

# 基于邻域相似度的联合稀疏表示的高光谱图像分类算法

李佳逊, 董安国, 沈亚栋, 张蓓

长安大学理学院, 陕西 西安 710064

**摘要** 为了提高基于联合稀疏表示的高光谱图像的分类精度, 提出一种基于邻域相似度联合稀疏表示的分类算法。与传统的联合稀疏表示算法相比, 邻域内不同地物类别的像元对待测像元 P 的影响权重不同, 依据邻域内的像元与像元 P 的相似程度, 设定相似度阈值。通过联合稀疏表示与像元 P 相似度高的像元来确定像元 P 的类别, 然后进一步利用空间信息修正分类算法, 即关联邻近像元的类别, 平滑分类结果。实验结果表明, 基于邻域相似度的联合稀疏表示的分类算法精度更高, 结果更稳定。

**关键词** 图像处理; 高光谱图像; 图像分类; 联合稀疏表示; 邻域相似度

中图分类号 TP751 文献标识码 A

doi: 10.3788/LOP54.122803

## Hyperspectral Image Classification Algorithm Based on Joint Sparse Representation of Neighborhood Similarity

Li Jiaxun, Dong Anguo, Shen Yadong, Zhang Bei

School of Science, Chang'an University, Xi'an, Shaanxi, 710064, China

**Abstract** In order to improve classification accuracy of hyperspectral image based on the joint sparse representation, we propose a classification algorithm based on neighborhood similarity. Compared with conventional joint sparse representation algorithm, the weight of different feature categories pixels to pixel P to be test in neighborhood is different. Similarity threshold can be set based on the similarity of all pixels in neighborhood and pixel P. Category of pixel P can be obtained by joint sparse representation pixels which have high similarity with pixel P. And then the spatial information is used to modify classification algorithm, which associates with the categories of the neighboring pixels and gets smooth classification results. Experiment results demonstrate that the proposed algorithm has higher classification accuracy and more stable results.

**Key words** image processing; hyperspectral image; image classification; joint sparse representation; neighborhood similarity

**OCIS codes** 100.4145; 100.3008; 280.4788

## 1 引言

高光谱图像(HSI)<sup>[1]</sup>包含从可见到红外光谱区域的数百个狭窄且连续波段的光谱信息和空间信息。HSI中的每个像元都可以表示为一个高维向量,该向量的每个分量表示对某一波段的光谱反射值。高光谱图像含有丰富的光谱信息,可用于解决确定地物类别这一难题。基于这种优势,高光谱遥感技术已广泛应用于环境监测、地质勘探、灾害评估、军事侦察、目标识别等领域<sup>[2]</sup>。

高光谱图像的分类<sup>[3]</sup>是依据光谱特性的不同将像元分类。常见的地物分类算法有:神经网络

收稿日期: 2017-05-16; 收到修改稿日期: 2017-06-15

基金项目: 国家自然科学基金(41571346, 41601437, 11201038)

作者简介: 李佳逊(1993—),女,硕士研究生,主要从事高光谱图像处理方面的研究。E-mail: 15637793688@163.com

导师简介: 董安国(1964—),男,教授,硕士生导师,主要从事数值代数、数字图像处理等方面的研究。

E-mail: donganguo@chd.edu.cn

(ANN)<sup>[4]</sup>、支持向量积(SVM)<sup>[5-6]</sup>、最邻近分类(KNN)<sup>[7]</sup>和稀疏表示模型(SR)<sup>[8]</sup>等。ANN算法对初始值的依赖很大,不同的初始值会得到不同的分类效果。SVM算法虽然能够解决神经网络难以解决的小样本和高维数据分类问题,但是对数据存储空间要求高。KNN算法则是根据训练样本中  $K$  个与待测像元最接近的像元确定类别。而SR算法中每个像元都用稀疏向量表示,计算像元和各类训练样本的最小残差,确定待测像元类别。这些算法都只考虑像元的光谱信息,没有分析像元的空间关系。Chen等<sup>[9]</sup>利用空间相邻的像元地物类别具有一致性的特点,提出了联合稀疏表示模型(JSR),该模型通过邻域内所有像元确定待测像元的类别,但地物种类丰富时,容易出现错分现象。王佳宁<sup>[10]</sup>在进行联合稀疏表示之前加入高光谱图像的主成分分析,提取其形态学特征,进而对局部空间区域新特征像元进行联合稀疏表示,有效提高了分类精度。为了充分利用稀疏表示分类算法中重构残差包含的特征信息,陈善学等<sup>[11]</sup>提出了基于紧耦合像元的自适应增强类内稀疏表示分类算法,将自适应增强算法融入正交匹配追踪算法<sup>[12]</sup>,增强待测像元稀疏特征的提取,提高高光谱图像的分类精度和稳定性。

为了提高高光谱图像的分类精度,本文提出一种基于邻域相似度的联合稀疏表示的分类算法。

## 2 联合稀疏表示模型

在高光谱图像中,相邻的像元极有可能属于同一类地物<sup>[13]</sup>,可以加入空间邻域信息,使邻域内的所有像元共用同一个稀疏表示模型,即联合稀疏表示模型。该模型中待测像元的类别由待测像元及邻域内其他像元共同决定。设地物类别总数为  $C$ ,训练样本总个数为  $N$ ,记  $S = \{1, \dots, C\}$ ,  $S = S_1 + S_2 + \dots + S_C$ ,其中  $S_c$  为第  $c$  类训练样本 ( $c=1, \dots, C$ )。设  $d_i$  为第  $i$  个训练样本的光谱向量 ( $i \in S$ ),训练样本集  $D = \{d_1, d_2, \dots, d_N\}$ 。设  $X = \{x_1, x_2, \dots, x_T\}$  为当前待分类像元邻域内的像元集 ( $T$  为邻域内像元总个数),  $x_1$  为邻域中心的像元,关于像元集  $X$  的联合稀疏表示模型<sup>[14]</sup>如下:

$$\hat{A} = \arg \min_A \|X - DA\|_F, \text{ s.t. } \|A\|_{\text{row},0} \leq K, \quad (1)$$

式中  $A = \{\alpha_1, \alpha_2, \dots, \alpha_T\}$ ,  $\alpha_j$  为  $X$  中第  $j$  个像元的稀疏向量 ( $j=1, 2, \dots, T$ ),  $\|*\|_F$  表示取  $F$  范数, s.t. 表示约束条件,  $\|A\|_{\text{row},0}$  表示稀疏矩阵中非零行的个数,  $K$  为稀疏度。

求得稀疏矩阵  $\hat{A}$  后,待测像元  $x_1$  的地物类别由与各类训练样本的最小残差<sup>[15]</sup>区分出来,

$$f_{\text{class}}(x_1) = \arg \min_{c=1,2,\dots,C} r_c(X), \quad (2)$$

式中像元集  $X$  被第  $c$  类训练样本表示的残差

$$r_c(X) = \|X - D_{S_c} \hat{A}_{S_c}\|_F, \quad (3)$$

其中  $D_{S_c}$  和  $\hat{A}_{S_c}$  分别为  $D$  中取下标集  $S_c$  列及  $\hat{A}$  中取下标集  $S_c$  行所得矩阵。

## 3 基于邻域相似度的联合稀疏表示分类算法

在实际的地物情况中,邻域内的地物往往会存在多种类别,若在地物种类复杂区域直接进行联合稀疏表示,错分的概率很高。因此提出在待测像元的邻域内所有像元中,选择与待测像元相似度高的像元,构建不规则的邻域窗口,再用JSR模型分析待测像元的地物类别。

高光谱图像包含了丰富的光谱信息,且不同类别的地物对同一波段的光谱响应不同,可以通过计算像元光谱向量间的欧氏距离来判断像元间的相似程度。对于待测像元  $x_1$  的像元集  $X = [x_1, x_2, \dots, x_T]$ , 两个像元  $x_1, x_j$  ( $j=2, \dots, T$ ) 的相似度为

$$g(x_1, x_j) = \exp[-\lambda \times s(x_1, x_j)], \quad (4)$$

式中  $\lambda$  为空间距离因子,用来衡量不同像元之间的相互影响程度。通过调整  $\lambda$  的大小来调整邻近像元对中心像元的影响程度。像元  $x_1, x_j$  之间的光谱距离定义为

$$s(x_1, x_j) = |x_1 - x_j|^2. \quad (5)$$

相似度量度和距离度量相反,距离越小,相似度越大;反之,距离越大,相似度越小。设定相似度阈值  $\tau$ , 当相似度大于  $\tau$  时,像元的光谱相似度较高,尤其对于边界区域的像元,其邻域内的像元类别复杂。JSR算法假定邻域内各像元对中心像元的影响权重相同,在分类时必定对分类结果产生影响,因此选择邻域内与中

心像元相似度高的像元就显得尤为重要。构建联合稀疏表示模型时选择像元集的算法流程如图 1 所示。

选择像元集  $\hat{\mathbf{X}}$ , 接着对  $\hat{\mathbf{X}}$  进行联合稀疏表示, 根据最小重构残差准则确定中心像元  $\mathbf{x}_1$  的类别。

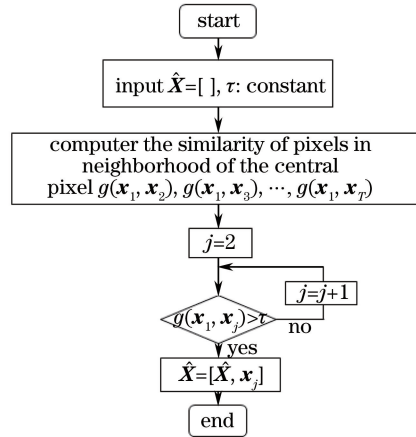


图 1 基于联合稀疏表示模型的像元集选择算法流程图

Fig. 1 Pixel set selecting algorithm flow chart based on joint sparse representation model

在采集高光谱图像光谱信息过程中往往受到噪声等影响而存在误差, 同谱异类、异谱同类等问题难以避免。分类之后仍会存在一些离散分错点, 因此还需利用邻域的空间信息, 关联图像中邻近像元的类别, 计算邻域像元集  $\hat{\mathbf{X}}$  到中心像元  $\mathbf{x}_1$  的空间距离权重向量  $\mathbf{W} = \{\tau_{\omega_j}\}^T$ ,  $\tau_{\omega_j} = [1 + d(\mathbf{x}_j, \mathbf{x}_1)]^{-1}$  表示像元  $\mathbf{x}_j$  到中心像元  $\mathbf{x}_1$  的空间距离权重, 其中  $d(\mathbf{x}_j, \mathbf{x}_1)$  为像元  $\mathbf{x}_1, \mathbf{x}_j$  的归一化空间距离。采用邻域投票的方式计算第  $c$  类的距离权重之和  $N(c) = \sum_{(j | f_{\text{class}}(\mathbf{x}_j) = c)} \tau_{\omega_j}$ , 用邻域内空间距离权重之和最大的类别代替中心像元的地物类别。

基于相似度筛选和邻域投票的算法(NSJSR)算法步骤如下:

1) 将高光谱图像数据归一化, 计算邻域像元  $\mathbf{x}_2, \mathbf{x}_3, \dots, \mathbf{x}_T$  与待测样本  $\mathbf{x}_1$  的相似程度, 将相似度达到阈值的像元选入像元集  $\hat{\mathbf{X}}$ , 即: 若  $g(\mathbf{x}_1, \mathbf{x}_j) > \tau (j=2, 3, \dots, T)$ , 则  $\mathbf{x}_j \in \hat{\mathbf{X}}$ ; 若  $g(\mathbf{x}_1, \mathbf{x}_j) \leq \tau$ , 则  $\mathbf{x}_j \notin \hat{\mathbf{X}}$ ;

2) 选取训练样本  $\mathbf{D} = [\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_N]$ , 其余样本作为测试样本, 迭代次数(稀疏度)为  $K$ , 迭代初始值  $k=1$ , 初始残差  $\mathbf{R}_0 = \hat{\mathbf{X}}$ ;

3) 确定与残差最接近的原子  $\lambda_k = \arg \min_{i=1, 2, \dots, N} \|\mathbf{R}_{k-1}^T \mathbf{d}_i\|_F$ , 更新索引集  $\Lambda_k = \Lambda_{k-1} \cup \lambda_k$ ; 更新残差  $\mathbf{R}_k = \hat{\mathbf{X}} - \mathbf{D}_{\Lambda_k} [(\mathbf{D}_{\Lambda_k}^T \mathbf{D}_{\Lambda_k})^{-1} \mathbf{D}_{\Lambda_k}^T \hat{\mathbf{X}}]$ ,  $\mathbf{D}_{\Lambda_k}$  为字典中索引集所在位置的训练样本;

4) 如果迭代次数  $k > K$ , 求得稀疏矩阵  $\hat{\mathbf{A}} = \mathbf{D}_{\Lambda_k} [(\mathbf{D}_{\Lambda_k}^T \mathbf{D}_{\Lambda_k})^{-1} \mathbf{D}_{\Lambda_k}^T \hat{\mathbf{X}}]$ ; 否则, 更新迭代次数  $k = k + 1$ , 转步骤 3);

5) 计算像元集  $\hat{\mathbf{X}}$  被第  $c$  类训练样本表示的重构残差  $r_c(\hat{\mathbf{X}}) = \|\hat{\mathbf{X}} - \mathbf{D}_{S_c} \hat{\mathbf{A}}_{S_c}\|_F$ , 确定中心像元  $\mathbf{x}_1$  的类别  $f_{\text{class}}(\mathbf{x}_1) = \arg \min_{c=1, 2, \dots, C} r_c(\hat{\mathbf{X}})$ ;

6) 计算邻域像元集  $\hat{\mathbf{X}}$  中所有像元到中心像元  $\mathbf{x}_1$  的空间距离权重向量  $\mathbf{W} = \{\tau_{\omega_j}\}^T$ , 以及邻域内第  $c$  类的距离权重之和  $N(c)$ ;

7) 确定中心像元  $\mathbf{x}_1$  的地物类别  $f_{\text{class}}(\mathbf{x}_1) = \arg \max_{c=1, \dots, C} [N(c)]$ 。

## 4 实验

实验采用 Indianpines 和 Pavia U 地区两组遥感图像数据集, 通过 6 组对比实验验证本文算法的有效性。算法 1 为 SVM 算法; 算法 2 为正交匹配追踪算法(OMP); 算法 3 为多尺度自适应稀疏表示(MASR); 算法 4 为同步正交匹配追踪算法(SOMP); 算法 5 为文中提出的进行相似度筛选, 未进行邻域投票(NSJSR-WNV)的算法; 算法 6 为基于相似度筛选和邻域投票的算法。

文中对比了分类总精度(OA)、KAPPA 系数<sup>[16]</sup>以及变异系数(CV)3 个指标。每组实验均运行 10 次并

对分类精度取平均值。

**实验 1** Indian pines 地区高光谱遥感图像。图像大小为  $145 \text{ pixel} \times 145 \text{ pixel}$ , 空间分辨率为  $20 \text{ m}$ , 谱间分辨率为  $10 \text{ nm}$ , 谱段范围为  $0.4 \sim 2.5 \mu\text{m}$ 。除去原始 220 个波段中的 20 个水汽吸收和低信噪比波段后, 选取剩余的 200 个波段作为研究对象。Indian pines 地区的伪彩色图 and 实际地物图如图 2 所示。

**实验 2** Pavia U 地区高光谱遥感图像。图像大小为  $610 \text{ pixel} \times 340 \text{ pixel}$ , 空间分辨率为  $1.3 \text{ m}$ , 谱段范围为  $0.43 \sim 0.86 \mu\text{m}$ 。除去原始的 115 个波段中的 12 个低信噪比波段后, 选取剩余的 103 个波段作为研究对象。Pavia U 地区的伪彩色图 and 实际地物图如图 3 所示。




图 2 Indian pines 地区的(a)伪彩色图和(b)实际地物图

Fig. 2 (a) Pseudocolor image and (b) real ground map of Indian pines dataset

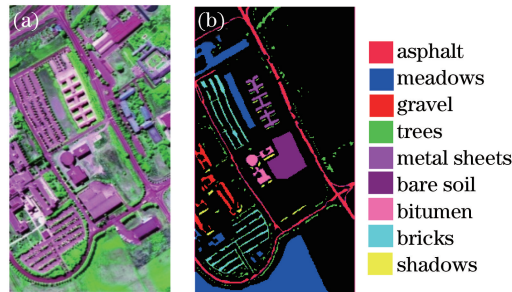


图 3 Pavia U 地区的(a)伪彩色图和(b)实际地物图

Fig. 3 (a) Pseudocolor image and (b) real ground map of Pavia U dataset

#### 4.1 最优邻域空间和相似度阈值

为确定最优邻域空间和相似度阈值  $\tau$ , 分别选取邻域空间  $3 \times 3, 5 \times 5, 7 \times 7, 9 \times 9, 11 \times 11, 13 \times 13, 15 \times 15, 17 \times 17$  和相似度阈值  $\tau = 0.75, 0.80, 0.85, 0.90, 0.95$  进行实验。实验结果如图 4 所示。




图 4 邻域空间和相似度阈值  $\tau$  对分类精度的影响。(a) Indian pines; (b) Pavia U

Fig. 4 Influence of neighborhood scales and similarity threshold on classification accuracy. (a) Indian pines; (b) Pavia U

1) 由图 4(a)可知, Indian pines 地区邻域空间为  $7 \times 7$  且  $\tau = 0.85$  时精度最优。随着邻域空间的增大, 分类精度提高, 在邻域空间  $7 \times 7$  时精度最优; 当邻域空间超过  $7 \times 7$  时, 分类精度随着邻域空间的增大而降低。  $\tau = 0.85$  时分类精度最优, 当阈值低于或超过 0.85 时, 分类精度随着阈值的减小或增大而降低。

2) 由图 4(b)可知, Pavia U 地区邻域空间为  $9 \times 9$  且  $\tau = 0.85$  时精度最优。随着邻域空间的增大, 分类



精度有所提高,在邻域空间  $9 \times 9$  时精度最优;当邻域空间超过  $9 \times 9$  时,分类精度随着邻域空间的增大而降低。 $\tau=0.85$  时分类精度最优,当阈值低于或超过 0.85 时,分类精度随着阈值的减小或增大而降低。

结果表明,合适的邻域空间是该算法的前提,合适的相似度阈值则是关键。图 2、3 中,Indian pines 和 Pavia U 两个地区的区域大小分布不均,因此需要依据实际的地物分布特征来选择窗口大小。过大的邻域窗口有利于噪声的抑制,但对小区域地物分类时,容易错分;窗口过小,对噪声的敏感度降低,且不能有效利用空间特性。阈值选取过低,会使异类地物进入像元集,导致分类误差变大;阈值选取过高,会筛除同类地物,仅留下少部分样本进入像元集,影响分类结果。

## 4.2 分类结果

Indian pines 地区包含 16 类地物,实验从选出的样本数据集中随机抽取每类样本的 10% 作为训练样本,其余的 90% 作为测试样本。图 5 为各算法的实验结果,邻域空间为  $7 \times 7$ ,相似度阈值  $\tau=0.85$ 。Pavia U 地区包含 9 类地物,各类样本个数相差较大,若按比例抽取,样本少的地物会被样本多的地物表示。因此,实验从选出的样本数据集中随机抽取每类样本的 250 个像元作为训练样本,其余像元作为测试样本,且总的训练样本个数仍不超过总样本的 10%。图 6 为各算法的实验结果,邻域空间为  $9 \times 9$ ,相似度阈值  $\tau=0.85$ 。

从图 5 可知,(a)~(d)分错点很多,且边界处不容易区分;(e)、(f)分错点减少,且边界处的区分效果良好。对比(d)、(e)、(f),白色方框区域是 SOMP 算法、NSJSR-WNV 算法以及 NSJSR 算法分类效果逐步改善的地物,离散的分错点依次减少;(f)边界处的区分效果最为明显,尤其在 corn-M、soybeans-C 以及 oats 3 类地物的边界处取得了很好的分类效果。

从图 6 可知,(a)~(d)中 Asphalt 和 Bricks 是容易混淆的两类地物,都会出现 bare soil 错分为 Meadows 的问题;(e)、(f)离散分错点减少,边界处的区分效果良好。对比(d)、(e)、(f),白色方框区域 bricks、bare soil 和 meadows 3 类地区的分类效果也在逐步改善,(f)分错点很少,边界处的区分效果最为明显。




图 5 Indian pines 地区的分类结果。(a) SVM;(b) OMP;(c) MASR;(d) SOMP;(e) NSJSR-WNV;(f) NSJSR

Fig. 5 Classification results of Indian pines dataset. (a) SVM; (b) OMP; (c) MASR; (d) SOMP; (e) NSJSR-WNV; (f) NSJSR

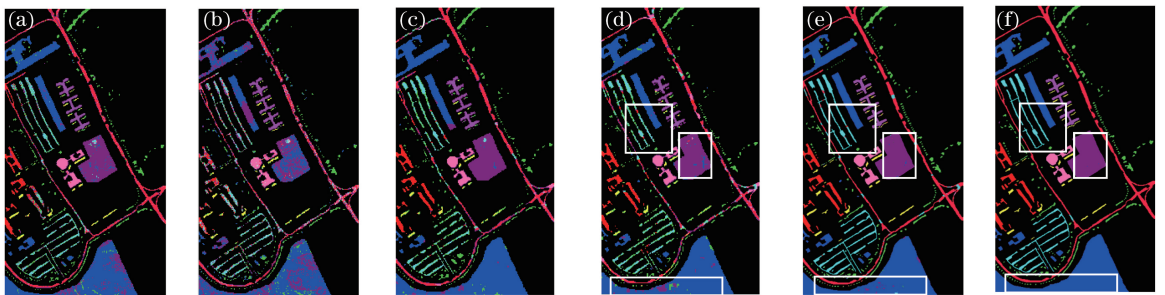


图 6 Pavia U 地区的分类结果。(a) SVM;(b) OMP;(c) MASR;(d) SOMP;(e) NSJSR-WNV;(f) NSJSR

Fig. 6 Classification results of Pavia U dataset. (a) SVM; (b) OMP; (c) MASR; (d) SOMP;

(e) NSJSR-WNV; (f) NSJSR

以 Indian pines 地区为例,表 1 为该地区的实验数据和分类精度,NSJSR 比 SVM 算法总体精度提高 21.37%;比仅使用光谱信息的 OMP 算法提高 38%;比 MASR 算法提高 1.6%;比 SOMP 算法提高 8.13%;比 NSJSR-WNV 算法提高 1.95%。从每类地物的分类精度来看,alfalfa、corn、grass-M、hay-W、wheat、woods 和 buildings 的分类精度达到 100%;grass-P 和 soybeans-N 两类地物分类精度仅次于 MASR 算法;

NSJSR 算法对其他地物的分类精度高于其他的分类算法。grass-P 和 soybeans-N 两类地物分类精度不是最优,原因是邻域内非同类地物相对较多,且光谱向量数值接近,联合稀疏表示过程中容易错分。SOMP、NSJSR-WNV 和 NSJSR 算法的分类精度逐步提高,与图 5 反映的分类结果相吻合。

表 1 Indian pines 地区实验数据和分类精度(括号里的数字为重复实验数值的标准差)

Table 1 Experimental data and classification accuracy of Indian pines dataset (number in parenthesis indicates the standard variance of the repeated experimental value)

Feature	Sample		Classification accuracy of different algorithm /%					
	Train	Test	SVM	OMP	MASR	SOMP	NSJSR-WNV	NSJSR
Alfalfa	5	41	60.98(10.68)	41.86(13.24)	88.83(6.29)	90.93(6.71)	94.36(6.39)	100(0)
Corn-N	143	1285	77.26(2.76)	51.68(5.36)	98.24(1.37)	90.01(3.48)	94.15(2.83)	99.38(1.26)
Corn-M	83	747	60.56(5.12)	46.17(5.21)	97.82(2.06)	88.08(2.87)	96.47(2.15)	99.60(0.97)
Corn	23	214	38.60(4.35)	32.83(5.69)	95.07(2.19)	89.02(3.44)	98.84(2.77)	100(0)
Grass-P	50	433	89.17(2.82)	77.84(4.35)	97.48(1.43)	87.69(3.90)	92.13(3.60)	96.07(1.76)
Grass-T	75	655	96.36(1.37)	92.19(2.29)	99.59(0.95)	90.79(1.30)	97.75(0.97)	99.85(0.45)
Grass-M	3	25	88.00(8.64)	73.85(13.58)	99.29(2.20)	80.08(7.14)	95.27(6.43)	100(0)
Hay-W	49	429	94.91(1.36)	94.58(1.26)	99.96(0.31)	99.14(0.97)	99.48(0.18)	100(0)
Oats	2	18	66.67(8.45)	42.78(9.68)	69.00(8.26)	17.22(17.69)	83.64(11.52)	95.92(4.03)
Soybeans-N	97	875	68.64(3.24)	60.49(4.69)	97.81(1.12)	85.45(2.67)	92.59(2.28)	97.45(1.58)
Soybeans-M	247	2208	77.62(1.96)	68.12(3.38)	98.63(1.32)	93.14(2.78)	99.12(1.09)	99.41(0.23)
Soybean-C	61	532	68.66(4.62)	37.91(5.57)	98.29(1.58)	81.83(3.55)	92.66(3.27)	98.37(3.19)
Wheat	21	184	95.68(1.95)	89.76(4.12)	98.74(0.97)	90.13(1.47)	98.85(0.42)	100(0)
Woods	129	1136	92.60(1.27)	89.25(2.51)	100(0)	98.96(2.28)	98.64(0.64)	100(0)
Buildings	38	348	45.11(7.44)	31.03(7.39)	97.78(0.60)	86.39(0.93)	98.35(0.58)	100(0)
Stone	10	83	91.67(5.93)	90.80(8.49)	95.08(1.48)	89.79(2.95)	96.89(2.31)	97.59(0.23)
OA /%			77.64(1.36)	61.01(3.37)	97.41(0.67)	90.88(1.46)	97.06(0.85)	99.01(0.47)
KAPPA			0.74(1.64)	0.66(3.98)	0.97(0.69)	0.90(1.58)	0.96(1.06)	0.99(0.56)
CV /10 <sup>-2</sup>			1.75	5.52	0.69	1.61	0.88	0.47

### 4.3 稳定性分析

表 1 括号中的数据是 10 次实验的分类精度的标准差,从结果来看,NSJSR 的标准差与其他算法相比较小。标准差反映了分类精度的波动程度,但是在比较各个算法的精度波动大小时,如果仅看标准差,数据的大小有一个相对问题,有时会产生不合理的现象。因此引入变异系数判断各算法的稳定性,变异系数是标准差和均值的比值。对比 6 组实验的变异系数,NSJSR 的变异系数低于其他算法,说明 NSJSR 算法的分类稳定性优于其他算法。

## 5 结 论

基于邻域相似度的联合稀疏表示的分类算法,对局部邻域内的像元进行相似度分析。通过设定相似度阈值,选取与待测像元相似度高的像元联合进行稀疏表示,根据最小残差准则确定待测像元的类别,最后利用邻域投票修正分类结果。实验结果表明,选取合适的邻域空间和相似度阈值,能够提高分类精度,使结果更稳定,同时减少离散错分样本数。

## 参 考 文 献

- [1] Camps-Valls G, Tuia D, Bruzzone L, *et al.* Advances in hyperspectral image classification[J]. IEEE Signal Processing Magazine, 2014, 31(1): 45-54.
  - [2] Li Tie, Sun Jinguang, Zhang Xinjun, *et al.* Research of hyperspectral image classification based on hierarchical sparse representation feature learning[J]. Laser & Optoelectronics Progress, 2016, 53(9): 091001.
- 李铁, 孙劲光, 张新君, 等. 基于分层稀疏表示特征学习的高光谱图像分类研究[J]. 激光与光电子学进展, 2016, 53(9): 091001.

- [3] Tong Q, Xue Y, Zhang L. Progress in hyperspectral remote sensing science and technology in China over the past three decades[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7(1): 70-91.
- [4] Li Y, Xie W, Li H. Hyperspectral image reconstruction by deep convolutional neural network for classification[J]. Pattern Recognition, 2017, 63: 371-383.
- [5] Deng S, Xu Y, He Y, *et al.* A hyperspectral image classification framework and its application[J]. Information Sciences, 2015, 299: 379-393.
- [6] Braun A C, Weidner U, Hinz S. Support vector machines, import vector machines and relevance vector machines for hyperspectral classification-A comparison[C]. 2011 3rd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, 2011: 12386162.
- [7] Huang Hong, Zheng Xinlei. Hyperspectral image classification with combination of weighted spatial-spectral and KNN[J]. Optics and Precision Engineering, 2016, 24(4): 873-881.  
黄鸿, 郑新磊. 加权空-谱与最近邻分类器相结合的高光谱图像分类[J]. 光学精密工程, 2016, 24(4): 873-881.
- [8] Haq Q S U, Shi L, Tao L, *et al.* A I-1-minimization based approach for hyperspectral data classification[C]. International Conference on Advanced Materials in Microwaves and Optics, 2012, 500: 675-681.
- [9] 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.
- [10] Wang Jianing. Hyperspectral image classification based on joint sparse representation and morphological feature extraction[J]. Laser & Optoelectronics Progress, 2016, 53(8): 082801.  
王佳宁. 基于联合稀疏表示与形态特征提取的高光谱图像分类[J]. 激光与光电子学进展, 2016, 53(8): 082801.
- [11] Chen Shanxue, Gui Chengming, Wang Yining. Close coupled set of pixels-based adaptive boosting class-wise sparse representation classifier for robust hyperspectral image classification[J]. Systems Engineering and Electronics, 2017, 39(3): 655-661.  
陈善学, 桂成名, 王一宁. 基于紧耦合像元的自适应增强类内稀疏表示高光谱图像分类[J]. 系统工程与电子技术, 2017, 39(3): 655-661.
- [12] 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.
- [13] Fang L, Li S, Kang X, *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.
- [14] 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.
- [15] Song Lin, Chen Yongmei, Zhao Yongqiang. Hyper-spectrum classification based on sparse representation model and auto-regressive model[J]. Acta Optica Sinica, 2012, 32(3): 0330003.  
宋琳, 程咏梅, 赵永强. 基于稀疏表示模型和自回归模型的高光谱分类[J]. 光学学报, 2012, 32(3): 0330003.
- [16] Du P, Xue Z, Li J, *et al.* Learning discriminative sparse representations for hyperspectral image classification[J]. IEEE Journal of Selected Topics in Signal Processing, 2015, 9(6): 1089-1104.