

基于图正则自适应联合协同表示的高光谱图像分类

李冬青, 程玉虎, 王雪松

引用本文:

李冬青, 程玉虎, 王雪松. 基于图正则自适应联合协同表示的高光谱图像分类[J]. *控制与决策*, 2020, 35(5): 1063–1071.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2018.1159>

您可能感兴趣的其他文章

Articles you may be interested in

[结合多特征和模糊偏好关系的高分辨率遥感影像分割](#)

Combining multi-feature and fuzzy preference relation for high resolution remote sensing image segmentation

控制与决策. 2020, 35(4): 781–790 <https://doi.org/10.13195/j.kzyjc.2018.0676>

[基于子类划分和粒子群优化的自适应编码多类分类方法](#)

Multiclass classification of adaptive error-correcting output codes based on subclass and particle swarm optimization

控制与决策. 2018, 33(2): 211–218 <https://doi.org/10.13195/j.kzyjc.2016.1616>

[一种基于二部图谱划分的聚类集成方法](#)

A cluster ensemble approach based on bipartite spectral graph partitioning

控制与决策. 2018, 33(12): 2208–2212 <https://doi.org/10.13195/j.kzyjc.2017.1010>

[基于认知差异的多机器人协同信息趋向烟羽源搜索方法](#)

Multi-robot collaborative infotaxis searching for plume source based on cognitive differences

控制与决策. 2018, 33(1): 45–52 <https://doi.org/10.13195/j.kzyjc.2016.1421>

[模糊聚类光滑支持向量机](#)

Fuzzy clustering smooth support vector machine

控制与决策. 2017, 32(3): 547–551 <https://doi.org/10.13195/j.kzyjc.2015.1526>

[参数自适应的可变类FLICM灰度图像分割算法](#)

Self-adaptive FLICM algorithm for gray image segmentation with unknown number of clusters

控制与决策. 2017, 32(2): 262–268 <https://doi.org/10.13195/j.kzyjc.2016.0050>

[基于火焰图像显著区域特征学习与分类器融合的回转窑烧结工况识别](#)

Burning state recognition for rotary kiln sintering process based on burning salient zone image feature learning and classifiers fusion

控制与决策. 2017, 32(1): 187–192 <https://doi.org/10.13195/j.kzyjc.2015.1237>

[基于联合特征直方图的均值漂移目标跟踪算法](#)

Mean shift target tracking algorithm based on joint feature histogram

控制与决策. 2016, 31(10): 1845–1852 <https://doi.org/10.13195/j.kzyjc.2015.1291>

基于图正则自适应联合协同表示的高光谱图像分类

李冬青, 程玉虎[†], 王雪松

(中国矿业大学信息与控制工程学院, 江苏 徐州 221116)

摘要: 针对由于空间信息利用不充分而导致的高光谱图像分类精度较低的问题, 提出一种基于图正则自适应联合协同表示的高光谱图像分类算法. 首先, 采用双边滤波操作对高光谱图像进行空间信息提取, 以充分挖掘每个像素的空间信息; 其次, 在联合协同表示的目标函数中引入图正则约束项, 以保持高光谱数据的流形结构; 再次, 一方面利用图像分割来自适应调整空间邻域的形状, 另一方面通过对中心像素的空间近邻赋予不同的权重, 提出一种自适应空间-光谱特征融合策略; 最后, 基于误差最小原则, 给出测试样本的类别标签. 在两个高光谱数据集上的实验结果表明, 所提出算法的整体分类精度分别达到 98.50% 和 97.30%.

关键词: 高光谱图像; 图正则; 联合协同表示; 自适应; 分类

中图分类号: TP18

文献标志码: A

Graph regularized adaptive joint collaborative representation for hyperspectral image classification

LI Dong-qing, CHENG Yu-hu[†], WANG Xue-song

(School of Information and Control Engineering, China University of Mining and Technology, Xuzhou 221116, China)

Abstract: In this paper, a graph regularized adaptive joint collaborative representation algorithm is proposed to overcome a low classification accuracy problem caused by insufficient utilization of spatial information for hyperspectral image classification. Firstly, the bilateral filter is adopted to extract spatial information for hyperspectral image to fully explore the spatial information of each pixel. Then, a graph regularized term is introduced into the objective function of joint collaborative representation to maintain the local manifold structure of hyperspectral image (HSI) data. On one hand, the image segmentation is used to adjust the shape of the spatial neighborhood; on the other hand, an adaptive space-spectral feature fusion strategy is proposed by assigning different weights to the spatial neighbors of the central pixels. Finally, the label of each testing sample is determined by utilizing the least errors criterion. Experimental results on Indian Pines and Pavia University datasets show that overall accuracies of the proposed algorithm can achieve 98.50% and 97.30% respectively.

Keywords: hyperspectral image; graph regularization; joint collaborative representation; adaptive; classification

0 引言

近年来, 基于过完备字典的稀疏表示^[1-2] 已被广泛地应用于信号处理中, 例如: 高光谱图像去噪、解混、降维和分类^[3]. 在高光谱维度高、样本少的情况下, Haq 等^[4] 提出了一种快速鲁棒的稀疏表示分类方法. 在训练样本个数小于特征维数时, 通过引入一个大小为字典元素个数的单位矩阵, 对字典进行扩充, 进而提升稀疏表示能力, 同时在求解稀疏表示矩阵时采用 Homotopy 方法, 使得求解更加快速. 但该稀疏表示方法仅考虑了高光谱的光谱特征, 忽略了高光谱图像空间信息.

对于高光谱图像, 处于空间近邻的像素点, 同属一个类的概率很大. 为了利用高光谱的空间特征, Gu 等^[5] 结合高光谱的空间和光谱信息, 提出了多核稀疏表示. Liu 等^[6] 研究了空间-光谱联合核情形下的稀疏表示. Zhang 等^[7] 结合多特征学习、核学习和联合稀疏表示, 提出了基于加权多特征的核联合稀疏表示. Chen 等^[8] 通过固定窗口大小, 假设处于相同窗口大小邻域的近邻样本可以用相同的字典元素进行稀疏表示, 提出了联合稀疏模型. Zhang 等^[9] 将局部联合稀疏表示应用于高光谱图像融合. Zhang 等^[10] 将非局部加权策略引入联合稀疏表示中, 对不同的空间

收稿日期: 2018-08-29; 修回日期: 2018-12-04.

基金项目: 国家自然科学基金项目(61772532).

责任编辑: 阳春华.

[†]通讯作者. E-mail: chengyuhu@163.com.

近邻赋予不同的权重,提出了非局部加权联合稀疏表示. Zou等^[11]在非局部加权联合稀疏表示的基础上,通过均值漂移算法对高光谱图像进行分割处理,使得局部空间近邻的形状能够自适应调整,提出了自适应的联合稀疏表示. Zhang等^[12]通过均值漂移算法对高光谱图像进行聚类,联合空间和光谱特征,提出了基于聚类组的稀疏编码模型. Liu等^[13]通过在联合稀疏表示中引入图拉普拉斯正则化约束,提出了基于图正则的联合空谱稀疏编码模型,以保持样本间的流形结构.

基于稀疏表示的方法,首先需要充分的训练样本,构成一个过完备字典,进而对测试样本进行稀疏表示,而稀疏表示矩阵是通过求解 L_1 范数最小化得到的,需要很长耗时.为了解决这些问题,很多学者通过转变求解 L_1 范数最小化问题,提出了许多基于协同表示的分类算法. Chen等^[14]在协同表示的基础上考虑了测试样本的局部信息,提出了局部协同表示. Chen等^[15]通过对协同表示系数添加权重约束,提出了多正则化协同表示. Li等^[16]在协同表示的基础上,通过对协同系数进行Tikhonov权重约束,提出了最近邻子空间方法. Li等^[17]将基于Tikhonov正则化的协同表示推广到相应的核情形,提出了基于Tikhonov正则化的核协同表示(kernel collaborative representation with tikhonov regularization). Li等^[18]通过固定窗口大小,对训练和测试样本的近邻取平均值,提出了联合协同表示模型(joint collaborative representation, JCR). Xiong等^[19]在联合协同表示的基础上,通过对近邻赋予不同权重,提出基于加权的联合协同表示(weighted joint collaborative representation, WJCR). Li等^[20]通过将多任务学习与联合协同表示模型相结合,提出了基于多任务学习的联合协同表示. Li等^[21]通过构建一个局部自适应字典,提出了非局部联合协同表示. Li等^[22]在非局部联合协同表示基础上,通过引入核学习,提出了基于核学习的非局部联合协同表示.

然而,上述基于联合协同表示的方法存在3方面不足:1)高光谱图像的空间信息利用不充分;2)协同表示过程中忽略了样本间的流形结构;3)每个中心像素空间近邻的选择范围是固定的,不适合处理位于不同类别边界上的像素.为此,结合双边滤波、图像分割和近邻图的优势,本文提出一种基于图正则的自适应联合协同表示方法.首先提出基于图正则自适应联合协同表示的高光谱图像分类算法;然后通过Indian Pines和Pavia University两个高光谱数据集上

对算法参数进行比较,确定每种算法的最优参数并进行分类性能对比;最后,通过实验结果表明了本文方法的有效性.

1 基于图正则自适应联合协同表示的高光谱图像分类

基于图正则自适应联合协同表示的高光谱图像分类框架(GAJCR-BF)主要分为7个步骤:1)对高光谱数据分波段进行双边滤波处理,以充分挖掘每个像素的空间信息;2)对滤波后的高光谱数据,先使用PCA降维得到了前3个主成分,生成假彩色图,再利用图像分割算法对图像进行分割,得到形状不规则的空间区域块;3)设置窗口大小,对落在自适应空间区域的中心像素进行自适应加权表示;4)从数据集的每个地物中,随机选择固定个数的样本组成训练集,剩下的样本作为测试集;5)计算训练样本间的邻接表示矩阵;6)求每个测试样本在由训练集组成的字典下的基于图正则的联合协同表示系数矩阵;7)确定测试样本的标签.

1.1 高光谱图像滤波

双边滤波是一种非线性滤波器,可以达到保持边缘、降噪平滑的效果.它采用基于高斯分布的加权平均方法,用周边像素的光谱特征加权平均代表中心像素的光谱特征.它的权重设置不但考虑了周围像素位置对中心像素的影响,而且考虑了它们之间的光谱特征的差异,在计算中心像素特征时应同时考虑这两个权重.下式给出了双边滤波的操作:

$$J_p = \frac{1}{k_p} \sum_{q \in \Omega} I_q f(\|p - q\|) g(\|I_p - I_q\|). \quad (1)$$

其中: I 为输入的高光谱图像, p 、 q 为像素在图像中的坐标, I_q 为对应位置的像素值, J_p 为输出, f 、 g 为权重分布函数. J_p 一般为高斯函数,即

$$J_p = \frac{1}{k_p} \sum_{q \in \Omega} I_q \left\{ \exp \left[- \left(\frac{\|p - q\|_2^2}{2\sigma_s^2} + \frac{\|I_p - I_q\|_2^2}{2\sigma_r^2} \right) \right] \right\}, \quad (2)$$

其中 σ_s 、 σ_r 分别为像素的空间特征和光谱特征核参数.这种滤波的结果表明,周边像素的权值设置不仅与空间距离有关,而且还与相应位置的光谱值有关.

1.2 自适应空间-光谱特征融合策略

高光谱图像中,空间邻域中的像素同属一个类别的概率很大.因此,在对高光谱图像进行分类时,充分利用每个像素的空间信息可以提升分类精度.通常采用的策略是,以某个像素为中心,选择固定窗口大

小区域中像素作为近邻, 然后对该区域中所有像素求平均值, 作为中心像素的光谱特征值. 这种平均权重设计方法存在两个方面的缺陷: 1) 窗口大小一旦选定, 近邻区域块的形状便是固定的, 并不适合处于空间边界上的像素点; 2) 对区域内所有像素设置相同的权重, 未能根据距离中心像素的远近自适应调整, 不能更好地表示中心像素. 为了解决上述问题, 本文提出一种自适应空间-光谱特征融合策略. 该策略主要包括两步: 1) 空间区域形状的自适应划分; 2) 权重自适应计算.

为了充分挖掘中心像素的空间信息, 需要满足以下两方面: 1) 空间邻域的形状能够根据周围像素的相似性自适应调整; 2) 在自适应空间邻域内, 距离中心像素越近的像素, 应赋予更大的权重. 如图 1(a) 和图 1(b) 所示, 首先, 对高光谱数据用主成分分析 (principal component analysis, PCA) 降维, 选择前 3 个主成分组成假彩色图像. 其次, 如图 1(b) 和图 1(c) 所示, 使用图像分割算法对假彩色图像进行图像分割, 得到空间邻域自适应调整的区域块. 然后, 设置窗口

大小为 5×5 , 红色圆圈为中心像素, 假设经过图像分割算法处理之后, 绿色圆圈与中心像素属于同一空间区域, 而蓝色圆圈与中心像素属于不同的空间区域. 图 1(f) 表示相邻两块自适应区域在固定窗口大小时得到的局部自适应划分的空间区域. 图 1(g) 表示在自适应空间邻域内, 距离中心像素越近, 即标号越小的像素, 权重设置越大. 为此, 本文设计如下自适应权重方式: 设 x 、 y 表示不规则区域中的两个像素点, 它们的空间坐标分别为 (a, b) 和 (m, n) ; x_i 、 y_i 分别表示对应像素 x 、 y 的第 i 个光谱特征分量, $i = 1, 2, \dots, r$. 则像素 x 、 y 的权重通过如下方式计算:

$$w(x, y) = (1 - \lambda) \frac{1}{d(x, y)} + \lambda s(x, y). \quad (3)$$

其中: $d(x, y) = \sqrt{(a - m)^2 + (b - n)^2}$ 表示像素 x 、 y 的空间坐标的欧氏距离, $s(x, y) = \frac{\sum_{i=1}^r x_i y_i}{\left(\sqrt{\sum_{i=1}^r x_i^2} \times \sqrt{\sum_{i=1}^r y_i^2}\right)}$ 表示像素 x 、 y 的光谱特征的余弦相似度, λ 用于平衡空间和光谱信息的重要性.

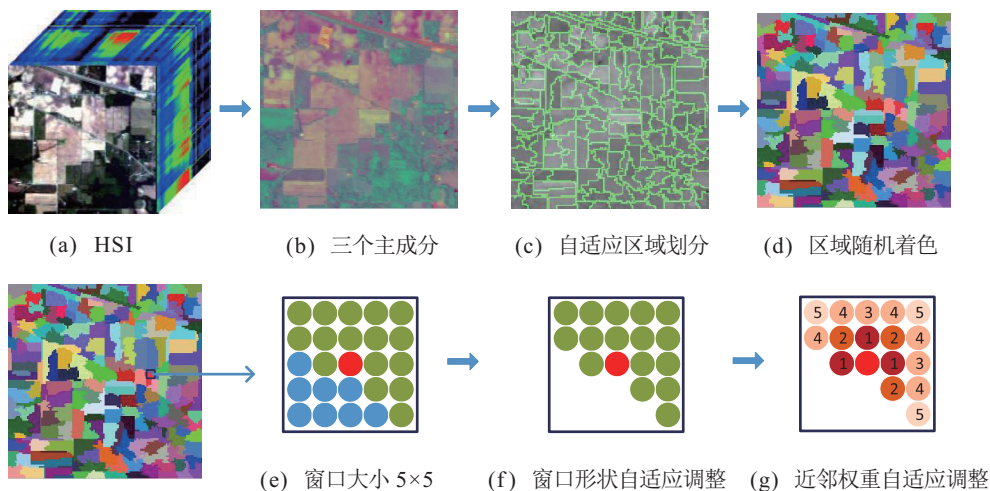


图 1 自适应空间-光谱特征融合策略示意

1.3 联合协同表示

假设高光谱数据 X 被划分成训练集 D 和测试集 T . 训练集包含 c 类, 第 i 类中包含 n_i 个样本. 在协同表示中, 字典元素通常由所有训练样本组成, 即 $D = \{D_1, D_2, \dots, D_c\} \in R^{m \times n}$. 其中: m 表示每个样本的光谱维数; D_i 表示由第 i 类组成的子字典, 即 $D_i = \{x_{i1}, x_{i2}, \dots, x_{in_i}\} \in R^{m \times n_i}$, $\sum_{i=1}^c n_i = n$. 根据协同表示法则, 属于第 i 类的测试样本可以表示为

$$y \approx x_{i1}z_{i1} + x_{i2}z_{i2} + \dots + x_{in}z_{in_i}, \quad (4)$$

其中 $z_{ij} \in R (j = 1, 2, \dots, n_i)$ 是子字典 D_i 中样本 x_{ij} 对应的表示系数.

若字典由所有训练样本组成, 则测试样本 y 可以表示为

$$y = \hat{y} + e = \sum_{i=1}^c \sum_{j=1}^{n_i} x_{ij}z_{ij} + e \approx \sum_{i=1}^c \sum_{j=1}^{n_i} x_{ij}z_{ij} = Dz \in R^m, \quad (5)$$

其中 e 表示由噪声产生的残差. 因此, 协同系数 z 可以通过求解如下带约束的优化问题获得:

$$z^* = \arg \min_z \|z\|_2^2, \quad (6)$$

并使得

$$\|y - Dz\|_2^2 \leq \varepsilon, \quad (7)$$

其中 ε 表示一个小的误差约束. 通过拉格朗日方程转化, 上述问题可以表示为

$$z^* = \arg \min_z \|y - Dz\|_2^2 + \alpha \|z\|_2^2, \quad (8)$$

其中 α 表示正则化参数, 用来平衡残差与系数之间的关系. 得到最优协同系数之后, 测试样本的标签可通过如下表达式确定:

$$\text{Label}(y) = \arg \min_i (\|y - D_i z_i\|_2^2 / \|z_i\|_2^2). \quad (9)$$

上述协同表示中, 样本间是相互独立的. 然而, 对高光光谱像素而言, 它们之间有很强的空间相关性, 即: 空间近邻域中的像素属于同类的概率很大. 为了充分利用高光光谱的空间信息, Li等^[17]提出了联合协同表示模型. 在该模型中, 采用空间平均加权的策略表示每个样本, 即

$$\tilde{z}^* = \arg \min_{\tilde{z}} \|\tilde{y} - \tilde{D}\tilde{z}\|_2^2 + \alpha \|\tilde{z}\|_2^2. \quad (10)$$

其中: $\tilde{y} = \frac{1}{k} \sum_{i=1}^k y_i$ 表示以 y 为中心的空间区域内所有像素的平均值; \tilde{D} 表示原字典 D 中每个像素经过以它为中心的空间区域中所有像素平均加权表示后组成的新字典.

1.4 图正则约束

为了保持近邻的流形结构, 本文在联合协同表示的目标函数中加入图正则约束项, 提出图正则化的联合协同表示模型, 即

$$\begin{aligned} \tilde{z}^* = & \arg \min_{\tilde{z}} \|\tilde{y} - \tilde{D}\tilde{z}\|_2^2 + \alpha \|\tilde{z}\|_2^2 + \frac{\beta}{2} \sum_{i=1}^n \sum_{j=1}^n (\tilde{s}_i - \tilde{s}_j) W_{ij} = \\ & \arg \min_{\tilde{z}} \|\tilde{y} - \tilde{D}\tilde{z}\|_2^2 + \alpha \|\tilde{z}\|_2^2 + \beta \text{tr}(\tilde{z}L\tilde{z}^T). \end{aligned} \quad (11)$$

其中: W_{ij} 表示训练样本 x_i 、 x_j 间的邻接权重, 有

$$W_{ij} = \begin{cases} \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right), & x_i, x_j \text{ 是近邻;} \\ 0, & \text{otherwise.} \end{cases} \quad (12)$$

$L = D - W$ 是Laplacian矩阵, β 为图正则项的协调参数. 上述目标函数具有闭式解

$$\tilde{z} = (\tilde{D}^T \tilde{D} + \alpha I + \beta L)^{-1} \tilde{D}^T \tilde{y}. \quad (13)$$

得到协同系数向量之后, 根据残差最小原理确定测试样本的标签, 即

$$\text{Label}(y) = \arg \min_i (\|\tilde{y} - \tilde{D}_i \tilde{z}_i\|_2^2 / \|\tilde{z}_i\|_2^2). \quad (14)$$

根据上述分析, 给出GAJCR-BF算法描述.

输入: 高光光谱数据集 X , 每个类中训练样本的个数 n_i , 空间窗口大小 S , 协同系数正则化参数 α , 图正

则化参数 β , 空间-光谱信息平衡参数 λ ;

输出: 测试样本的标签.

step 1: 根据式(2), 对高光光谱数据分波段进行双边滤波处理, 充分挖掘每个像素的空间信息.

step 2: 对滤波后的高光谱数据, 首先使用PCA降维, 得到第一主成分, 生成假灰度图; 然后利用均值漂移算法对图像进行分割, 得到形状不规则的空间区域块.

step 3: 设置窗口大小, 对落在自适应空间区域的中心像素进行自适应加权表示, 中心像素周围的空间近邻与中心像素的自适应近邻权重根据式(3)计算.

step 4: 从数据集的每个地物中随机选择 n_i 个样本组成训练集, 剩下的样本作为测试集.

step 5: 根据式(12)计算训练样本间的邻接表示矩阵 W .

step 6: 根据式(13)求每个测试样本在由训练集组成的字典下的联合协同表示系数矩阵.

step 7: 根据式(14)确定测试样本的标签.

2 实验与分析

采用公用的Indian Pines和Pavia University高光光谱数据集来评估GAJCR-BF的性能. 对比算法分为两部分: 一部分未经过双边滤波处理和图约束, 包括: 基于Tikhonov正则化协同表示(CRT), 联合协同表示(JCR), 加权联合协同表示(WJCR)和自适应联合协同表示(AJCR); 另一部分是经过双边滤波和图约束的情况, 包括: 基于双边滤波的图正则协同表示(GCRT-BF), 基于双边滤波的图正则联合协同表示(GJCR-BF), 基于双边滤波的图正则加权协同表示(GWJCR-BF)和基于双边滤波的图正则自适应联合协同表示(GAJCR-BF).

2.1 高光光谱遥感实验数据

Indian Pines高光光谱图像来源于美国的普渡大学1992年拍摄于印第安纳州西北部农业区, 由机载可见光/红外成像光谱仪(AVIRIS)采集. 图2为Indian Pines高光光谱图像的假彩色合成图及真实标记图. 观察区域覆盖145行、145列, 包括220个波段, 空间分辨率为20 m, 光谱范围为0.2 ~ 2.4 μm . 在分类前, 20个光谱波段(即104 ~ 108, 150 ~ 163, 220)由于信噪比低而被丢弃. 此数据集包含16种不同的地物类别.

Pavia University高光光谱图像源于帕维亚大学, 2003年拍摄于意大利的帕维亚城, 由反射光学系统成像光谱仪(ROSIS)采集. 图3为Pavia University高光光谱图像的假彩色合成图及真实标记图. 观察区域




图2 Indian Pines 高光谱数据的假彩色合成图及真实标记图

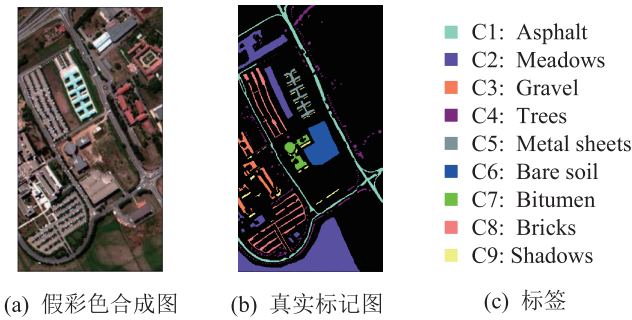


图3 Pavia University 高光谱数据的假彩色合成图及真实标记图

覆盖 610 行、340 列, 包括 115 个波段, 空间分辨率为 1.3 m, 光谱范围为 0.43 ~ 0.86 μm . 在分类前, 12 个光谱波段由于信噪比低而被丢弃. 此数据集包含 9 种不同的地物类别.


2.2 参数分析

根据第 1 节中所阐述: 所有算法会受到协同系数正则化参数 α 影响; JCR、WJCR、AJCR、GJCR-BF、GWJCR-BF 和 GAJCR-BF 六种算法会受到窗口邻域大小 S 的影响; GCRT-BF、GJCR-BF、GWJCR-BF 和 GAJCR-BF 四种算法受到图正则化参数 β 的影响; AJCRT 和 GAJCR-B 受空间-光谱平衡化参数 λ 的影响. 为了评估各个参数对算法分类性能的影响, 设计如下 4 组实验, 进而确定每种算法的最优参数.


2.2.1 协同系数正则化参数 α 对实验的影响

在 Indian Pines 和 Pavia University 高光谱数据集上, 为了对比实验公平性, 窗口大小设置为 5×5 , 图约束正则化参数 $\beta = 10^{-8}$, 空间-光谱信息平衡参数 $\lambda = 0.1$. 两个数据集中, 每类地物中随机选取 50 个样本用作训练. 协同系数正则化参数 α 的变化范围为 $[10^{-10}, \dots, 10^5]$. 图 4 给出了协同系数正则化参数 α 与整体分类精度 (overall accuracy, OA) 之间的关系.

由图 4 可见: 1) JCR、WJCR、AJCR、GCRT-BF、GJCR-BF、GWJCR-BF 和 GAJCR-BF 七种算法随着 α 增大, OA 值先略微上升, 然后下降, 最后趋于稳定; 2) 对于 Indian Pines 和 Pavia University 数据集而言, CRT 算法随着 α 增大, OA 值会先上升, 然后下降, 后续会



(a) Indian Pines



(b) Pavia University

图4 α 与 OA 之间的关系

略微上升.

2.2.2 窗口邻域大小 S 对实验的影响

在 Indian Pines 和 Pavia University 高光谱数据中, 为了对比实验公平性, 协同系数正则化参数 $\alpha = 10^{-3}$, 图约束正则化参数 $\beta = 10^{-8}$, 空间-光谱信息平衡参数 $\lambda = 0.1$. 两个数据集中, 每类地物中随机选取 50 个样本用作训练. 窗口大小 $S = [3 \times 3, 5 \times 5, 7 \times 7, 9 \times 9]$. 图 5 给出了空间窗口大小参数 S 与 OA 之间的关系.

由图 5 可以看出: 1) 对于 Indian Pines 数据集而言, WJCR 随着 S 增大, OA 值先升后降; JCR、AJCR、GJCR-BF、GWJCR-BF 和 GAJCR-BF 五种算法随着 S 增大, OA 值会趋于下降趋势; 2) 对于 Pavia University 数据集而言, JCR、WJCR 和 AJCR 三种算法随着 S 增大, OA 值先升后降; GJCR-BF、GWJCR-BF 和 GAJCR-BF 三种算法随着 S 增大, OA 值会趋于下降趋势; 3) 与其他对比算法比较, GAJCR-BF 在窗口大小固定时, OA 最高.

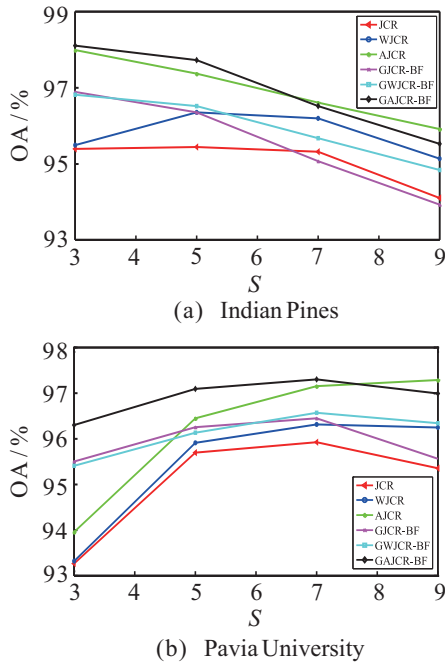


图5 S与OA之间的关系

2.2.3 图正则化参数 β 对实验的影响

在 Indian Pines 和 Pavia University 高光谱数据中, 为了对比实验公平性, 窗口大小设置为 5×5 , 协同系数正则化参数 $\alpha = 10^{-3}$, 空间-光谱相似度平衡参数 $\lambda = 0.1$. 两个数据集中, 每类地物中随机选 50 个样本用作训练. 图约束正则化参数 $\beta = [10^{-10}, \dots, 10^{-4}]$. 图6给出了图正则化参数 β 与 OA 之间的关系.

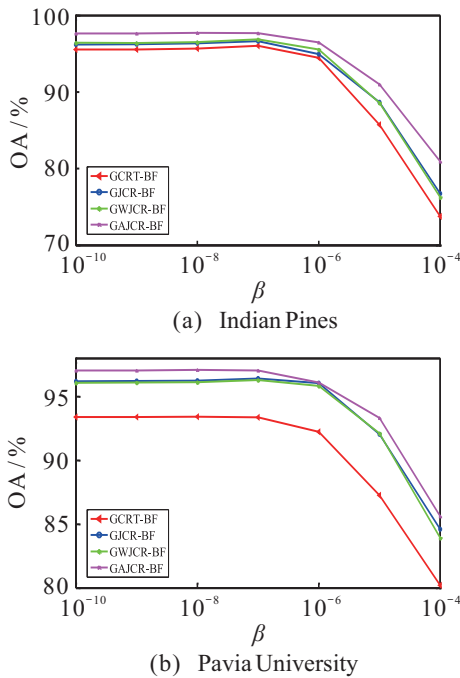


图6 β 与OA之间的关系

由图6可见: 1) GCRT-BF、GJCR-BF、GWJCR-BF 和 GAJCR-BF 四种算法随着 β 增大, OA 值会先保持不变然后趋于下降; 2) 与其他对比算法比较, 在 β 取值选定之后, GAJCR-BF 的 OA 最高.

2.2.4 空间-光谱平衡化参数 λ 对实验的影响

在 Indian Pines 和 Pavia University 高光谱数据中, 为了对比实验公平性, 窗口大小设置为 5×5 , 协同系数正则化参数 $\alpha = 10^{-3}$, 图约束正则化参数 $\beta = 10^{-8}$. 两个数据集中, 每类地物中随机选取 50 个样本用作训练. 空间-光谱平衡参数 $\lambda = [0, 0.1, \dots, 1]$. 图7给出了空间-光谱信息平衡参数 λ 与 OA 之间的关系.

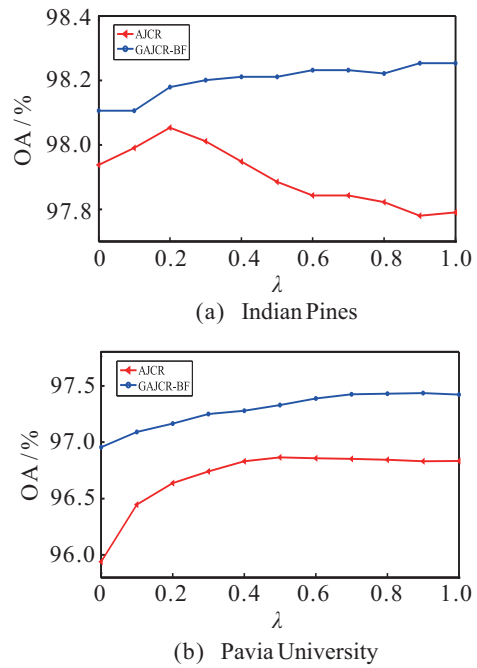


图7 λ 与OA之间的关系

由图7可见: 1) 对于 Indian Pines 高光谱数据集: AJCR 算法随着 λ 增大, OA 值会先上升然后略微下降, 最佳空间-光谱平衡参数 $\lambda = 0.2$; GAJCR-BF 算法随着 λ 增大, OA 值会先上升然后趋于稳定, 最佳空间-光谱平衡参数 $\lambda = 0.9$. 2) 对于 Pavia University 高光谱数据集, AJCR 和 GAJCR-BF 两种算法随着 λ 增大, OA 值会先上升然后趋于稳定, 最佳空间-光谱平衡参数分别是 $\lambda = 0.5$ 和 $\lambda = 0.7$. 3) 与 AJCR 比较, 在 λ 取值选定之后, GAJCR-BF 的 OA 较高.

2.3 实验结果及分析

为公平对比, 根据上述参数分析, 每种对比算法都选择最优参数, 如表1所示. 仿真中, 每个实验均进行 10 次, 取平均值.

首先, 对于 Indian Pines 和 Pavia University 两个数据集, 分别从每类地物中随机选取 50 个高光谱数据作为训练样本进行训练, 剩下样本用于测试. 分别采用 CRT、JCR、WJCR、AJCR、GCRT-BF、GJCR-BF、GWJCR-BF 和 GAJCR-BF 共 8 种算法对 Indian Pines 和 Pavia University 高光谱图像进行分类. 图8给出了

表1 实验参数设置

参数	Indian Pines				Pavia University			
	α	S	β	λ	α	S	β	λ
CRT	10^{-2}	-	-	-	10^{-2}	-	-	-
JCR	10^{-4}	5	-	-	10^{-4}	7	-	-
WJCR	10^{-4}	5	-	-	10^{-4}	7	-	-
AJCR	10^{-3}	3	-	0.2	10^{-4}	9	-	0.5
GCRT-BF	10^{-4}	-	10^{-9}	-	10^{-4}	-	10^{-6}	-
GJCR-BR	10^{-4}	3	10^{-9}	-	10^{-4}	7	10^{-7}	-
GWJCR-BF	10^{-4}	3	10^{-9}	-	10^{-4}	7	10^{-7}	-
GAJCR-BF	10^{-4}	3	10^{-9}	0.9	10^{-4}	7	10^{-6}	0.9

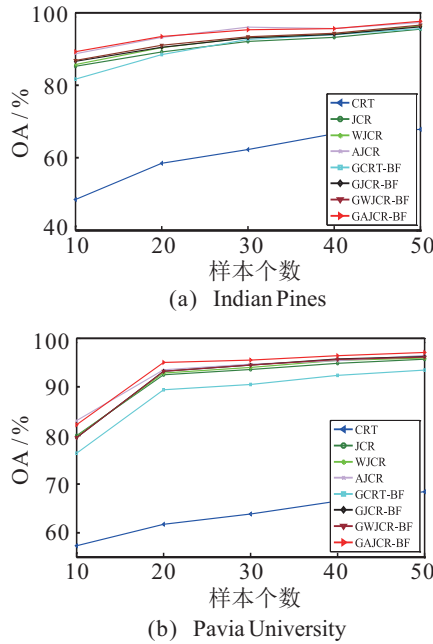


图8 每类地物的训练样本个数与OA之间的关系

表2 分类性能对比 (Indian Pines)

类别 / %	CRT ^[17]	JCR ^[18]	WJCR ^[19]	AJCR	GCRT-BF	GJCR-BR	GWJCR-BF	GAJCR-BF
C1	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0
C2	47.53	95.43	95.50	98.19	96.23	96.52	96.44	98.62
C3	59.23	95.51	95.38	95.51	95.38	96.15	96.15	96.03
C4	76.47	100.0	100.0	100.0	100.0	100.0	100.0	100.0
C5	83.60	97.46	97.23	98.15	97.69	97.23	97.23	97.92
C6	94.56	99.56	99.41	99.85	99.56	99.26	99.26	99.85
C7	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0
C8	94.39	100.0	100.0	100.0	100.0	100.0	100.0	100.0
C9	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0
C10	64.86	96.20	96.10	97.18	96.10	96.20	96.20	98.16
C11	43.91	92.47	92.60	96.17	93.39	96.09	95.84	97.92
C12	62.62	95.58	95.76	96.50	96.13	97.24	96.87	97.05
C13	98.71	100.0	100.0	100.0	100.0	100.0	100.0	100.0
C14	89.30	99.26	99.26	99.84	99.26	99.84	99.84	100.0
C15	63.10	100.0	100.0	100.0	100.0	100.0	100.0	100.0
C16	97.67	100.0	100.0	100.0	100.0	100.0	100.0	100.0
OA / %	64.76	96.20	96.21	97.81	96.57	97.46	97.37	98.50
AA / %	79.75	98.22	98.20	98.84	98.36	98.66	98.62	99.10
Kappa	0.603	0.956	0.957	0.975	0.961	0.971	0.970	0.983

每类地物的训练样本个数与OA的关系. 由图8可得: 1) AJCR和GAJCR-BF所获得的OA高于CRT、JCR、WJCR、GCRT-BF、GJCR-BF、GWJCR-BF, 因为AJCR和GAJCR-BF的空间近邻是自适应选取的, 而且局部近邻的权重同时考虑了空间和光谱信息, 能够获得有效的系数表示, 所以获得的整体分类精度比CRT、JCR、WJCR、GCRT-BF、GJCR-BF和GWJCR-BF要高. 2) 与其他对比算法相比较, 在样本个数较少的情况下, AJCR和GAJCR-BF可以获得较高的OA. 3) 随着样本个数的增加, 各算法所获得的OA都会随之提高.

其次, 评价各种分类算法在高光谱图像Indian Pines和Pavia University上的分类性能指标, 如单个地物的分类精度(%), 平均精度(average accuracy, AA)(%), 整体分类精度(overall accuracy, OA)(%) 和Kappa系数. 从表2和表3可知: 1) GAJCR-BF除少数地物比其他算法低之外, 单个地物的分类精度均高于其他算法; 2) GAJCR-BF所获得的AA, OA和Kappa系数均高于其他分类算法.

最后, 给出各算法在Indian Pines和Pavia University高光谱数据集上的分类效果, 如图9和图10所示. 由图9和图10可以看出, GAJCR-BF的分类效果最好, AJCR次之, CRT较差. 因此, 通过GAJCR-BF分类的效果图更清晰、更平滑, 细节更丰富.

表3 分类性能对比(Pavia University)

类别 / %	CRT ^[17]	JCR ^[18]	WJCR ^[19]	AJCR	GCRT-BF	GJCR-BR	GWJCR-BF	GAJCR-BF
C1	40.95	87.36	87.83	94.26	84.59	88.88	89.01	93.12
C2	71.5	98.91	98.88	98.17	96.25	99.63	99.63	99.76
C3	77.50	96.97	97.12	98.19	96.05	98.34	98.49	97.90
C4	95.55	92.90	93.13	94.19	93.20	92.34	92.63	90.78
C5	99.46	99.92	99.92	99.85	100.0	100.0	100.0	99.85
C6	72.89	99.18	99.16	99.46	97.41	99.38	99.32	100.0
C7	87.03	100.0	100.0	99.30	99.53	100.0	100.0	100.0
C8	45.51	88.35	88.90	91.35	83.78	88.30	87.64	92.43
C9	90.75	94.87	95.54	97.21	93.42	92.75	92.53	94.87
OA / %	68.42	95.70	95.84	96.91	93.43	96.25	96.23	97.30
AA / %	75.68	95.38	95.61	96.52	93.80	95.51	95.47	96.89
Kappa	0.603	0.943	0.945	0.960	0.913	0.950	0.950	0.964

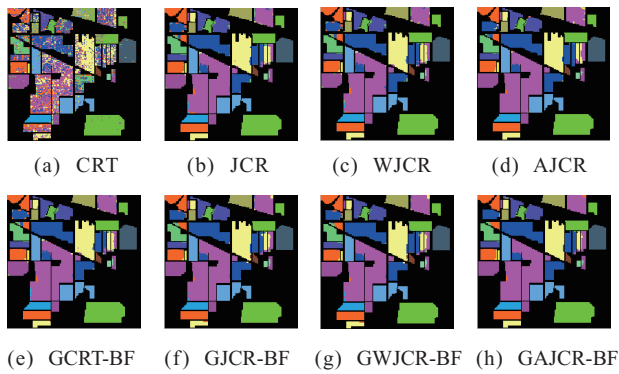


图9 不同算法的分类效果对比(Indian Pines)




图10 不同算法的分类效果对比(Pavia University)

3 结论

结合双边滤波、图像分割和近邻图的优势,本文提出了一种基于图正则自适应联合协同表示的高光谱图像分类算法. 主要贡献如下: 1) 高光谱像素点的空间邻域信息能够得以保持. 通过对高光谱图像波段进行双边滤波,能够很好地利用每个像素周围的

空间信息,降低噪声对光谱特征的影响. 2) 提出了一种自适应空间-光谱特征融合策略. 该策略自适应体现在两个方面: 中心像素近邻空间邻域形状的自适应调整和近邻权重的自适应计算. 中心像素近邻空间邻域形状的自适应调整,能够减少对处于空间邻域边界上异类像素的干扰;近邻权重的自适应计算可以充分保持中心像素的空间近邻信息. 3) 给出了一种图正则联合协同表示. 在联合协同表示过程中增加了图正则项约束,可以保持样本间的近邻结构.

参考文献(References)

- [1] 尹宏鹏, 刘兆栋, 柴毅, 等. 压缩感知综述[J]. 控制与决策, 2013, 28(10): 1441-1445.
(Yin H P, Liu Z D, Chai Y, et al. Survey of compressed sensing[J]. Control and Decision, 2013, 28(10): 1441-1445.)
- [2] 钱彬, 唐振民, 李雪, 等. 基于流形鉴别信息的特征选择及其结构化稀疏表示[J]. 控制与决策, 2016, 31(7): 1272-1278.
(Qian B, Tang Z M, Li X, et al. Feature selection based on manifold discriminant information and its structured sparse representation[J]. Control and Decision, 2016, 31(7): 1272-1278.)
- [3] 高阳, 王雪松, 程玉虎, 等. 基于块非负稀疏重构嵌入的高光谱数据降维[J]. 控制与决策, 2013, 28(8): 1219-1225.
(Gao Y, Wang X S, Cheng Y H, et al. Dimensionality reduction of hyperspectral data based on block non-negative sparsity reconstruction embedding[J]. Control and Decision, 2013, 28(8): 1219-1225.)
- [4] Haq Q S, Tao L, Sun F C, et al. A fast and robust sparse approach for hyperspectral data classification using a few labeled samples[J]. IEEE Transactions on Geoscience and Remote Sensing, 2012, 50(6): 2287-2302.

- [5] Gu Y F, Wang Q W, Xie B Q. Multiple kernel sparse representation for airborne LiDAR data classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(2): 1085-1105.
- [6] Liu J J, Wu Z B, Wei Z H, et al. Spatial-spectral kernel sparse representation for hyperspectral image classification[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2013, 6(6): 2462-2471.
- [7] Zhang E L, Zhang X R, Jiao L C, et al. Weighted multifeature hyperspectral image classification via kernel joint sparse representation[J]. Neurocomputing, 2016, 178(C): 71-86.
- [8] 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.
- [9] Zhang Y H, Prasad S. Multisource geospatial data fusion via local joint sparse representation[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(6): 3265-3276.
- [10] 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(4): 2057-2065.
- [11] Zou J Y, Li W, Huang X, et al. Classification of hyperspectral urban data using adaptive simultaneous orthogonal matching pursuit[J]. Journal of Applied Remote Sensing, 2014, 8(085099): 1-14.
- [12] Zhang X R, Song Q, Gao Z Y, et al. Spectral-spatial feature learning using cluster-based group sparse coding for hyperspectral image classification[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2016, 9(9): 4142-4159.
- [13] Liu C H, Zhou J, Liang J, et al. Exploring structural consistency in graph regularized joint spectral-spatial sparse coding for hyperspectral image classification[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2017, 10(3): 1151-1163.
- [14] Chen J W, Jiao L C. Hyperspectral imagery classification using local collaborative representation[J]. International Journal of Remote Sensing, 2014, 36(3): 734-748.
- [15] Chen X, Li S Y, Peng J T. Hyperspectral imagery classification with multiple regularized collaborative representations[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(7): 1121-1125.
- [16] Li W, Du Q. Joint within-class collaborative representation for hyperspectral image classification[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7(6): 2200-2208.
- [17] Li W, Tramel E W, Prasad S, et al. Nearest regularized subspace for hyperspectral classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(1): 477-489.
- [18] Li W, Du Q, Xiong M M. Kernel collaborative representation with tikhonov regularization for hyperspectral image classification[J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(1): 48-52.
- [19] Xiong M M, Ran Q, Li W, et al. Hyperspectral image classification using weighted joint collaborative representation[J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(6): 1209-1213.
- [20] Li J Y, Zhang H Y, Zhang L P, et al. Joint collaborative representation with multitask learning for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(9): 5923-5936.
- [21] Li J Y, Zhang H Y, Huang Y C, et al. Hyperspectral image classification by nonlocal joint collaborative representation with a locally adaptive dictionary[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(6): 3707-3719.
- [22] Li J Y, Zhang H Y, Zhang L P. Column-generation kernel nonlocal joint collaborative representation for hyperspectral image classification[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2014, 94(10): 25-36.

作者简介

李冬青(1986—), 男, 博士生, 从事高光谱图像处理的研究, E-mail: lidongqingcumt@163.com;

程玉虎(1973—), 男, 教授, 博士生导师, 从事机器学习等研究, E-mail: chengyuhu@163.com;

王雪松(1974—), 女, 教授, 博士生导师, 从事人工智能等研究, E-mail: wangxuesogncumt@163.com.

(责任编辑: 李君玲)