

文章编号 1004-924X(2015)09-2708-07

基于多尺度分割的高光谱图像稀疏表示与分类

唐中奇^{1,2}, 付光远¹, 陈 进³, 张 利²

(1. 第二炮兵工程大学 信息工程系, 陕西 西安 710025;

2. 清华大学 电子工程系, 北京 100084;

3. 北京市遥感信息研究所, 北京 100192)

摘要:针对高光谱特征的稀疏表示,提出了一种基于多尺度分割的空间加权算法用于高光谱图像分类。该算法采用更合理的邻域定义挖掘空间先验信息,优化类边缘像元的稀疏表示。首先,通过多尺度分割提供邻域空间约束;结合拉普拉斯尺度混合(LSM)先验,分别对每个邻域组内像元进行空间加权的稀疏表示。然后,采用概率支持向量机(SVM)分类,同时提供像元的分类标签及其置信度。最后,以此置信度为权重,对多尺度分类图进行加权融合,生成最终的分类图。实验显示,本文算法能够增强光谱特征表示的稀疏性和鲁棒性,提高总体分类精度;在小样本训练下,单类的分类精度可提升 30%左右,表明该算法在高光谱应用中具有较强的实用性。

关键词:高光谱图像分类;光谱稀疏表示;空间先验融合;多尺度策略

中图分类号:TP751 **文献标识码:**A **doi:**10.3788/OPE.20152309.2708

Multiscale segmentation-based sparse coding for hyperspectral image classification

TANG Zhong-qi^{1,2}, FU Guang-yuan¹, CHEN Jin³, ZHANG Li²

(1. *Department of Information Engineering,*

The Second Artillery Engineering University, Xi'an 710025, China;

2. *Department of Electronic Engineering, Tsinghua University, Beijing 100084, China;*

3. *Beijing Institute of Remote Sensing Information, Beijing 100192, China)*

* *Corresponding author, E-mail: tangzql2@mails.tsinghua.edu.cn*

Abstract: For the sparse representation of hyperspectral characteristics, a spatial weighted algorithm based on multiscale segmentation is proposed for hyperspectral classification. The algorithm uses a more reasonable neighborhood definition to mine spatial prior information to optimize the sparse representation of a like-edge pixel. Firstly, spatial neighborhoods were obtained through multiscale segmentation, and Laplacian Scale Mixture, (LSM) priori was then combined for the spatial-weighted sparse representation of pixels in each neighborhood. Then, the probabilistic Support Vector Machine (SVM) was used to classify the hyperspectral images and to provide classification labels and their confidences. Finally, the multiscale segmentation was weighted by the confidence of each label and the classification map was obtained by the fusion of labels. Experiments show that the algorithm enhances

收稿日期:2015-04-27;修订日期:2015-06-01.

基金项目:国家自然科学基金资助项目(No. 61132007, No. 61202332);中国博士后科学基金资助项目(No. 2012M521905)

the sparse and roughness characterized by spectral features and improves the classification accuracy. Under smaller sample training, the classification accuracy of single ground surface has increased by 30%, which verifies the practicability of the proposed algorithm in hyperspectral applications.

Key words: hyperspectral image classification; spectral sparse representation; spatial prior fusion; multiscale scheme

1 引言

高光谱遥感是结合光谱细分和空间成像的一种多维信息获取技术,可以用于识别宽波段遥感中不可探测的物质^[1]。高光谱图像分类在生态监测、地质分析、城市调查以及军事侦察等领域均有重要作用^[2-3]。然而,高光谱在带来更多信息的同时,其应用也面临着更多的挑战。首先,随着光谱分辨率的提升,相邻波段间的相关性增强,存在光谱信息冗余。其次,高维像元和有限标注样本产生的 Hughes 现象也给分类带来了严峻的挑战。另外,随着应用需求的不断提升,涉及了更多复杂场景多尺度目标的识别。因此,对高光谱数据进行高效、准确的压缩表示已成为高光谱分类应用中亟待解决的问题之一^[4-5]。

针对这一问题,涌现了一大批特征选择或特征提取算法。特征选择算法是按照某种准则挑选出少量特征图谱,虽能保留原有的谱通道结构,但却损失了大量的波段信息。特征提取算法是通过某种变换将数据投影到子空间上,然而纯数学的变换容易使高光谱数据丢失其自身的物理意义。鉴于高光谱遥感成像的特点,利用字典学习的稀疏表示已成为高光谱数据压缩表示中的研究热点^[4,6]。一些方法通过固定字典来优化稀疏表示^[7-8],其模型优劣依赖于字典的好坏;另一些方法采用在线的字典学习来取代固定字典,往往能获得更精准的代表模型^[9-11]。Chen 等^[9]采用训练样本组成字典,将测试样本分类为具有最大贡献率的字典元素类别。Charles 等^[10]采用线性支持向量机(Support Vector Machine, SVM)对光谱的稀疏表示向量进行分类。此外,最新的文献中还引入了空间约束的思想^[11]。该思想按照空间邻域关系将像元均匀分组,再对每组元素分别进行稀疏表示,以实现高效、精准的分类。然而,该方法选取 $w \times w$ 的像元块作为邻域组(w 为常数),而对于大多数类边缘像元的表示,这样的邻

域定义往往并不合理,并且也难以适应多尺度目标的分类要求。针对这一弊端,本文提出通过分割来提供更合理的邻域定义,并将这种定义扩展到多尺度,再通过多尺度分类图融合,消除分类结果对尺度的依赖。另外,由于分类器的输出结果可能具有不同的置信度,因此,本文采用概率 SVM 进行分类,在输出像元标签的同时也输出其置信度,再将该置信度作为权值,对多尺度分类结果进行加权投票。

针对复杂高光谱场景内的多尺度目标,本文基于多尺度分割提出了光谱特征的稀疏表示与分类模型。本文所提模型一方面可以更好地融合空间先验信息,优化类边缘像元的稀疏表示,增强地物光谱特征的可分性;另一方面其更灵活的加权投票机制也能够增强分类结果的鲁棒性,从而提升分类精度。

2 基于多尺度分割的稀疏表示与分类

本文提出的总体研究框架如图 1 所示。




图 1 总体研究框架

Fig. 1 Overall framework of proposed method

2.1 多尺度分割

近年来提出了一些可联合空间、光谱信息进行分割的高光谱图像分割算法,如分层图像分割(Hierarchical Image Segmentation, HSEG)、迭代分层图像分割(Recursive HSEG, RHSEG)^[12]等。本文将采用 RHSEG 算法进行多尺度分割,图 2 为其在不同尺度下的分割表现。

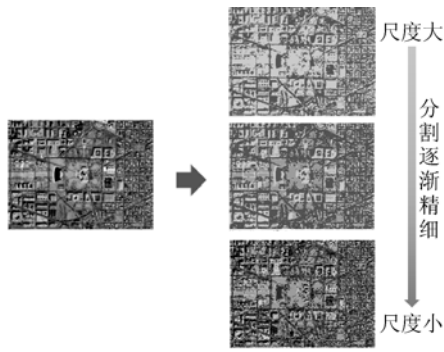


图 2 RHSEG 在不同尺度下的分割表现

Fig. 2 Segmentation performance of RHSEG in different scales

2.2 基于分割的空间加权稀疏表示

根据高光谱像元分解观点可知,原始的光谱响应主要由像元所属地物的反射率决定,同时也受周围像元的地物反射率以及测量噪声(光照强度、光线角度、气溶胶、湿度等)的影响。假设由纯净像元的光谱特征 $d_i \in \mathbb{R}^M$ 构成端元,那么所有感兴趣地物的端元就组成了端元字典 $\mathbf{D} = [d_1, \dots, d_K]$ 。这样,任一像元的原始光谱特征 $\mathbf{x}_i \in \mathbb{R}^M$ 都可以由字典中少量端元的稀疏线性组合表示,如图 3 所示。其中, $\mathbf{y}_i \in \mathbb{R}^K$ 为稀疏表示向量,其各分量系数非负。




图 3 光谱特征稀疏表示

Fig. 3 Sparse representation of spectral feature

由此,可以对高光谱像元的光谱特征建立稀疏表示模型。给定样本训练集 $\mathbf{X} = [x_1, \dots, x_N]$,在稀疏约束下迭代地进行字典学习,可求解像元的稀疏表示向量集 $\mathbf{Y} = [y_1, \dots, y_N]$,初步模型如式(1)所示:

$$\arg \min_{\mathbf{D}, \mathbf{Y}} \frac{1}{2} \|\mathbf{X} - \mathbf{D}\mathbf{Y}\|_F^2 + \lambda \sum_{i=1, N} \|\mathbf{y}_i\|_1. \quad (1)$$

需要注意的是,对于高光谱应用,式(1)中隐含的若干假设仍然存在不合理性。下面将对这些问题进行分析和解决。

2.2.1 LSM 先验加权

初步模型的第一个假设是,字典的各元素是

相互独立的,即不考虑端元之间的相关性。然而,由于端元代表地物的像元光谱特征,在实际情况下,感兴趣地物的类别定义往往具有多层次的特点,不同类别地物的光谱间存在着不容忽视的相关性差异^[13]。对于这一相关性差异,可以通过拉普拉斯尺度混合(Laplacian Scale Mixture, LSM)先验^[14]来描述。在初步模型中加入这一先验,得到最大期望(Expectation Maximization, EM),计算方法如式(2)所示:

$$y^k = \arg \min_y \frac{1}{2} \|x - \mathbf{D}\mathbf{y}\|^2 + \lambda_0 \sum_{j=1; K} \lambda_j^{k-1} |y^{(j)}|, \quad (2)$$

$$\lambda_j^k = \frac{(\alpha+1)}{(\beta + |y^{(j),k}|)},$$

其中: $y^{(j)}$ 为稀疏表示向量的第 j 分量, λ_j 表示该分量相对应字典元素的 LSM 先验系数, λ_0 、 α 、 β 为常量参数, k 为迭代次数。

分析式(2)可知,在 EM 算法的每步迭代中,若稀疏表示向量的某分量 $y^{(j)}$ 较大时,则在 E 步骤中,该分量对应的惩罚因子 λ_j 将缩小,继而在 M 步骤中,该分量将继续增大;若 $y^{(j)}$ 较小,则在 E 步骤中,该分量对应的惩罚因子增大,继而在 M 步骤中,该分量将继续减小。因此,这样的迭代过程可以使稀疏表示向量的大分量得到增强,小分量受到抑制,从而增强表示的稀疏性。

2.2.2 基于分割的分组稀疏表示

在式(1)所示的初步模型中,隐含的另一个假设是各像元的表示向量之间相互独立。然而,由于高光谱图像具有明确的地理学意义,其空间相邻的像元之间往往携带了大量的相关信息。因此,可以将每个空间分割块作为一组,对每组内的像元分别进行稀疏表示。由于组内像元间具有较强的光谱相关性,故可以共用一套 LSM 先验。设经分割得到的空间邻域组为 $G_i (i = 1, \dots, g)$,令 $\mathbf{X}_G = [x_{G,1}, \dots, x_{G,N}]$ 表示每组的样本集, \mathbf{Y}^j 为 \mathbf{Y} 的第 j 行,则改进后的 EM 算法如式(3)所示:

$$\mathbf{Y}_G^k = \arg \min_{\mathbf{Y}} \frac{1}{2} \|\mathbf{X}_G - \mathbf{D}\mathbf{Y}\|_F^2 + \lambda_0 \sum_{j=1; K} \lambda_{G,j}^{k-1} \|\mathbf{Y}_G^j\|_1, \quad (3)$$

$$\lambda_{G,j}^k = \frac{(\alpha + |G|)}{(\beta + \|\mathbf{Y}_G^j\|_1)},$$

其中 $(\cdot)_T$ 代表转置变换。

随着每个邻域组中 EM 算法迭代次数的增多,频繁出现的字典元素所对应的惩罚因子 $\lambda_{G,j}$ 将被抑制,而鲜少出现的字典元素所对应的惩罚因子将被增强,表示向量将逐渐变得稀疏。

由于基于分割的分组为像元的稀疏表示提供

了更合理的空间约束,使得该迭代过程更为精确,从而可以提高表示向量的准确性。

2.3 基于概率 SVM 的标签融合

在得到像元光谱的稀疏表示后,本文采用概率 SVM^[15]对稀疏表示向量进行分类,在输出像元标签的同时,也输出该标签的置信度。以该置信度为权值,对多尺度分类标签进行加权投票,将累计票数最多的标签作为各像元的最终标签。

3 实验与结果分析

由于篇幅所限,以高光谱图像 Indian Pines^[16]为例进行实验,这是一组多类不同生长阶段的农作物和人工建筑混杂的高光谱场景,其中共标注了 16 种尺度不一的感兴趣地物,其类别定义具有多层次的特点。随机选取参考图中 $p\%$ 的像元作为训练集,其余像素用于测试。采用 libsvm^[15]的交叉验证进行分类,每组实验重复 10 次,结果取平均值。图 4 为 Indian Pines 伪彩色图及其参考图。

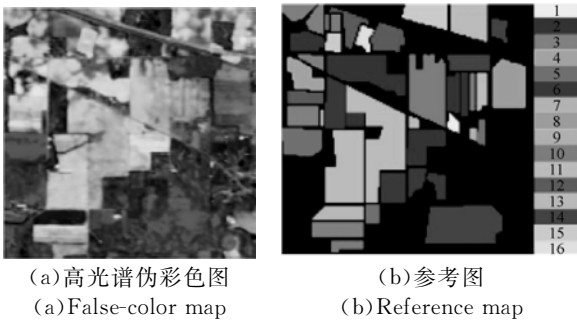


图 4 Indian Pines 实验数据
Fig. 4 Experimental data of Indian Pines

在基于光谱稀疏表示的分类方法中,谱稀疏表示(Spectral Sparse Coding, SSC)^[10]为经典算法;SOMP(Simultaneous Orthogonal Matching Pursuit)算法^[9]在基于联合稀疏表示的分类算法中常有很好的表现;空间权重稀疏表示(Spatially Weighted Sparse Coding, SWSC)^[11]则是现有相关算法中性能最好的算法之一。本文选取这 3 种算法作为对比实验,以验证本文稀疏表示方法的有效性。此外,文中还使用 SVM 对原始光谱特征进行分类,作为另一组对比实验,以验证稀疏表示在高光谱分类应用中的适用性。

3.1 稀疏表示结果

3.1.1 稀疏性验证

图 5 显示了两种方法对不同感兴趣地物的像

元稀疏表示结果,其中,纵轴为稀疏表示的系数编号,横轴为归一化后的稀疏表示系数值。对比 SSC 与本文方法可以看到,本文方法的表示系数主要集中在少量几个轴上,而 SSC 方法的表示稀疏较为分散,这证明了本文方法可以增强表示向量的稀疏性。

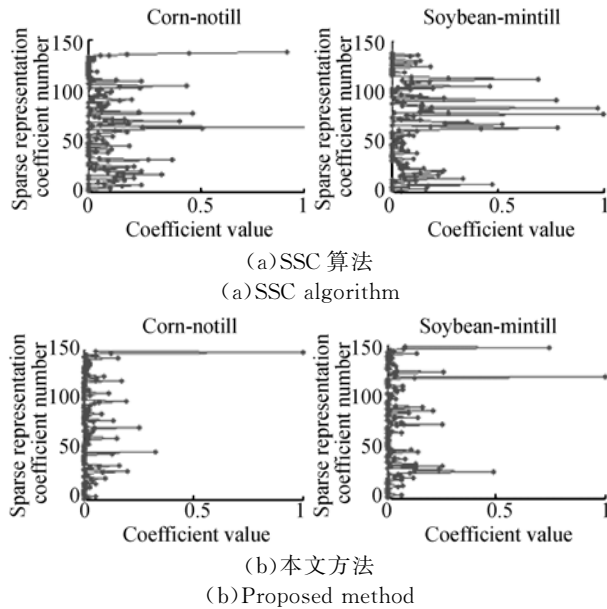


图 5 不同地物像元的稀疏表示

Fig. 5 Sparse representation of different object pixels

3.1.2 基于分割的空间约束对表示的影响

为了验证本文提出的空间约束对稀疏表示的影响,将 SSC、SWSC 方法在均匀分组(取 8×8 邻域,如图 6 所示)下的稀疏表示结果与本文方法的结果进行对比,如图 7 所示。图 7 中,横轴为像元编号(1~64),纵轴为稀疏系数编号,每列代表一个像元的稀疏表示向量,亮度越大,表示其取值越大,全黑的列为背景像元。

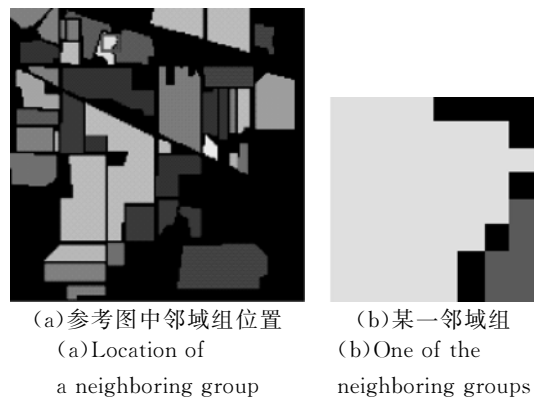


图 6 SWSC 方法中的某一邻域定义

Fig. 6 Definition of neighborhood in SWSC

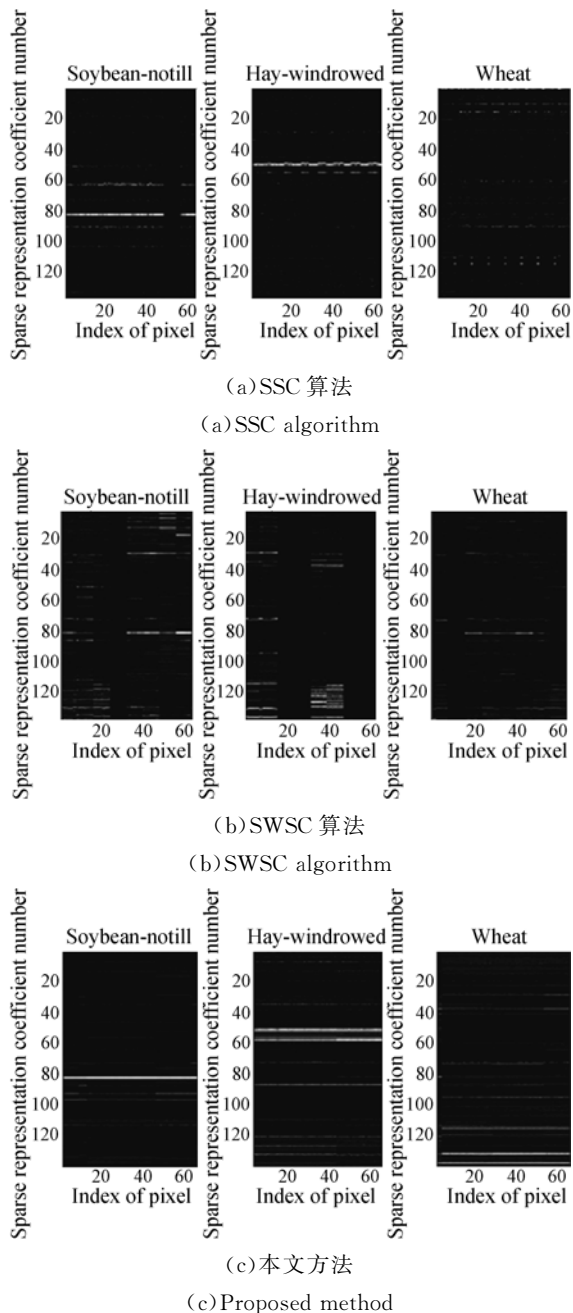


图 7 空间约束对稀疏表示的影响

Fig. 7 Influence of spatial constraint on sparse coding

从图 7 中不难看出,对于中心像元取某一地物的邻域组(图 6 中为地物“Stone-Steel-Towers”的邻域组),SSC 和 SWSC 方法的组内像元表示都出现了不均匀现象,有些邻域组内甚至出现了较为明显的差异,例如图 7(b)中的地物“Hay-windrowed”。这是由于其所定义的邻域组内可能包含了不止一种地物,例如图 6(b)所示。对比 SSC 方法与 SWSC 方法可知,对于所取的邻域组“Soybean-notill”和“Hay-windrowed”,SWSC 方

法的均匀性和稀疏性反而更差,这暴露出 SWSC 的稀疏表示更依赖于邻域定义的弊端。而本文方法却能很好地克服这一弊端,可以看到,在图 7(c)中,3 个邻域组内的表示结果都趋于一致。这一现象说明,基于分割的邻域定义能够使稀疏表示结果更加鲁棒。

3.2 高光谱图像分类结果

3.2.1 分类图与地物分类精度

图 8 为 $p=10$ 时,不同稀疏表示方法的分类图与分类误差。可以看出,SSC 方法的分类误差最多,这是因为该方法中仅利用了光谱信息,而未考虑空间信息。相比之下,SOMP 和 SWSC 由于融入了空间信息,分类误差有所减少。相比 SWSC 方法,本文方法的分类误差进一步减少,这是由于基于多尺度分割的空间约束提供了更为合理的邻域定义,使表示特征更加鲁棒,更利于分类。

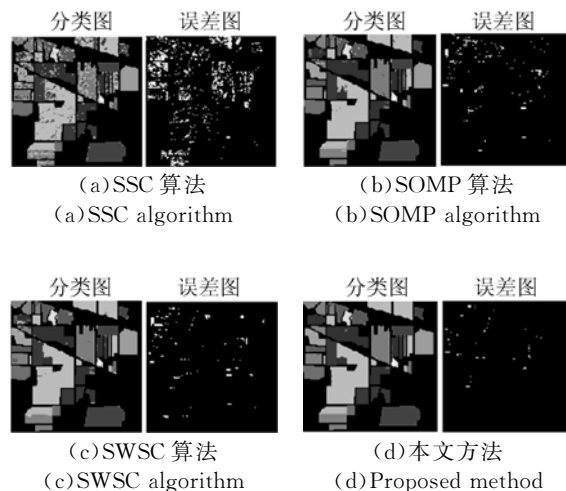


图 8 分类图及其误差

Fig. 8 Classification maps and errors

表 1 记录了相同实验条件下几种方法对各类地物的分类精度,以及 3 个综合性分类评价指标^[13]:总体分类精度(Overall Accuracy, OA)、平均分类精度(Average Accuracy, AA)和 kappa 系数(κ)。其中,划线部分标出了每行中的最优结果。可见,SWSC 和本文方法的分类精度普遍高于 SSC、SOMP 方法。相比 SWSC 方法,本文方法的地物分类精度更加均衡。例如第 1 类地物,由于此类地物在参考图中分布较少,所取的训练集也更加稀少,SWSC 的分类精度仅为 66.67%,而本文方法提升了 30% 左右。这说明本文方法

对于小样本训练具有较明显的优势。此外,从综合性指标的评价也可以看到,本文方法优于其他几类方法。

表1 各类地物分类精度

Tab.1 Classification accuracy of a various of classes objects (%)

类别	SSC	SOMP	SWSC	本文方法
1	68.75	72.92	66.67	<u>97.62</u>
2	73.57	78.37	<u>95.35</u>	95.20
3	74.27	58.13	98.13	<u>99.25</u>
4	52.86	69.05	93.33	<u>94.62</u>
5	91.95	79.64	<u>98.21</u>	96.98
6	92.86	98.96	98.36	<u>99.50</u>
7	39.13	30.43	<u>100</u>	<u>100</u>
8	97.50	99.77	<u>100</u>	<u>100</u>
9	61.11	44.44	<u>100</u>	<u>100</u>
10	73.36	56.95	<u>97.82</u>	97.67
11	74.47	87.75	99.19	<u>99.70</u>
12	80.25	66.49	94.57	<u>96.53</u>
13	96.84	100	<u>99.47</u>	98.21
14	93.38	99.48	99.05	<u>99.71</u>
15	60.53	68.13	<u>100</u>	<u>100</u>
16	92.94	98.82	<u>100</u>	97.33
OA	79.66	81.29	97.83	<u>98.37</u>
AA	76.49	75.58	96.26	<u>98.27</u>
κ	76.88	78.47	97.53	<u>98.14</u>

3.2.2 分类性能比较

图9显示了在不同的训练集比例下几种方法的总体分类精度。

对比原始特征方法与稀疏表示方法可以看到,几种稀疏表示方法除了SSC方法效果略差外,其他方法的分类结果均优于直接使用原始特征分类的方法。这证明了稀疏表示对于高光谱图像分析的适用性。对比SOMP、SWSC、本文方法与其他两类方法的分类性能曲线可发现,前3种方法的分类精度更高,这是由于这3种方法大多

利用了空间先验信息,能够增强光谱特征的鲁棒性。相比SOMP方法,本文方法和SWSC方法在小样本训练下分类精度更高,如 $p < 10$ 时的分类曲线所示。这证明了基于空间约束的稀疏表示方法的有效性。此外,由于本文方法提供了更为合理的空间约束,其总体分类性能普遍优于SWSC方法,在多类方法中也取得了最佳的分类结果。

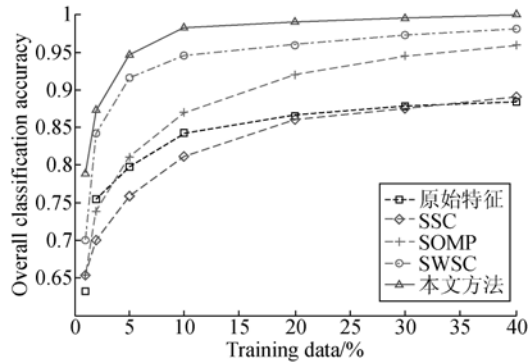


图9 训练集大小对分类的影响

Fig.9 Influence of training set size on classification

4 结论

根据高光谱图像遥感成像的特点,本文提出了一种基于多尺度分割的光谱稀疏表示与分类算法。针对实际应用中的目标往往具有多尺度边缘复杂,并且感兴趣地物的定义通常带有主观性,地物类别呈现多层次化,容易出现类内差异大、类间差异小等问题,本文采用更合理的邻域定义挖掘空间先验信息,使空间信息的融合方式更加灵活,类边缘像元的特征表示得到改善。实验结果表明,相比其他算法,本文算法的光谱表示向量具有更强的稀疏性,对于同类地物表示具有更强的鲁棒性,从而能够提升总体分类精度。另外,本文算法在小样本训练下也能得到较好的分类结果,对某些由于训练集有限而导致分类困难的地物,可使其分类精度提升30%左右,证明了本文算法在高光谱应用中具有较强的实用性。

参考文献:

[1] CAMPS-VALLS G, TUIA D L, BRUZZONE J. Atli-Benediktsson. Advances in hyperspectral image classification [J]. *IEEE Signal Process*, 2014, 21(4):45-54.

[2] 李志敏, 张杰, 黄鸿, 等. 面向高光谱图像分类的半监督丛流形学习[J]. *光学精密工程*, 2015, 23(5):1434-1442.
LI ZH M, ZHANG J, HUANG H, et al.. Semi-supervised bundle manifold learning for hyperspectral image classification [J]. *Opt. Precision Eng.*,

- 2015, 23(5):1434-1442. (in Chinese)
- [3] 何勇, 陈纳, 刘飞, 等. 近红外高光谱成像技术快速鉴别国产咖啡豆品种[J]. 光学精密工程, 2015, 23(2):349-355.
- HE Y, CHEN N, LIU F, *et al.*. Rapid identification of coffee bean variety by near infrared hyperspectral imaging technology [J]. *Opt. Precision Eng.*, 2015, 23(2):349-355. (in Chinese)
- [4] BIOUCAS-DIAS J, PLAZA A, CAMPS-VALLS G, *et al.*. Hyperspectral remote sensing data analysis and future challenges [J]. *IEEE Remote Sens.*, 2013, 1(2):6-36.
- [5] 黄鸿, 曲焕鹏. 基于半监督稀疏鉴别嵌入的高光谱遥感影像分类[J]. 光学精密工程, 2014, 22(2):434-442.
- HUANG H, QU H P. Hyperspectral remote sensing image classification based on SSDE [J]. *Opt. Precision Eng.*, 2014, 22(2):434-442. (in Chinese)
- [6] BIOUCAS-DIAS J M, PLAZA A, DOBIGEON N, *et al.*. Hyperspectral unmixing overview: Geometrical, statistical, sparse regression-based approaches [J]. *IEEE J. Sel. Topics Appl. Earth Observ.*, 2012, 5(2):354-379.
- [7] MAIRAL J, BACH F, PONCE J. Task-driven dictionary learning [J]. *IEEE Trans. Pattern Anal. Mach. Intell.*, 2012, 34(4):791-804.
- [8] IORDACHE M, BIOUCAS-DIAS J, PLAZA A. Total variation spatial regularization for sparse hyperspectral unmixing [J]. *IEEE Trans. Geosci. Remote Sens.*, 2012, 50(11):4484-4502.
- [9] CHEN Y, NASRABADI N M, TRAN T P. Hyperspectral image classification using dictionary-based sparse representation [J]. *IEEE Trans. Geosci. Remote Sens.*, 2011, 49(10):3973-3985.
- [10] CHARLES A, OLSHAUSEN B, ROZELL C. Learning sparse codes for hyperspectral imagery [J]. *IEEE Sel. Topics Signal Process.*, 2011, 5(5):963-978.
- [11] SOLTANI-FARANI A, RABIEE H R. When pixels team up: spatially weighted sparse coding for hyperspectral image classification [J]. *IEEE Geosci. Remote Sens. Lett.*, 2015, 12(1):107-111.
- [12] TILTON J C. RHSEG User's Manual (version 1.47) [OL]. <http://ipp.gsfc.nasa.gov/RHSEG>, 2009.
- [13] TANG Z Q, FU G Y, YU X, *et al.*. A class-Oriented model for hyperspectral image classification through hierarchy-tree-based selection [C]. *The 2nd International Sym. on Computer Vision in Remote Sens.*, Xiamen, P. R. China: CVRS, 2015, 2:1-4.
- [14] GARRIGUES P, OLSHAUSEN B A. Group sparse coding with a Laplacian scale mixture prior [C]. *The 24th Annu. Conf. NIPS*, 2010, 23:1-9.
- [15] CHANG C, LIN C. LIBSVM: A library for Support Vector Machines (Version 3.20) [CP]. <http://www.csie.ntu.edu.tw/~cjlin/libsvm>, 2014.
- [16] AVIRIS NW Indiana's Indian Pines 1992 Data Set. [OL]. <http://engineering.purdue.edu/~biehl/MultiSpec/hyperspectral.html>, 1992.

作者简介:



唐中奇(1987—),女,湖南洞口人,博士研究生,2009年、2012年于第二炮兵工程大学分别获得学士、硕士学位,主要从事计算机视觉、高光谱图像分析方面的研究。E-mail: tangzq12@mails.tsinghua.edu.cn

导师简介:



张利(1965—),男,山东烟台人,教授,博士生导师,1987年、1992年、2008年于清华大学分别获得学士、硕士、博士学位,主要从事无人机视觉、图像智能信息处理等方面的研究。E-mail: chinazhangli@mail.tsinghua.edu.cn

导师简介:



付光远(1966—),男,四川简阳人,教授,博士生导师,1989年于第二炮兵工程大学获得学士学位,1993年于西南交通大学获得硕士学位,2004年于第二炮兵工程大学获得博士学位,主要从事C4I系统建模与仿真、图像匹配精确制导技术研究。E-mail: dr-f@21cnl.com