

基于空谱字典的加权联合稀疏表示高光谱图像分类

陈善学^{1,2}, 何宇峰^{1,2*}

¹重庆邮电大学移动通信技术重庆市重点实验室, 重庆 400065;

²重庆邮电大学通信与信息工程学院, 重庆 400065

摘要 稀疏表示广泛用于高光谱图像分类任务中。针对字典原子空间信息和光谱信息未得到充分利用的问题,提出了基于空谱字典的加权联合稀疏表示高光谱图像分类算法。计算测试像元与字典原子的空谱联合距离,选择相似度最高的 K 个字典原子,并将被选择字典原子的超像素邻域扩充到新的字典中,形成空谱字典。在联合稀疏模型中,对测试像元的超像素邻域像元使用不同的权重,在空谱字典上构建加权稀疏表示模型。基于所选的两个高光谱数据集的实验证明所提算法能够有效地提高分类精度。

关键词 图像处理; 高光谱图像分类; 空谱字典; 超像素; 稀疏表示

中图分类号 TP751.1 **文献标志码** A

DOI: 10.3788/AOS220854

1 引言

高光谱图像是星载或机载高光谱成像仪采集数十至数百个连续窄波段光谱数据而成的遥感图像。高光谱图像数据是三维立方体数据,包含每个波段的二维空间信息和每个像元的光谱信息。由于高光谱图像具有丰富的空间信息和光谱信息,故被广泛应用在环境检测、矿物勘探、作物监测和目标识别等领域中^[1]。

高光谱图像分类的目的是对图像中的每一个像元赋予地物标签。如今,多种分类技术被应用于高光谱分类中,如支持向量机(SVM)^[2]、多项式逻辑回归^[3]和神经网络^[4]等。近年来,稀疏表示被证明是解决人脸识别、图像超分辨率等问题的强有力工具^[5]。稀疏表示的基本假设是:若一个类有足够多的训练样本,则属于此类的测试样本就能利用来自此类的训练样本的线性组合表示^[6]。稀疏表示分类通过对测试样本进行稀疏表示得到稀疏表示参数,计算每一类训练样本的重构残差从而确定测试样本的类别。Chen等^[6]将稀疏表示模型引入到高光谱分类中,根据邻域内像元共享稀疏模型,提出了联合稀疏表示模型。文献[6-9]通过对邻域内像元进行加权的方式削弱不相似元素的影响。陈善学等^[10]使用超像素提高了相邻像素的一致性。李非燕等^[11]通过提取多特征并添加约束的方式构建了稀疏模型。良好的字典可以为测试样本提供合适的子空间,从而达到更好的分类效果。Fang等^[12]采用判别 K -

SVD算法同时学习字典和分类器。Long等^[13]提出了非局部字典学习稀疏表示方法,使用估计函数选择加入字典的邻域像元,最后利用估计函数建立了联合稀疏模型。Zhang等^[14]提出了局部约束稀疏表示方法,选择与字典原子中最相似的原子组成自适应字典进行稀疏表示。Peng等^[15]提出了局部自适应联合稀疏表示,将训练样本邻域的像元扩展到训练样本字典中构建了自适应字典。

在上述的稀疏表示方法中字典原子的空间信息未得到有效的利用,Han等^[16]研究发现高光谱图像字典中除了光谱信息,还包含了空间信息。因此,本文提出了基于空谱字典的加权联合稀疏表示高光谱图像分类(SSD-WJSRC)算法。先使用熵率超像素分割(ERS)算法获得超像素分割图,再计算测试样本与字典原子之间的联合相似度,通过 K 最邻近法(KNN)算法选择相似度最高的原子,添加原子及其邻域作为新的空谱字典。对测试像元的超像素邻域使用不同的权重以降低邻域中不相关像元对联合稀疏表示模型的影响,再在空谱字典上构建联合稀疏表示模型计算稀疏表示系数,最后根据稀疏表示系数计算每一类重建残差,并将测试像元分类到重建残差最小的类别中。

2 稀疏表示高光谱分类

高光谱数据集为 $X = [x_1 x_2 \cdots x_n \cdots x_N] \in \mathbb{R}^{B \times N}$,其中 B 为光谱带的数目, N 为像素数目。结构化

收稿日期: 2022-03-24; 修回日期: 2022-05-09; 录用日期: 2022-06-20; 网络首发日期: 2022-06-30

通信作者: *846320689@qq.com

字典为 $D = [d_1 \ d_2 \ \dots \ d_c \ \dots \ d_C]$, 其中 $d_c = [d_c^{(1)} \ d_c^{(2)} \ \dots \ d_c^{(N_c)}]$ 为第 c 类地物子字典, N_c 为第 c 类地物字典原子数目, C 为地物类别数目。如果测试像元 x 属于 c 类, 那么 x 就能由子字典线性组合表示出, 即

$$x = d_c^{(1)} a_c^{(1)} + d_c^{(2)} a_c^{(2)} + \dots + d_c^{(N_c)} a_c^{(N_c)}, \quad (1)$$

式中: a_c 是稀疏表示系数, 满足稀疏性要求, 只包含少数非零项, 其中非零项表示对应字典原子的权重。对于未知类别的像元 x , 可以通过字典 D 的线性组合表示为

$$x = d_1 a_1 + d_2 a_2 + \dots + d_C a_C = [d_1 \ d_2 \ \dots \ d_C] [a_1 \ a_2 \ \dots \ a_C]^T = Da, \quad (2)$$

式中: $a_1 \sim a_C$ 为稀疏表示参数。在理想情况下, 如果 x 属于第 c 类, 则存在 $a_i = 0 (i = 1, 2, \dots, C \text{ 且 } i \neq c)$, 即只有对应类的稀疏向量项为非零项, 其他项均为 0。

稀疏表示参数的求解可以视为优化问题, 即

$$\hat{a} = \arg \min \|Da - x\|_F, \quad \text{s. t. } \|a\|_{\text{row},0} \leq K_0, \quad (3)$$

式中: $\arg \min(\cdot)$ 为求解参数最小函数; \hat{a} 为稀疏系数矩阵; $\|\cdot\|_F$ 为 Frobenius 范数; $\|\cdot\|_{\text{row},0}$ 为 0 范数, 代表非零

项的数目; K_0 是稀疏向量中非零项数目的上限 (稀疏度)。稀疏表示参数可由正交匹配追踪 (OMP)^[17] 算法得到, 计算出稀疏表示参数后根据稀疏表示参数计算每一类重建残差, 重建残差最小类别即为测试像素所属类别, 为测试像素分配对应的地物标签后完成分类, 即

$$\text{class}(x) = \arg \min r_c(x), \quad (4)$$

式中: $\text{class}(\cdot)$ 为分类结果函数; $r_c(x) = \|x - d_c \hat{a}_c\|_F$ 为利用第 c 类子字典对测试像元进行重构后得到的像元与测试像元之间的残差; \hat{a}_c 为 OMP 算法得到的稀疏表示系数矩阵。

3 基于空谱字典的加权联合稀疏表示高光谱图像分类

3.1 空谱字典

稀疏表示通常对测试像元的邻域空间信息更加关注, 忽略了字典原子的空间信息。所提的基于空谱字典的加权联合稀疏表示高光谱图像分类算法改善了字典原子的空谱信息未得到充分利用的问题。所提高光谱图像分类方法的示意图如图 1 所示。

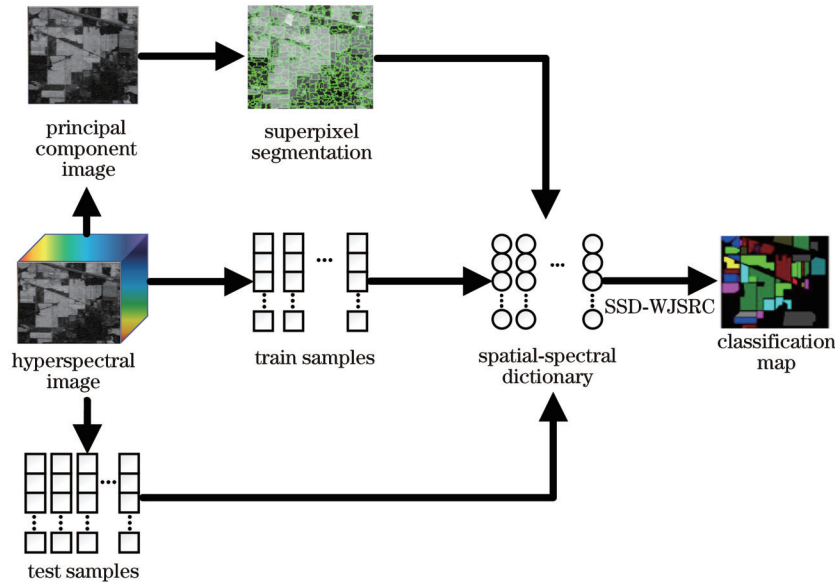


图 1 所提高光谱图像分类方法示意图

Fig. 1 Schematic diagram of proposed hyperspectral image classification method

本文中的空谱字典的构造流程如下。

首先, 通过主成分分析 (PCA) 算法将高光谱图像降维到一维得到主成分图像, 并在主成分图像上使用 ERS 算法得到超像素分割标签图, 超像素标签对应的区域为 $S = [s_1 \ s_2 \ \dots \ s_s]$, 其中 s 为超像素的个数。

然后, 计算测试像元 x 和字典原子 d 的联合相似度。测试像元 x 和字典原子 d 的空间坐标分别为 $P_x = (x^{\text{pixel}}, y^{\text{pixel}})$ 和 $P_d = (x_d^{\text{pixel}}, y_d^{\text{pixel}})$, 待测像元 x 和字典原子 d 之间的空间距离的定义为

$$D_{\text{pixel}} = \sqrt{(x^{\text{pixel}} - x_d^{\text{pixel}})^2 + (y^{\text{pixel}} - y_d^{\text{pixel}})^2}, \quad (5)$$

测试像元 x 和字典原子 d 之间的光谱距离的定义为

$$D_{\text{spc}} = \arccos \left(\frac{x^T d}{\|x\|_2 \|d\|_2} \right), \quad (6)$$

结合空间距离和光谱距离定义测试像元 x 和字典原子 d 之间的联合相似度, 即

$$D_{\text{joint}} = \lambda D_{\text{pixel}} + (1 - \lambda) D_{\text{spc}}, \quad (7)$$

式中: λ 是平衡系数, 用于平衡空间信息与光谱信息之间的比重, 其值通常在 0~1 范围内。

接着,计算测试像元 x 和所有字典原子 d 之间的联合相似度 D_{joint} ,并将所有的联合相似度按照降序排列,选择前 K 个字典原子。

最后,将前 K 个字典原子对应的超像素邻域中的像元作为子字典加入到空谱字典 $D_{\text{local}} = [S_{K,1} \ S_{K,2} \ \dots \ S_{K,K}]$ 中。

3.2 加权联合稀疏表示

相邻的高光谱像元通常由相似的地物组成,故光谱信息相关性很高。因此,当光谱相似度低的像元加入到联合稀疏表示模型中时,对其赋予与光谱相似度高的像元相同的权重是不合适的。因此,邻域中的像元应该与测试像元权重不同,并且权重由测试像元与邻域像元之间的光谱相关性确定。

对于测试像元 x 所在超像素区域 $X_p = [x_1 \ x_2 \ \dots \ x_p \ \dots \ x_P]$,其中 P 为超像素内像元的数目,先计算测试像元与超像素邻域像元的光谱距离,并通过光谱距离确定字典原子的权重。测试像元与邻域像元之间的距离通常使用欧氏距离计算,使用高斯

核能够捕捉非线性信息的距离来衡量样本之间的相似度。测试像元 x 与邻域像元 x_p 之间的高斯核距离的定义为

$$w(x, x_p) = \exp\left[-\|x - x_p\|_2^2 / (2\sigma^2)\right], \quad (8)$$

式中 σ 是高斯核宽度,通过计算字典原子之间的平均欧氏距离得到。由于高斯核距离的取值范围为 $0 \sim 1$,故可以直接使用高斯核距离作为权重。 σ 的计算公式为

$$\sigma = \sum_e \sum_f \|x_e - x_f\|_2 / P^2, \quad e \neq f, \quad (9)$$

式中 $e = 1, \dots, P; f = 1, \dots, P$ 。

然后,根据式(8)得到的距离信息对字典原子进行加权,得到加权邻域 $X_p = [w_1 x_1 \ w_2 x_2 \ \dots \ w_p x_p]$ 。获得的加权稀疏表示模型为

$$\hat{a} = \arg \min \|Da - X_p\|_F, \quad \text{s. t. } \|a\|_{\text{row},0} \leq K_0. \quad (10)$$

最后,使用同步正交匹配追踪(SOMP)算法求解稀疏表示参数。加权联合稀疏表示算法具体步骤如图2所示。

1. Input: sparse representation dictionary D , test sample x and superpixel neighbourhood X
2. Calculating average Euclidean distance of superpixel neighbourhood image elements σ

For $e=1:P-1$

For $f=e:P$

$$\sigma += \sqrt{(x_e - x_f)^2}$$

End

End

$$\sigma = \sigma / P^2$$
3. Calculating Gaussian kernel distance between test sample and dictionary atom
$$w(x, x_p) = \exp\left[-\|x - x_p\|_2^2 / (2\sigma^2)\right]$$
4. Calculating weight of dictionary atoms using Gaussian kernel distances
$$X_p = [w_1 x_1 \ w_2 x_2 \ \dots \ w_p x_p]$$
5. Output: weighted neighbourhood X_p
6. Solving sparse representation models using SOMP algorithm

图2 加权联合稀疏表示算法

Fig. 2 Weighted joint sparse representation

3.3 基于空谱字典的加权稀疏表示高光谱图像分类

使用联合相似度,利用测试样本与字典原子之间的光谱角距离和空间距离选择相似度更高的原子、空谱字典,能够有效地提高分类精度,减少稀疏表示的字典数目,降低计算量。只选择一定数目的字典原子作为空谱字典,但字典数目过少会导致字典不满足稀疏表示字典的过完备性,故需要对空谱字典进行扩展。由于高光谱图像有着丰富的光谱信息和空间信息,在邻域范围内像元具有同质性,光谱信息近似,故通过分

割超像素的方法可以得到像元的同质区域,获取到像元的空间信息。空谱字典的扩展使用超像素邻域像元进行扩展,并利用字典的邻域空间信息。使用加权算法对超像素邻域进行加权,减少不相关像元对联合稀疏表示的影响,在空谱字典上构建加权联合稀疏表示模型,最终实现分类。

基于空谱字典的加权联合稀疏表示高光谱图像分类方案的具体步骤如图3所示。

1. Input: HSI dataset \mathbf{X}
2. Initialization: sparsity K_0 , test samples T , dictionary $\mathbf{D} = [\mathbf{d}_1 \ \mathbf{d}_2 \ \cdots \ \mathbf{d}_c \ \cdots \ \mathbf{d}_C]$, index set $\mathcal{A}_0 = \emptyset$, iteration count $q = 1$, construction of a dictionary of empty spectra to select number of atoms K , super pixel area \mathcal{S} , balance parameter λ
3. For each text sample
 - 1) Constructing dictionary spatial-spectral dictionary

$$\mathbf{D}_{\text{local}} = [\mathcal{S}_{K,1} \ \mathcal{S}_{K,2} \ \cdots \ \mathcal{S}_{K,k}] = [\mathbf{d}_1 \ \mathbf{d}_2 \ \cdots \ \mathbf{d}_l], \quad l \text{ is number of empty spectral dictionaries}$$
 - 2) Weighted neighbourhood obtained via weighted joint sparse representation algorithm

$$\mathbf{X}_p = [w_1 \mathbf{x}_1 \ w_2 \mathbf{x}_2 \ \cdots \ w_p \mathbf{x}_p]$$
 - 3) Initializing residual $\mathbf{R}_0 = \mathbf{X}_p$
 - 4) Constructing sparse model $\hat{\mathbf{A}} = \arg \min \|\mathbf{D}_{\text{local}} \hat{\mathbf{A}} - \mathbf{X}_p\|_F$, s.t. $\|\hat{\mathbf{A}}\|_{\text{row},0} \leq K_0$
 - 5) For $k=1:K_0$
 - a) Finding index of dictionary atom $\lambda_q = \arg \max \|\mathbf{R}_{k-1}^T \mathbf{d}_l\|_2$, and updating index set $\mathcal{A}_k = \mathcal{A}_{k-1} \cup \{\lambda_q\}$
 - b) Calculating $\mathbf{A}_q = \left(\mathbf{D}_{\text{local}, \mathcal{A}_k}^T \mathbf{D}_{\text{local}, \mathcal{A}_k} \right)^{-1} \mathbf{D}_{\text{local}, \mathcal{A}_k}^T \mathbf{X}_p$
 - c) Updating residual $\mathbf{R}_q = \mathbf{R}_{q-1} - \mathbf{D}_{\text{local}, \mathcal{A}_k} \mathbf{A}_q$
 - d) Updating iteration count $q = q + 1$
 End for
 - 6) Calculating sparse coefficient matrix $\hat{\mathbf{A}} = \left(\mathbf{D}_{\text{local}, \mathcal{A}_k}^T \mathbf{D}_{\text{local}, \mathcal{A}_k} \right)^{-1} \mathbf{D}_{\text{local}, \mathcal{A}_k}^T \mathbf{X}_p$
 - 7) Calculating residuals obtained for each category

$$\mathbf{r}_c(\mathbf{X}_p) = \|\mathbf{X}_p - \mathbf{D}_{\text{local}} \mathbf{A}_c\|_F, \quad c = 1, 2, \dots, C$$
 - 8) Classification: $\text{class}(\mathbf{x}) = \arg \min \mathbf{r}_c(\mathbf{X}_p)$
- End for
4. Output: hyperspectral image classification results $\text{class}(T)$

图 3 基于空谱字典的加权联合稀疏表示高光谱图像分类

Fig. 3 Weighted joint sparse representation hyperspectral image classification based on spatial-spectral dictionary

4 实验分析

在高光谱图像分类中常使用 Indian Pines 和 Salinas 数据集对所提高光谱分类方法的性能进行验证,并将所提方法与 KNN、SRC、局部约束稀疏表示 (LSRC)^[14]、基于空间预处理的高光谱图像分类联合稀疏表示 (SP-JSRC)^[11] 和 HybridSN^[18] 进行仿真对比。采用的仿真条件: intel i5-8500, 6核 6线程处理器, 主频

为 3 GHz, 随机存取存储器 (RAM) 容量为 16 GB、仿真软件为 MATLAB2021a。仿真实验的评价标准使用总体分类准确度 (OA)、平均准确度 (AA) 和 Kappa 系数。

4.1 高光谱数据集说明

Indian Pines 数据集由 AVIRIS 传感器在印第安纳州西北部的印第安松树试验场中收集得到, 图像尺寸为 145 pixel \times 145 pixel, 且包括 224 个光谱反射带。

在实验中去掉吸水波段后波段数目减少到 200 个。该数据集包含 16 个地物类别,其中大部分是不同的作物,如小麦、玉米和大豆等。Salinas 数据集是由 224 波段的 AVIRIS 传感器在美国加州萨利纳斯山谷上空采集得到的,覆盖的区域包括 512×217 个像素。弃用了 20 个水吸收波段,保留 204 个有效光谱波段。该数据集一共包含 16 个地物类别,如蔬菜、土壤和葡萄园田等。

4.2 参数设置

Indian Pines 和 Salinas 数据集的地物类别、训练样本数目和测试样本数目如表 1 和表 2 所示。在 Indian Pines 数据集中,随机选择 10% 的已标记像元作为稀疏表示的字典,其余 90% 的样本作为测试样本。在 Salinas 数据集中,使用 1% 的已标记像元作为稀疏表示的字典,其余 99% 的样本作为测试样本。字典由随

机选取的已标记的像元组成,可能给实验结果带来偶然性偏差,故将 10 次实验结果的平均值作为最终的实验结果数据。在 SRC 算法中,将稀疏度 K_0 设置为 10。在 KNN 算法中,将最近邻值设置为 3。在 SP-JSRC 算法中,将 Indian Pines 数据集的超像素生成数目设置为 $K_1=3000$ 和 $K_2=500$,将 Salinas 数据集的超像素生成数目设置为 $K_1=15000$ 和 $K_2=1200$ 。在所提算法中,将 Indian Pines 数据集的超像素生成数目设置为 500,将 Salinas 数据集的超像素生成数目设置为 2000,此时两个数据集中的超像素分割伪彩图如图 4 和图 5 所示。将空间信息和光谱信息之间的权重 λ 设置为 0.9,空谱字典选择相似度最高的 10 个训练样本,将 Indian Pines 数据集的稀疏度设置为 10,将 Salinas 数据集的稀疏度设置为 9。

表 1 Indian Pines 数据集中的训练样本与测试样本数目
Table 1 Number of training samples and test samples in Indian Pines dataset

Label	Class	Number of training samples	Number of test samples
1	Alfalfa	4	42
2	Corn-notill	142	1286
3	Corn-mintill	83	747
4	Corn	23	214
5	Grass-pasture	48	435
6	Grass-trees	73	657
7	Grass-pasture-mowed	2	26
8	Hay-windrowed	47	431
9	Oats	2	18
10	Soybean-notill	97	875
11	Soybean-mintill	245	2210
12	Soybean-clean	59	534
13	Wheat	20	185
14	Woods	126	1139
15	Buildings-Grass-Trees-Drives	38	348
16	Stone-Steel-Towers	9	84
Total		1018	9231

4.3 实验结果和分析

在 Indian Pines 数据集的实验仿真过程中,每类选取 10% 已标记的样本组成字典,其余 90% 样本作为测试样本。Indian Pines 数据集在不同算法下的分类精度如表 3 所示。

为了更好地观察分类结果,使用不同的图像灰度值作为不同类别的地物标签来生成分类结果图像。当字典原子数目占比为总样本数目的 10% 时,各算法的分类结果如图 6 所示,不同灰度值代表不同地物。从表 3 可以看出,当字典原子数目占比为 10% 时,所提 SSD-WJSRC 算法的总体精度为 97.60%,相比于 SRC、KNN、LSRC、SP-JSRC 和 HybridSN 算法的总体精度分别高出 30.47 个百分点、28.44 个百分点、16.73 个百分点、2.70 个百分点和 2.62 个百分点,且在每类

地物的分类上均取得了较好的分类结果。从图 6 可以看出,各个算法对 Grass-pasture 的分类效果均不佳。LSRC 只使用光谱信息从而会引起分类效果不佳,而所提方法充分使用了字典原子的空间信息,故有效提高了光谱相似度高像元之间的分类效果。Indian Pines 数据集有部分类别数目较少会导致 HybridSN 网络没有足够的样本进行训练,故其分类精度较低,而样本数目较少时,所提方法可以利用空间信息加快分类进度,从而提高分类精度。

对于 Salinas 数据集,每类选取 1% 已标记的样本组成结构化字典。各算法分别运行 10 次,并将 10 次实验分类结果的平均值作为算法的最终分类结果,各个算法的分类结果如表 4 所示。在每类选取 1% 总样本作为字典的情况下,各算法的分类结果如图 7 所示。

表 2 Salinas 数据集中的训练样本与测试样本数目
Table 2 Number of training samples and test samples in Salinas dataset

Label	Class	Number of training samples	Number of test samples
1	Brocoli_green_weeds_1	20	1989
2	Brocoli_green_weeds_2	37	3689
3	Fallow	19	1957
4	Fallow_rough_plow	13	1381
5	Fallow_smooth	26	2652
6	Stubble	39	3920
7	Celery	35	3544
8	Grapes_untrained	112	11159
9	Soil_vinyard_develop	62	6141
10	Corn_senesced_green_weeds	32	3246
11	Lettuce_romaine_4wk	10	1058
12	Lettuce_romaine_5wk	19	1908
13	Lettuce_romaine_6wk	9	907
14	Lettuce_romaine_7wk	10	1060
15	Vinyard_untrained	72	7196
16	Vinyard_vertical_trellis	18	1789
Total		533	53596




图 4 Indian Pines 数据集中的超像素分割图
Fig. 4 Superpixel segmentation of Indian Pines dataset




图 5 Salinas 数据集中的超像素分割图
Fig. 5 Superpixel segmentation of Salinas dataset

由表 3 可以看出,所提 SSD-WJSRC 算法的总体精度为 98.01%,相比于 SRC、KNN、LSRC 和 SP-JSRC 算法的总体精度分别高出 13.38 个百分点、14.49 个百分点、6.62 个百分点和 2.83 个百分点,相比于 HybridSN 低 0.07 个百分点。与当前的深度学习方法相比,在样

本量少的情况下所提 SSD-WJSRC 算法仍然有较好的分类精度。从图 7 可以看出,所提算法有效利用了空间信息,提高了对多地物混合区域的分类精度。

图 8 展示了构建空谱字典时平衡空间信息与光谱信息的平衡系数 λ 取不同值时对分类整体精度的影响。可以看出,当 $\lambda = 0$ 时,即只使用光谱信息时,由于缺失空间信息,故字典表达能力较小。随着空间信息权重的增加,分类精度逐步提升,但空间信息过多时会导致选择的字典只在测试像元周围,此时字典多样性会下降,从而导致分类精度降低。

图 9 和图 10 展示了超像素数目和稀疏度对分类结果的影响。在本实验中,Indian Pines 数据集选择 10% 样本作为字典,其余 90% 作为测试样本,Salinas 数据集选择 1% 样本作为字典,并将其余样本作为测试样本。可以看出:随着超像素数目的增多(每个邻域内原子数目的减少),空谱字典多样性在降低,而空间信息的减少会使得分类效果降低;Indian Pines 数据集与 Salinas 数据集的分类精度随着稀疏度的增大先增大后减小,稀疏度越大代表在稀疏表示过程中选取的原子数目越多,选择的原子数目的增多提高了分类精度,但原子数目过多会导致稀疏表示不满足稀疏性从而使分类效果降低。

从 Indian Pines 和 Salinas 数据集的实验结果看出,所提的基于空谱字典的加权稀疏表示高光谱图像分类方法能有效提高分类精度。采取空谱约束的方式实现了字典原子空谱信息的充分利用,生成了表达性更好的空谱字典。在地物光谱相似度高的情况下,所提方法也可以利用空间信息改善错误分类的情况。同时,

表 3 Indian Pines 数据集在不同算法下的分类精度
Table 3 Classification accuracies of Indian Pines dataset under different algorithms

unit: %

Class	SRC	KNN	LSRC	SP-JSRC	HybridSN	SSD-WJSRC
Alfalfa	21.43	7.14	0	61.90	100.00	97.62
Corn-notill	47.98	53.58	77.29	96.58	95.47	96.89
Corn-mintill	51.81	40.43	56.49	92.77	97.24	97.19
Corn	29.44	12.62	51.40	90.65	99.46	93.46
Grass-pasture	82.07	80.92	88.74	93.79	94.93	99.08
Grass-trees	87.82	97.56	95.43	98.17	89.09	100.00
Grass-pasture-mowed	61.54	65.38	3.85	84.62	100.00	96.15
Hay-windrowed	95.13	98.84	100.00	100.00	100.00	100.00
Oats	22.22	27.78	0	100.00	88.89	100.00
Soybean-notill	68.00	72.34	68.23	93.14	93.54	97.83
Soybean-mintill	72.04	79.59	87.87	97.06	95.65	98.73
Soybean-clean	40.82	35.39	83.71	79.59	95.98	88.95
Wheat	88.65	95.14	97.84	89.73	97.69	99.46
Woods	87.18	92.45	98.51	97.98	93.21	99.47
Buildings-Grass-Trees-Drives	35.92	12.64	40.80	99.14	96.71	94.83
Stone-Steel-Towers	83.33	80.95	75.00	82.14	84.75	88.10
OA	67.13	69.16	80.87	94.90	94.98	97.60
AA	60.96	59.55	64.07	91.08	89.73	97.26
Kappa	62.53	64.84	78.19	94.18	94.26	96.73




图 6 Indian Pines 数据集的分类结果。(a)标准分类结果;(b) SRC;(c) KNN;(d) LSRC;(e) SP-JSRC;(f) HybridSN;(g) SSD-WJSRC

Fig. 6 Classification results of Indian Pines dataset. (a) Standard classification result; (b) SRC; (c) KNN; (d) LSRC; (e) SP-JSRC; (f) HybridSN; (g) SSD-WJSRC




图 7 Salinas 数据集的分类结果。(a)标准分类结果;(b) SRC;(c) KNN;(d) LSRC;(e) SP-JSRC;(f) HybridSN;(g) SSD-WJSRC

Fig. 7 Classification results of Salinas dataset. (a) Standard classification result; (b) SRC; (c) KNN; (d) LSRC; (e) SP-JSRC; (f) HybridSN; (g) SSD-WJSRC

所提方法对邻域进行加权减少了邻域像元内不相关像元对稀疏模型的影响,有效提高了不同地物相邻区域和地物边缘处的分类精度。在对样本较少的地物类型

进行分类时,所提方法充分使用了样本的邻域信息,保证了分类精度。

为了验证构建的空谱字典对稀疏表示分类的影

表 4 Salinas 数据集在不同算法下的分类精度

Table 4 Classification accuracies of Salinas dataset under different algorithms

unit: %

Class	SRC	KNN	LSRC	SPJSRC	HybridSN	SSD-WJSRC
Brocoli_green_weeds_1	97.49	94.822	99.40	91.65	96.88	99.70
Brocoli_green_weeds_2	98.62	97.235	99.89	100.00	100.00	99.76
Fallow	89.37	80.838	97.04	99.18	100.00	99.74
Fallow_rough_plow	95.51	99.566	96.38	90.88	97.31	98.84
Fallow_smooth	88.08	86.237	98.68	95.36	97.10	97.17
Stubble	99.82	98.240	99.46	99.87	99.15	99.67
Celery	99.63	98.787	99.72	99.41	99.14	99.46
Grapes_untrained	77.96	70.132	86.18	96.59	99.16	97.33
Soil_vinyard_develop	98.76	96.320	99.98	98.65	98.95	100.00
Corn_senesced_green_weeds	87.80	84.104	95.90	97.41	99.56	97.87
Lettuce_romaine_4wk	89.79	72.779	90.45	90.64	100.00	97.07
Lettuce_romaine_5wk	86.01	96.960	99.90	95.28	99.53	98.74
Lettuce_romaine_6wk	88.31	97.905	77.40	69.90	98.22	97.35
Lettuce_romaine_7wk	90.38	90.660	93.68	94.15	97.90	95.75
Vinyard_untrained	44.89	63.396	67.37	86.27	89.96	94.23
Vinyard_vertical_trellis	97.26	66.797	98.66	96.25	99.94	98.88
OA	84.63	83.52	91.39	95.18	98.08	98.01
AA	89.36	84.17	93.76	93.84	97.72	98.22
Kappa	82.89	81.66	90.42	94.63	97.46	97.78




图 8 不同平衡系数下的总体精度

Fig. 8 Overall accuracies at different balance factors

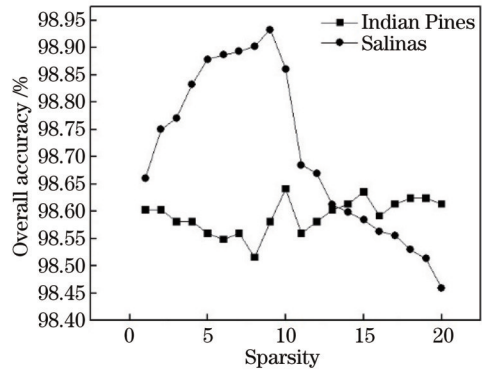


图 10 稀疏度对分类结果的影响

Fig. 10 Effect of sparsity on classification result

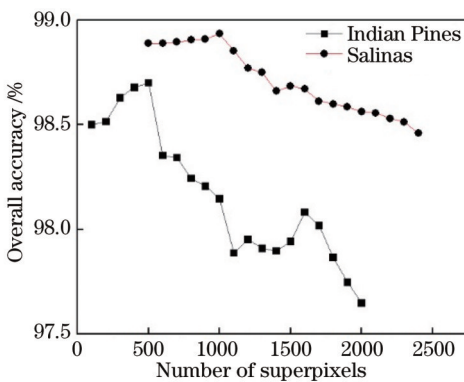


图 9 超像素数目对分类结果的影响

Fig. 9 Effect of number of superpixels on classification result

响,进行了消融实验。在测试像元与字典原子选择相同的情况下,所得的分类结果如表 5 所示。可以看出,在没有构建空谱字典的情况下,分类精度有一定的下降,证明了空谱字典能够有效提高分类精度。

5 结 论

所提的基于空谱字典的加权联合稀疏表示高光谱图像分类方法充分利用了字典原子邻域的空间信息和光谱信息。选择字典中与测试像素空间和光谱相似性高的原子作为自适应字典,并将字典原子的超像素邻域扩展到自适应字典中,形成空谱字典。对超像素邻域赋予不同的权重以减少不相关像元对稀疏表示结果的影响,并在空谱字典上构建加权稀疏表示模型,得到

表 5 无空谱字典的消融实验的分类精度

Table 5 Classification accuracies of ablation experiments without spatial-spectral dictionary unit: %

Label	Indian Pines	Salinas
1	95.24	99.10
2	89.66	99.78
3	93.71	95.40
4	89.72	98.33
5	97.93	99.21
6	99.85	99.80
7	92.31	99.58
8	100.00	94.97
9	94.44	99.76
10	94.97	91.74
11	97.01	98.02
12	91.01	97.69
13	98.92	98.68
14	99.47	93.02
15	90.23	91.79
16	97.62	97.71
OA	95.46	96.24
AA	95.13	97.12
Kappa	94.83	96.24

分类结果。在光谱相似度高的样本测试中,由于在字典中加入了空间信息,故分类精度得到了有效提高。Indian Pines 和 Salinas 数据集上的仿真实验结果表明,所提算法精度高于 KNN 算法等传统算法,与当前深度学习方法相比,样本较少时有较好的分类效果。后续仍可开展相关的研究工作,如测试像元邻域信息如何使用到选择字典的过程中和字典邻域中可能出现的干扰像元对分类结果的影响等。

参 考 文 献

- [1] Ghamisi P, Plaza J, Chen Y S, et al. Advanced spectral classifiers for hyperspectral images: a review[J]. IEEE Geoscience and Remote Sensing Magazine, 2017, 5(1): 8-32.
- [2] Melgani F, Bruzzone L. Classification of hyperspectral remote sensing images with support vector machines[J]. IEEE Transactions on Geoscience and Remote Sensing, 2004, 42(8): 1778-1790.
- [3] Haut J M, Paoletti M E. Cloud implementation of multinomial logistic regression for UAV hyperspectral images[J]. IEEE Journal on Miniaturization for Air and Space Systems, 2020, 1(3): 163-171.
- [4] 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.

- [5] Wright J, Yang A Y, Ganesh A, et al. Robust face recognition via sparse representation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(2): 210-227.
- [6] Chen Y, Nasrabadi N M, Tran T D. Hyperspectral image classification using dictionary-based sparse representation[J]. IEEE Transactions on Geoscience and Remote Sensing, 2011, 49(10): 3973-3985.
- [7] Zhang H Y, Li J Y, Huang Y C, 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.
- [8] 纪磊, 张欣, 张丽梅, 等. 基于空谱加权近邻的高光谱图像分类算法[J]. 激光与光电子学进展, 2020, 57(6): 061013.
- [9] Ji L, Zhang X, Zhang L M, et al. Hyperspectral image classification algorithm based on space-spectral weighted nearest neighbor[J]. Laser & Optoelectronics Progress, 2020, 57(6): 061013.
- [9] 李佳逊, 董安国, 沈亚栋, 等. 基于邻域相似度的联合稀疏表示的高光谱图像分类算法[J]. 激光与光电子学进展, 2017, 54(12): 122803.
- [9] Li J X, Dong A G, Shen Y D, et al. Hyperspectral image classification algorithm based on joint sparse representation of neighborhood similarity[J]. Laser & Optoelectronics Progress, 2017, 54(12): 122803.
- [10] 陈善学, 王欣欣. 基于空间预处理联合稀疏表示高光谱图像分类[J]. 系统工程与电子技术, 2021, 43(9): 2422-2429.
- [10] Chen S X, Wang X X. Joint sparse representation hyperspectral image classification based on spatial preprocessing[J]. Systems Engineering and Electronics, 2021, 43(9): 2422-2429.
- [11] 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.
- [11] 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.
- [12] Fang L Y, Li S T, Kang X D, et al. Spectral-spatial classification of hyperspectral images with a superpixel-based discriminative sparse model[J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(8): 4186-4201.
- [13] Long Y, Li H C. Hyperspectral image classification by sparse representation with nonlocal adaptive dictionary[C]//2015 IEEE International Geoscience and Remote Sensing Symposium, July 26-31, 2015, Milan, Italy. New York: IEEE Press, 2015: 1721-1724.
- [14] Zhang Y S, Ma Y, Dai X B, et al. Locality-constrained sparse representation for hyperspectral image classification[J]. Information Sciences, 2021, 546: 858-870.
- [15] Peng J T, Jiang X, Chen N, et al. Local adaptive joint sparse representation for hyperspectral image classification[J]. Neurocomputing, 2019, 334: 239-248.
- [16] Han X L, Yu J, Xue J H, et al. Hyperspectral and multispectral image fusion using optimized twin dictionaries[J]. IEEE Transactions on Image Processing, 2020, 29: 4709-4720.
- [17] Tropp J A, Gilbert A C. Signal recovery from random measurements via orthogonal matching pursuit[J]. IEEE Transactions on Information Theory, 2007, 53(12): 4655-4666.
- [18] Roy S K, Krishna G, Dubey S R, et al. HybridSN: exploring 3-D-2-D CNN feature hierarchy for hyperspectral image classification[J]. IEEE Geoscience and Remote Sensing Letters, 2020, 17(2): 277-281.

Weighted Joint Sparse Representation Hyperspectral Image Classification Based on Spatial-Spectral Dictionary

Chen Shanxue^{1,2}, He Yufeng^{1,2*}

¹Chongqing Key Laboratory of Mobile Communications Technology, Chongqing University of Posts and Telecommunications, Chongqing 400065, China;

²School of Communication and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China

Abstract

Objective Hyperspectral image classification aims to assign feature labels to each image element in images. Nowadays, several classification techniques are applied in hyperspectral classification, such as support vector machines (SVMs), polynomial logistic regression, and neural networks. In recent years, sparse representation has proven to be a powerful tool for solving problems such as face recognition and image super-resolution. The basic assumption of sparse representation is that if a class has enough training samples, the test samples belonging to this class can be represented by using a linear combination of the training samples from this class. Sparse representation classification obtains the sparse representation parameters by the sparse representation of the test samples and calculates the reconstructed residuals for each class of the training samples, which thus determines the class of the test samples. The sparse representation usually pays more attention to the spatial information of the neighborhood of the test image elements and ignores the spatial information of dictionary atoms. The proposed weighted joint sparse representation hyperspectral image classification algorithm based on the spatial-spectral dictionary (SSD-WJSRC) addresses the problem that the spatial-spectral information of dictionary atoms is underutilized.

Methods SSD-WJSRC algorithm makes full use of the spatial-spectral information of dictionary atoms. Firstly, the superpixel segmentation is performed by using the entropy rate superpixel segmentation (ERS) algorithm on the principal component image to obtain the superpixel segmentation map. Secondly, the spatial-spectral joint distance between the test image elements and the dictionary atoms is calculated, and the spatial-spectral joint distance is jointly determined by the spatial distance and the spectral angle distance. Then, image elements are added in the superpixel neighborhood corresponding to the first K dictionary atoms to the spatial-spectral dictionary as sub-dictionaries. Meanwhile, in the joint sparse model, different weights are used for the superpixel neighborhood image elements of the test image elements, and the weights are calculated from the Gaussian kernel distance, and the Gaussian kernel can be used to capture the distance of nonlinear information to measure the similarity between samples. Finally, a weighted sparse representation model is constructed on the spatial-spectral dictionary, which solves sparse coefficients by using the simultaneous orthogonal matching pursuit (SOMP) algorithm, and the reconstructed residuals are calculated. Furthermore, the classification results are determined.

Results and Discussions Several important results are obtained as follows. Firstly, The experimental results from the Indian Pines and Salinas datasets show that the proposed SSD-WJSRC can effectively improve the classification accuracy by 97.60% and 98.01%, respectively. The spatial-spectral constraint is adopted to realize the full utilization of the pixel spatial-spectral information of the dictionary and generate a better expressive spatial-spectral dictionary. The proposed method can also improve the misclassification by using spatial information in the case of high spectral similarity of features (Figs. 6 and 7). Secondly, the proposed method reduces the influence of irrelevant pixels in the neighboring pixels on the sparse model by weighting the neighboring domains and effectively improves the classification accuracy in the neighboring regions of different features and at the edges of the features. When classifying feature types with few samples, the proposed method makes full use of the neighborhood information of the samples to ensure classification accuracy (Figs. 6 and 7). Thirdly, the effects of different balance coefficients, number of superpixels, and sparsity on classification accuracy are also analyzed (Figs. 8–10). Finally, in order to verify the effect of the constructed spatial-spectral dictionary on sparse representation classification, ablation experiments are performed. The classification results obtained with the same selection of test image elements and dictionary atoms are shown in Table 5. It can be seen that there is a certain decrease in classification accuracy without constructing the spatial-spectral dictionary, which proves that the spatial-spectral dictionary can effectively improve classification accuracy.

Conclusions The proposed SSD-WJSRC makes full use of the spatial and spectral information of the dictionary atoms'

neighborhoods. The dictionary atoms with high spatial and spectral similarity to the test pixels are selected as the adaptive dictionary, and the superpixel neighborhoods of the dictionary atoms are extended to an adaptive dictionary to form a spatial-spectral dictionary. Different weights are assigned to the superpixel neighborhoods to reduce the influence of the irrelevant image elements on the sparse representation results, and a weighted sparse representation model is constructed on the spatial-spectral dictionary to obtain the classification results. The simulation results on Indian Pines and Salinas datasets show that the accuracy of the proposed algorithm is higher than that of traditional algorithms such as K-Nearest Neighbor (KNN) algorithm, and it has better classification results with fewer samples than current deep learning methods.

Key words image processing; hyperspectral image classification; spatial-spectral dictionary; superpixel; sparse representation