text{ pixel}$, 空间分辨率为 20 m。去除受大气和水吸收影响的波段, 在实验中使用 200 个波段。印第安松林高光谱数据集如图 2 所示。

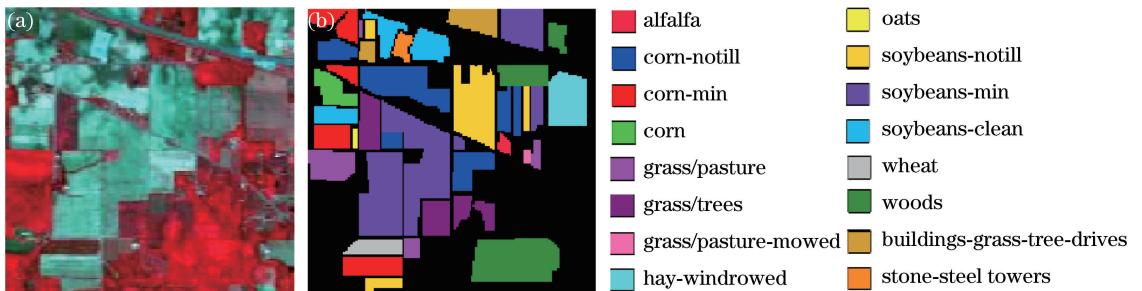


图 2 印第安松林高光谱数据集。(a) 原始图像; (b) 真实地物信息图

Fig. 2 Indian pines hyperspectral dataset. (a) Original image; (b) ground truth map

第二个数据集是由反射光学系统成像光谱仪(ROSIS)获取帕维亚大学数据集。包含 9 类地物, $610 \text{ pixel} \times 340 \text{ pixel}$, 空间分辨率为 1.3 m, 原始图像由 115 个光谱波段组成。去除 12 个受大气和水分吸收影响的波段, 在实验中使用 103 个波段的数据。帕维亚大学高光谱数据集如图 3 所示。

4 结果

4.1 比较与分析

第一个数据集邻域块的大小为 7×7 , 然后在第一层把每个块分解成 4×4 的子块。对每个数据集每类随机选取 10% 的样本作训练, 其余的作测试。表 1 和表 2 中分别给出了训练样本和测试样本的数量。实验 50 次取平均值作为最后的结果。



图3 帕维亚大学高光谱数据集。(a) 原始图像；(b) 真实地物信息图

Fig. 3 Pavia university hyperspectral dataset. (a) Original image; (b) ground truth map

表1 印第安松林图像训练样本和测试样本数及不同方法的分类精度

Table 1 Number of train and test sample of the Indian pines image and classification accuracy for different methods

Class name	Train	Test	SVM	SR	KSR	SOMP	SCSPM	Proposed method
Alfalfa	4	42	71.84	28.26	26.09	83.67	43.48	57.14
Corn-notill	142	1286	82.52	61.48	59.94	96.13	90.97	97.28
Corn-min	83	747	66.86	58.07	49.16	91.48	92.65	98.26
Corn	23	214	60.81	44.73	38.82	92.42	88.19	98.13
Grass/pasture	48	435	94.17	86.34	85.51	93.30	96.48	96.78
Grass/trees	73	657	96.54	92.05	92.60	98.37	99.18	99.24
Grass/pasture-mowed	2	26	49.58	75.00	64.29	50.00	32.14	84.62
Hay-windrowed	47	431	98.59	99.16	96.23	99.55	99.37	100
Oats	2	18	56.11	25.00	25.00	22.22	40.00	77.78
Soybeans-notill	97	875	66.36	71.19	51.95	87.39	90.84	93.26
Soybeans-min	245	2210	84.27	78.86	80.45	97.61	97.43	98.33
Soybeans-clean	59	534	74.95	46.54	44.18	89.51	84.32	93.63
Wheat	20	185	99.37	91.71	93.66	98.43	95.61	99.46
Woods	126	1139	96.09	93.20	95.49	99.57	99.05	99.39
Buildings-grass-tree-drives	38	348	61.29	49.48	47.67	97.66	90.16	96.84
Stone-steeltowers	9	84	91.51	94.62	91.40	94.19	92.47	86.90
OA			82.79±0.19	74.33±0.33	71.72±0.31	95.19±0.82	94.03±0.23	97.22±0.16
AA			78.17±1.51	68.48±2.36	65.15±0.28	86.96±0.75	83.27±0.36	92.31±0.32
Kappa			0.797±0.002	0.706±0.006	0.673±0.004	0.946±0.003	0.931±0.004	0.968±0.002

从训练集中每类随机选取 20 个样本建立第一层初始的字典。对少于 20 个训练样本的类别如苜蓿、草地/修剪的牧草、燕麦、石钢塔使用全部样本。因为特征的维数很高,在第二层初始的字典较大可以得到一个过完备的字典。对印第安松林第一层字典大小设置为 257,第二层为 1440。对帕维亚大学字典大小第一层为 180,第二层为 900。在类标一致性 K-SVD 中,平衡类标判别项的参数 α 、分类误差项的正则参数 β 、稀疏度阈值 T 分别设置为 2,4,40。

为了证明本文算法对于高光谱图像分类的有效性,采用四个相关的特征学习方法即 SR、KSR,同步正交匹配追踪(SOMP),基于稀疏的空间金字塔匹配模型(SCSPM)用来作比较。在所有的实验中,线性 SVM 作为分类器来判断学到的特征的性能。用原始的光谱特征 SVM 得到的结果作为基准。对于 SR 稀疏参数 λ 设置为 1。对于 KSR 使用线性核函数,稀疏参数 λ 也设置为 1。对于 SOMP 使用 7×7 的正方形窗口,稀疏参数 K 。设置为 5。对于两个高光谱数据集邻域块的大小设置为 7×7 。SCSPM 也采用 7×7 的邻域块,在稀疏编码上作三级最大化。

表 1 和表 2 显示了两个数据集上不同算法分别得到的分类结果。用三个评价指标即整体分类精度(OA),平均分类精度(AA),Kappa 系数评价分类性能。OA 是正确分类像素的百分比。AA 是单个类别精

度的平均值, Kappa 系数表示分类结果与参数数据之间的吻合程度或者精度指标。

表 2 帕维亚大学图像训练样本和测试样本数及不同方法的分类精度

Table 2 Number of train and test sample of the Pavia university and classification accuracy for different methods

Class name	Train	Test	SVM	SR	KSR	SOMP	SCSPM	Our method
Asphalt	548	6304	92.88	75.67	74.13	99.38	96.21	99.45
Meadows	540	18146	98.22	86.17	85.38	99.79	96.31	99.87
Gravel	392	1815	77.99	73.18	73.21	97.02	93.25	99.91
Trees	524	2912	94.18	93.66	92.16	96.18	98.05	98.34
Metal sheets	265	1113	99.20	99.78	93.45	93.90	99.93	99.64
Bare soil	532	4572	88.63	80.29	80.62	100	97.63	100
Bitumen	375	981	84.28	89.60	83.87	99.94	99.34	100
Bricks	514	3364	91.10	84.45	84.65	97.84	95.38	99.17
Shadow	231	795	96.36	96.98	96.32	99.96	99.61	99.47
OA			93.87±0.22	92.69±0.11	92.63±0.09	96.83±0.04	97.58±0.03	99.58±0.01
AA			91.43±0.41	86.64±0.33	86.53±0.32	96.90±0.09	97.30±0.03	99.32±0.01
Kappa			0.919±0.005	0.853±0.003	0.836±0.002	0.964±0.002	0.955±0.002	0.962±0.002

从结果中可以看到, 本文方法能达到较高的精度且优于其他的方法。该方法在印第安松林数据集和帕维亚大学数据集上的 OA 分别能达到 97.22% 和 99.58%。相比使用原始的光谱向量的 SR、KSR、SOMP、SCSPM, 该方法在学习特征上是有效的。特别是该方法在印第安松林数据集上相比 SCSPM 能提高大约 3% 精度, 在帕维亚大学数据集上大约 2% 精度。证明所提出的两层特征学习的方法相比单层特征学习的方法得到的特征更有效而且更具有判别性。因为该方法能从分层结构中的原始像素中发现上下文信息。

图 4 显示了不同方法的分类图。可以看到本文方法比其他方法能得到更好的一致性, 特别是用白色的矩形框标出的类别, 即使是很小的区域也如此。




图 4 不同方法得到的分类图。(a) SVM; (b) SR; (c) KSR; (d) SCSPM; (e) SOMP; (f) 本文方法

Fig. 4 Classification maps obtained by different methods. (a) SVM; (b) SR; (c) KSR; (d) SCSPM; (e) SOMP; (f) proposed method

4.2 邻域块大小的影响

为了分析本文方法中邻域块大小对精度的影响, 用不同的邻域块大小运行该特征学习算法, 表 3 显示了在两个高光谱数据集上不同邻域块大小下的 OA。

表 3 本文方法在两个高光谱数据集上不同邻域块大小下的 OA

Table 3 OA of proposed method on two hyperspectral datasets with different patch sizes

Dataset	Patch size				
	3×3	5×5	7×7	9×9	11×11
Indian pines	82.53±1.35	93.41±0.35	97.22±0.13	97.55±0.05	97.73±0.03
Pavia university	92.93±1.32	97.35±0.03	99.55±0.01	99.73±0.01	99.76±0.01

从结果中可以看到, 分类精度随着邻域块大小的增加而增加。当邻域块尺寸比较小时, 精度增加的趋势很快, 当邻域块尺寸为 7×7 时变得缓慢, 最后保持相对稳定。当邻域块尺寸为 3×3 时, 对于两个数据集来

说性能较差,很可能是因为在很小的区域内捕捉的信息有限。为了平衡计算的复杂度和性能之间的关系,在实验中使用的邻域块尺寸为 7×7 。

5 结 论

提出了一种基于分层稀疏表示的特征学习方法,即分层判别特征学习方法用于高光谱遥感图像分类。该方法可以挖掘光谱和空间信息。利用类标一致性 K-SVD 来得到判别稀疏编码。采用基于空间金字塔最大池化模型的分层方法能更好地表示信息,如高光谱数据中的细节和纹理信息。

实验结果表明,采用分层特征学习的方法优于单层的方法。与单层的特征学习方法相比较,本文方法在两个广泛使用的高光谱数据集上,分类精度都有一定程度地提高。与四种高光谱数据分类方法相比,该方法能取得更好的性能,证明了该方法所学习到的特征对分类的有效性。

高光谱图像数据中隐含大量有用的判别信息,将来的研究方向可以结合很多经典的语义挖掘算法,将每个高光谱像素点的原始特征拆分成多个中层语义特征描述子,更加准确地描述每类地物的特征,另外本文仅使用了监督学习的思想,导致训练过程中对训练样本的数目要求较多,因此,如何结合半监督学习架构也成为下一步的研究方向。

参 考 文 献

- 1 Shen Yi, Zhang Min, Zhang Miao. Mutual information bands selection and empirical mode decomposition based support vector machine for hyperspectral data high accuracy classification[J]. Laser & Optoelectronics Progress, 2011, 48(9): 091001.
沈 毅, 张 敏, 张 淼. 基于互信息波段选择和经验模态分解的高精度高光谱数据分类[J]. 激光与光电子学进展, 2011, 48(9): 091001.
- 2 Zhang H, Li J, Huang Y, *et al.* A nonlocal weighted joint sparse representation classification method for hyperspectral imagery[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7(6): 2056-2065.
- 3 Sun Peng, Gao Wei, Sun Yifan. Analysis and comparison of several target detectors for hyperspectral imaging[J]. Laser & Optoelectronics Progress, 2015, 52(9): 092801.
孙 鹏, 高 卫, 孙奕帆. 几种高光谱目标探测算法性能的分析比较[J]. 激光与光电子学进展, 2015, 52(9): 092801.
- 4 Wu Yiquan, Zhou Yang, Long Yunlin. Small target detection in hyperspectral remote sensing image based on adaptive parameter SVM[J]. Acta Optica Sinica, 2015, 35(9): 0928001.
吴一全, 周 杨, 龙云淋. 基于自适应参数支持向量机的高光谱遥感图像小目标检测[J]. 光学学报, 2015, 35(9): 0928001.
- 5 Fan Liheng, Lü Junwei, Deng Jiangsheng. Classification of hyperspectral remote images based on bands grouping and classification ensembles[J]. Acta Optica Sinica, 2014, 34(9): 0910002.
樊利恒, 吕俊伟, 邓江生. 基于分类器集成的高光谱遥感图像分类方法[J]. 光学学报, 2014, 34(9): 0910002.
- 6 Fang L, Li S, Kang X, *et al.* Spectral-spatial hyperspectral image classification via multiscale adaptive sparse representation[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(12): 7738-7749.
- 7 Falco N, Benediktsson J A, Bruzzone L. A study on the effectiveness of different independent component analysis algorithms for hyperspectral image classification[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7(6): 2183-2199.
- 8 Song B, Li J, Dalla Mura M, *et al.* Remotely sensed image classification using sparse representations of morphological attribute profiles[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(8): 5122-5136.
- 9 Pan Z, Glennie C, Legleiter C, *et al.* Estimation of water depths and turbidity from hyperspectral imagery using support vector regression[J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(10): 2165-2169.
- 10 Zou Z, Shi Z. Hierarchical suppression method for hyperspectral target detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(1): 330-342.
- 11 Ni D, Ma H. Hyperspectral image classification via sparse code histogram[J]. IEEE Geoscience and Remote Sensing

- Letters, 2015, 12(9): 1843-1847.
- 12 Kang X, Li S, Fang L, *et al.* Intrinsic image decomposition for feature extraction of hyperspectral images [J]. IEEE Transactions on Geoscience Remote Sensing, 2015, 53(4): 2241-2253.
 - 13 Ghamisi P, Benediktsson J A. Feature selection based on hybridization of genetic algorithm and particle swarm optimization [J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(2): 309-313.
 - 14 Zhou Y, Peng J, Chen C L P. Dimension reduction using spatial and spectral regularized local discriminant embedding for hyperspectral image classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(2): 1082-1095.
 - 15 Kang X, Li S, Fang L, *et al.* Extended random walker-based classification of hyperspectral images [J]. IEEE Transactions on Geoscience Remote Sensing, 2015, 53(1): 144-153.