

基于稀疏图正则矩阵判别分析的高光谱图像分类

黄晓伟, 杭仁龙, 孙玉宝, 刘青山

(江苏省大数据分析技术重点实验室, 南京信息工程大学信息与控制学院, 江苏 南京 210044)

[摘要] 光谱和空间信息的联合使用是高光谱图像分类领域的研究热点之一. 本文在已有的矩阵判别分析(MDA)模型的基础上, 提出了一种基于稀疏图正则的改进模型. 在有效融合高光谱图像光谱-空间信息的同时, 能充分挖掘无标签样本的信息, 从而提升了模型的分类性能. 为了验证本文算法的有效性, 在两个高光谱数据集上, 与多种方法进行了对比. 实验结果表明, 本文提出的算法优于其他同类算法.

[关键词] 高光谱图像分类, 谱-空特征融合, 矩阵判别分析, 稀疏图正则

[中图分类号] TP751 [文献标志码] A [文章编号] 1001-4616(2019)01-0051-08

Sparse Graph Regularized Matrix Discriminant Analysis for Hyperspectral Image Classification

Huang Xiaowei, Hang Renlong, Sun Yubao, Liu Qingshan

(Jiangsu Key Laboratory of Big Data Analysis Technology, School of Information and Control, Nanjing University of Information Science and Technology, Nanjing 210044, China)

Abstract: In the field of hyperspectral image classification, the incorporation of spectral information and spatial information is one of the hot research topics. In this paper, a modified matrix-based discriminant analysis (MDA) model is proposed based on sparse graph regularization. The proposed model can not only combine the spectral information and spatial information effectively, but also sufficiently explore the wealth information from unlabeled samples, thus improving the classification performance. In order to verify the effectiveness of the proposed method, experiments have been conducted on two widely used hyperspectral images. The experimental results show that the performance of our method is superior as compared to other methods.

Key words: hyperspectral image classification, spatial-spectral feature fusion, matrix-based discriminant analysis (MDA), sparse graph regularization

高光谱图像包含几十甚至几百个光谱波段, 具有超高的光谱分辨率, 包含着丰富的光谱图像信息. 如今, 高光谱图像已是人类认识世界的重要信息来源, 对它的处理是当前的一个重大技术课题. 高光谱图像分类是处理高光谱图像的一个重要技术手段, 它的主要目的是从图像中识别地物, 从而提取地物信息, 主要过程是为图像中的每个像素分配预定义的语义标签^[1]. 目前, 高光谱图像分类在地质勘探、资源调查、环境监测等方面发挥着重要作用, 是国家建设发展不可或缺的高新技术.

在早期的研究中, 大多数高光谱图像分类方法仅仅利用像素的光谱信息, 但是这些方法的分类效果往往不够理想, 分类效果图存在椒盐噪声. 后来的研究发现, 高光谱图像像素之间具有相关性, 空间位置邻域中的像素往往属于同一类地物, 即地物分布具有空间平滑的特性^[2], 而仅仅利用光谱信息的方法忽视了图像的空间信息, 造成了信息缺失; 同时高光谱图像中存在“同谱异物和同物异谱”现象, 这些因素制约了基于光谱信息的方法的分类效果. 因此, 为了进一步提升分类精度, 需要将光谱信息和空间信息进行联合使用.

光谱-空间信息的联合使用方法可以大致分为两种类型: 特征级的融合和决策级的融合. 特征级的融合通常分别提取空间特征和光谱特征, 然后进行特征融合. 例如, Fauvel 等人先利用形态轮廓提取空间信

收稿日期: 2018-09-18.

基金项目: 国家自然科学基金(61672292)、江苏省高校自然科学研究面上项目(18KJB520032)、江苏省青年基金项目(BK20180786).

通讯联系人: 刘青山, 博士, 教授, 博士生导师, 研究方向: 模式识别与计算机视觉. E-mail: qslu@nuist.edu.cn

息,然后分别对空间信息和光谱信息进行特征提取,最后将所有特征堆叠起来使用支持向量机(SVM)进行分类^[3].该方法将形态学算法的优势与 SVM 分类器强大的分类性能有效地结合在了一起,获得了比较好的效果.但是,直接串联特征会导致特征维度过高,容易造成过拟合. Camps-Valls 等利用空间均值及方差作为空间特征,然后用复合核方法来融合空间特征和光谱特征,最后利用 SVM 进行分类^[4].该方法需要大量的时间去调节核函数的权重参数.不同于特征级融合,决策级融合方法先分别利用光谱特征和空间特征产生分类结果,然后运用某些策略综合多个预测结果.如 Benediktsson 等人先依据光谱信息对像素进行分类,利用分类产生的结果辅助图像分割,然后利用多数投票策略结合分类和分割结果^[5],这种方法在大块区域上产生了光滑的分类效果,但是在边界区域和纹理明显的区域效果不够理想,因为在遥感数据上获取高精度的分割图非常困难.

近来,为了更加充分融合高光谱图像的光谱和空间信息, Hang 等提出了一种新颖的空间-光谱特征融合方法,该方法利用矩阵对每个像素进行描述,以充分保留像素的局部上下文信息和光谱波段信息,然后利用矩阵判别分析(MDA)模型对矩阵特征进行降维,获得了不错的分类效果^[6].在文献[7]中, Hang 等在 MDA 模型的基础上提出了鲁棒矩阵判别分析(RMDA)模型,先利用鲁棒主成分分析(RPCA)对数据进行去噪预处理,然后再用 MDA 进行降维,进一步提升了分类性能.尽管取得了一定的效果,MDA 模型仍然存在一些不足之处:首先,MDA 是一种监督模型,而设计一个高准确率和鲁棒性的监督模型需要大量的训练样本,但是高光谱图像的标注代价高昂,通常只含有少量的标注样本.其次,MDA 模型在某些情况下会出现度量矩阵的奇异性问题,无法得到准确的结果.为了解决这些问题,本文提出了一种基于稀疏图正则的 MDA 模型,利用半监督的图模型修正 MDA 模型的类内散度矩阵,从而产生以下两点优势:第一,半监督图模型充分利用了无标签样本的信息,可以提升 MDA 模型分类性能和泛化能力;第二,半监督图模型修正了 MDA 的类内散度矩阵,消除了 MDA 模型中度量矩阵的奇异性问题.

1 本文方法

1.1 谱-空特征表示

高光谱图像一般用一个三维矩阵表示,假设 $I \in \mathbf{R}^{m \times n \times l}$ 为一幅含有 $m \times n$ 个像素以及 l 个光谱波段的高光谱图像, $I_{ij}^{(k)}$ 表示像素位置为 (i, j) , 波段为 k 的像素,其中, $i \in (1, 2, \dots, m)$, $j \in (1, 2, \dots, n)$, $k \in (1, 2, \dots, l)$. 为了直接获取光谱和空间上下文信息,在图像上以目标像素为中心,选取大小为 $w \times w$ 的图像块作为原始特征,其中 w 为奇数,则像素 I_{ij} 在波段 k 上的特征可表示为 $\Omega(I_{ij}^{(k)}) = \{I_{pq}^{(k)} \mid p \in i-b, \dots, i, \dots, i+b; q \in j-b, \dots, j, \dots, j+b\}$,其中, $b = (w-1)/2$. 将每个波段上的图像块变成行向量,得到 l 个行向量,将这些行向量组合在一起,形成一个矩阵 $Y_{ij} \in \mathbf{R}^{l \times w^2}$,以此作为目标像素的特征.

1.2 图正则 MDA 模型

为了减少矩阵特征的冗余信息,同时提升特征的判别能力,利用 MDA 将特征映射到一个子空间,在映射后的子空间中,表征同类样本聚集度的类内散度矩阵要最小化,同时,表征异类样本聚集度的类间散度矩阵要最大化.令 $Z = L^T Y R$ 表示将特征矩阵 Y 映射到 $r \times c$ 维的子空间后的样本,其中, $L = [\mu_1, \mu_2, \dots, \mu_r] \in \mathbf{R}^{l \times r}$, $R = [v_1, v_2, \dots, v_c] \in \mathbf{R}^{w^2 \times c}$ 是子空间的变换矩阵.

假设有 N 个训练样本, C 个不同的类,第 j 个训练样本为 Y_j , $j \in (1, 2, \dots, N)$. M 和 M_i 分别表示所有训练样本的平均值和第 i 类训练样本的平均值, $i \in (1, 2, \dots, C)$, N_i 表示第 i 类训练样本的个数. \tilde{M} 和 \tilde{M}_i 代表映射后的样本的总平均值和第 i 类训练样本的平均值, $i \in (1, 2, \dots, C)$. S_B 代表映射后的类间散度矩阵, S_W 代表映射后的类内散度矩阵.为了获得最优的映射矩阵,需要将类间散度矩阵和类内散度矩阵的比值最大化.则 MDA 的目标函数可写为:

$$J = \max \frac{S_B}{S_W}, \quad (1)$$

式中, $S_W = \text{tr} \left(\sum_{i=1}^C \sum_{Y_k \in \Pi_i} L^T (Y_k - M_i) R R^T (Y_k - M_i)^T L \right)$, $S_B = \text{tr} \left(\sum_{i=1}^C N_i L^T (M_i - M) R R^T (M_i - M)^T L \right)$,

tr 表示矩阵的迹, Π_i 表示第 i 类样本.

MDA 是一种监督模型,在小样本情形下判别信息较少,模型学习往往不够充分. 本文在此基础上利用半监督的图模型挖掘无标签样本的信息,增加模型的判别能力,以此提升分类效果. 图正则 MDA 模型的目标函数为:

$$J' = \max \frac{S_B}{S_W + \lambda f'}, \quad (2)$$

式中, f' 是图正则项, λ 是正则参数. 将半监督图作为正则项修正 MDA 模型的类内散度矩阵,可以消除 MDA 模型中度量矩阵的奇异性问题.

1.3 稀疏图模型的构建

近来,半监督学习已经成为机器学习最活跃的领域之一. 半监督学习在使用带标签样本信息的同时,可以挖掘无标签样本的信息,提高模型判别能力. 在高光谱图像分类研究中,基于图的半监督学习方法^[8-10]获得了广泛的应用. Yan 等人^[11]提出了基于稀疏编码的 L1 图, L1 图将重构样本以外的所有样本作为过完备字典,利用最小化重构系数的 L1 范数来对每个数据样本进行重构,最后将所有样本的重构系数作为图的权重矩阵. Gu 等人^[12]利用 L1 图进行高光谱图像分类,他们的实验表明 L1 图在高光谱图像分类任务上比 K 近邻图和 ε -ball 图有着更好的性能.

假设 $G=(\mathbf{X}, \mathbf{W})$ 表示图模型,其中样本集 \mathbf{X} 为图的顶点, \mathbf{W} 为图的权重矩阵. 令样本集 $\mathbf{X}=[x_1, x_2, \dots, x_p]$ 表示高光谱图像特征集,其中 P 表示样本总量, $x_i \in \mathbf{R}^d$ 表示特征. 传统的图模型构建方法包括图邻域结构的构建和图权重的计算. 对于图权重的计算,常用的函数为: $S_{ij} = \exp[-\|x_i - x_j\|_2^2 / (2\sigma^2)]$; 对于图的邻域结构,常用的方法有两种,第一种是 K 近邻方法,当样本 x_j 是 x_i 的 K 近邻之一时,连接顶点 x_i 和顶点 x_j ; 第二种是 ε -邻域法, ε 是一个阈值,当样本 x_i 和 x_j 的相似度大于 ε 时,连接顶点 x_i 和顶点 x_j . 这两种图都有一定的缺陷. 首先,图的参数较多,参数调整相对复杂;其次,这两种图都是基于成对的欧式距离,对噪声较敏感,图结构容易受到噪声的影响而改变;最后,这两种图均使用固定的全局参数来决定所有数据的邻域,因此不能产生适应数据的邻域,而且 ε -ball 图往往会存在孤立的子图,阈值 ε 的确定也较难.

本文借鉴 L1 图的方法,利用 L0 范数约束的最小二乘逼近来对样本数据进行重构,以重构系数作为图的权重矩阵. 相对于传统的 K 近邻图和 ε -ball 图,本文的 L0 图具有如下优点: (1) 图的结构更加稳定,对数据噪声有很好的鲁棒性. (2) 参数少,图权重矩阵自动稀疏,且稀疏度可自由控制. (3) 可以针对样本数据的结构自动产生相适应的邻域.

对于样本集 $\mathbf{X}=[x_1, x_2, \dots, x_p]$, 对其中的每个样本 x_i 进行重构,以所有样本的重构系数作为 L0 图的权重矩阵 \mathbf{W} ,其稀疏重构表达式为:

$$\min \|\mathbf{D}\alpha - x\|_2^2, \text{ s.t. } \|\alpha_0\| < T. \quad (3)$$

对于每个样本 x_i , 对应的字典为 $\mathbf{D}=[x_1, x_2, \dots, x_{i-1}, x_{i+1}, \dots, x_p]$, 表示将样本集 \mathbf{X} 中被重构样本以外的其他 $P-1$ 个样本作为重构字典. 由于图像样本数量是固定的,为了更好地进行稀疏逼近,样本 x_i 的维度不宜过高,所以本文用图像中所有像素的光谱特征作为样本集 \mathbf{X} . 每个样本 x_i 的稀疏系数 α_i 有 $P-1$ 个元素,在第 $i-1$ 个元素和第 i 个元素之间添加元素 0,使得 α_i 为一个具有 P 个元素的列向量, $i \in (1, 2, \dots, P)$. 图的权重矩阵为 $\mathbf{W}=[\alpha_1, \alpha_2, \dots, \alpha_p]$. 半监督图的优化函数设计为:

$$f' = \arg \min_f \sum_{i,j=1}^P \|f(Y_i) - f(Y_j)\|_F^2 W_{ij}. \quad (4)$$

1.4 算法优化

将式(4)代入式(2),可得最终的目标函数为:

$$J' = \frac{\text{tr}(\sum_{i=1}^C N_i L^T (M_i - M) R R^T (M_i - M)^T L)}{\text{tr}(\sum_{i=1}^C \sum_{Y_k \in \Pi_i} L^T (Y_k - M_i) R R^T (Y_k - M_i)^T L + \lambda \sum_{i,j=1}^P L^T (Y_i - Y_j) R R^T (Y_i - Y_j)^T L W_{ij})}. \quad (5)$$

参考文献[13],利用迭代交替优化方法解出最优的变换矩阵 \mathbf{L} 和 \mathbf{R} ,使目标函数 J' 最大. 具体流程如下:首先,固定 \mathbf{R} ,目标函数可以改写成如下形式:

$$J' = \frac{L^T S_B^R L}{L^T S L}, \quad (6)$$

式中, S_B^R 和 S 分别为:

$$S_B^R = \sum_{i=1}^C N_i (M_i - M) R R^T (M_i - M)^T,$$

$$S = \sum_{i=1}^C \sum_{Y_k \in \Pi_i} (Y_k - M_i) R R^T (Y_k - M_i)^T + \lambda \sum_{i,j=1}^P (Y_i - Y_j) R R^T (Y_i - Y_j)^T W_{ij}.$$

对 $(S)^{-1} S_B^R$ 进行特征值分解, L 即为 r 个最大特征值所对应的特征向量的组合. 然后, 将 L 固定, 可以用同样的方式解出 R . 整个过程不断迭代直到收敛.

2 实验分析及讨论

为了验证算法的有效性, 本文在两个通用的高光谱数据集上进行测试.

2.1 实验数据

Indian Pines (IP) 数据集: 该数据集来自美国印第安纳州西北部的 Indian Pines 检测站, 由机载可见光成像和红外成像光谱仪 (AVIRIS) 获取, 是一幅农业区图像. 原始数据包含 224 个光谱反射波段, 剔除 4 个含有大量零值的波段和 20 个含有大量噪声的水体吸收波段, 使用剩余的 200 个波段进行实验. 图像包含 145×145 像素, 空间分辨率为 20 m. 图像中包含 16 种不同类别的地面覆盖物, 共 10 249 个样本, 每类样本数量从 20 到 2 455 不等, 样本数量很不均衡, 分类难度较大. 图 1 展示了一个伪彩色合成图和地面真值分布图.

Kennedy Space Center (KSC) 数据集: 该数据集来自于美国佛罗里达州的肯尼迪空间中心, 由机载可见光成像和红外成像光谱仪 (AVIRIS) 获取. 原始数据包含 224 个光谱波段, 剔除被水体吸收影响的波段和信噪比较低的波段, 使用剩余的 176 个波段进行实验. 图像包含 512×614 像素, 空间分辨率为 18 m. 该数据集包含 13 种不同类别的地面覆盖物, 共 5 211 个样本, 每类样本数量从 105 到 927, 样本数量相对均衡. 图 2 展示了一个三波段伪彩色合成图像和地面真值分布图.




图 1 Indian Pines 数据集

Fig. 1 Indian Pines data set

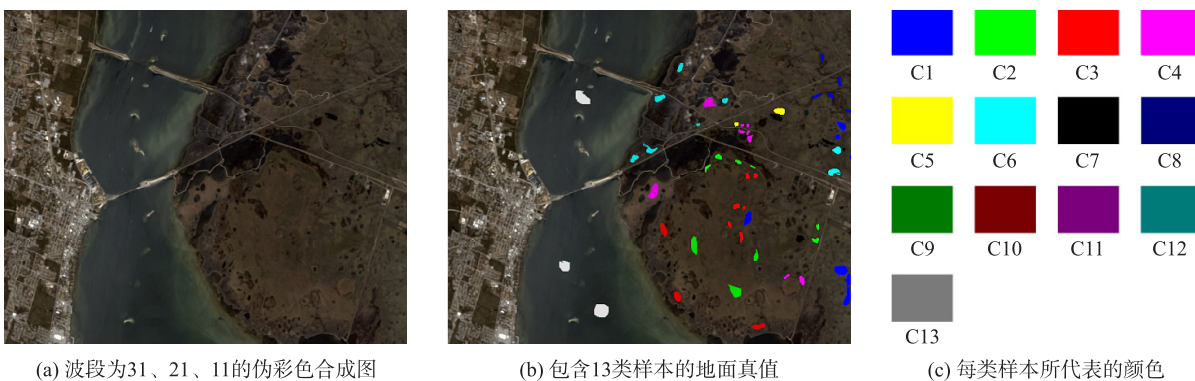


图 2 Kennedy Space Center 数据集

Fig. 2 Kennedy Space Center data set

2.2 实验设置

为了验证算法的有效性,用本文算法与几种不同的算法进行对比,包括 MDA^[6]、RMDA^[7] 以及 K 近邻图正则 MDA. 此外,采用基于光谱信息的线性判别分析 (LDA) 作为比较基准,因为 MDA 是 LDA 的推广. 在 LDA 的实验中,将类内散度矩阵 S_w 替换为 $S_w + \varepsilon I$, $\varepsilon = 10^{-3}$,以此抑制矩阵的奇异性问题,降维后特征维度为 $C-1$, C 为样本类别数. MDA 和 RMDA 中的参数设置与文献[7]中保持一致. K 近邻图正则 MDA 中最优的 K 从预选集 $\{1, 3, 5, 7, 9, 11\}$ 中选择,最优的 σ 按步长 0.2 从 1 到 5 中选择.

在每个数据集上,从每一类中随机选取 10 个像素作为训练集,剩余像素作为测试集,每种方法提取的特征都用线性核的 SVM 分类器进行分类. 为了降低随机选择样本的影响,每种方法重复做 10 遍取平均值作为最终结果. 本文使用的评价指标包括整体准确率 (overall accuracy, OA), 平均正确率 (average accuracy, AA), 用每类准确率以及 Kappa 系数 κ 作为度量指标. OA 表示测试样本中准确分类的样本数量与测试样本总数的比值,AA 代表所有类准确率的平均值, Kappa 系数 κ 代表分类与完全随机的分类产生错误减少的比例,是用来评价分类一致性程度的指标^[6].

2.3 参数分析

L0 图正则 MDA 模型共有 5 个参数,分别是稀疏度约束参数 T ,窗口尺度 w ,稀疏图的正则化参数 λ ,以及降维后的特征维度 r 和 c . 由于正则化参数 λ 变化范围较大,不易选取,因此设计一个函数来自动选择参数 λ ,使得 $\lambda f'$ 的平均值与 S_w 的平均值的比值固定为常量 θ . 在 IP 数据集和 KSC 数据集上分别抽取 5 份固定的训练样本来分析参数.

(1) 分析窗口尺度 w 和特征维度 c 与 OA 的关系. 由于降维后的特征维度 c 的可选范围受 w 的限制,因此同时分析这两个参数. 固定 r, θ 以及 T , OA 随 w 和 c 变化如图 3 所示,其中 OA 是 5 份训练样本的平均值. 在两个数据集中, $w=9$ 可以获得最好的分类结果. 在 IP 数据集中,随着 c 的增加,分类精度先快速提升而后开始下降,其最优参数 $c=9$. 在 KSC 数据集中,随着 c 的增加,分类精度先快速提升,达到一定精度后保持稳定,其最优参数 $c=33$.

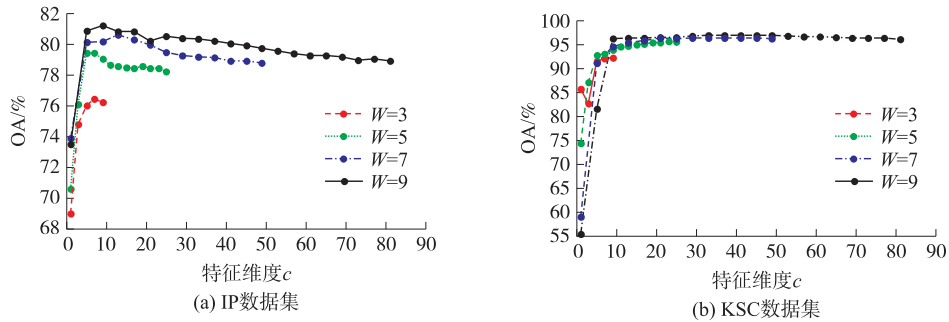


图 3 OA 随 w 和 c 的变化情况

Fig. 3 OA changes with parameters w and c

(2) 分析稀疏度参数 T 与 OA 的关系. 固定 r, c, θ 以及 w , OA 随参数 T 的变化如图 4 所示. IP 数据集中,最优参数 $T=6$; KSC 数据集中,最优参数 $T=2$ 或者 $T=4$. 当 T 取不同的值时,两个数据集上的 OA 都在一个很小的范围内震荡,因为稀疏重构系数快速衰减,使得产生的稀疏系数往往较小. 在 IP 数据集中参数




图 4 OA 随参数 T 的变化情况

Fig. 4 OA changes with parameter T

T 的影响更大一些,因为在稀疏重构过程中 IP 数据集样本的系数衰减比 KSC 数据集慢. 这说明相对于 KSC 数据集,IP 数据集同类样本的相似度更低,邻域中的样本比较松散,而 KSC 邻域中的样本相对密集.

(3)分析 θ 与 OA 的关系. 固定 r, c, T 和 w ,OA 随 θ 变化如图 5 所示,其中 IP 数据集最优参数 $\theta=1.3$, KSC 数据集 $\theta=1.08$.

(4)当窗口尺度 $w=9$ 时,分析特征维度 r 和 c 与 OA 的关系. 固定 θ 和 T ,按步长 10 遍历特征维度 r ,步长 8 遍历特征维度 c ,图 6 展示了两个数据集中 OA 随 r 和 c 的变化情况,图中 IP 数据集最优参数为 $r=171, c=9$,KSC 数据集最优参数为 $r=131, c=17$.




图 5 OA 随参数 θ 的变化情况
Fig. 5 OA changes with parameter θ




图 6 OA 随维度 r 和 c 的变化情况
Fig. 6 OA changes with dimension r and c

2.4 结果与讨论

表 1 和表 2 分别表示 5 种不同的方法在 IP 和 KSC 数据集上的分类结果,其中加粗字体代表相同情况下的最好结果.

表 1 IP 数据集 5 种方法的每类准确率,OA,AA,Kappa 系数(%)

Table 1 OA, AA, per-class accuracy and κ (%) of five different methods on the IP data set

序号	名称	训练样本	测试样本	LDA	MDA	RMDA	近邻图	L0 图
C1	Alfalfa	10	36	78.89	97.78	98.89	98.21	96.67
C2	Corn-notill	10	1418	30.34	72.28	69.79	78.45	81.62
C3	Corn-mintill	10	820	33.68	79.49	90.32	78.19	73.15
C4	Corn	10	227	32.42	91.37	98.15	95.56	97.27
C5	Grass-pasture	10	473	66.43	94.67	93.57	92.10	94.33
C6	Grass-trees	10	720	80.81	95.94	93.81	98.51	97.89
C7	Grass-pasture-mowed	10	18	86.67	100	100	100	100
C8	Hay-windrowed	10	468	71.79	100	99.57	99.79	99.27
C9	Oats	10	10	78.00	100	100	100	100
C10	Soybean-notill	10	962	40.98	75.47	74.24	78.41	78.07
C11	Soybean-mintill	10	2445	32.53	65.36	75.68	72.28	75.91
C12	Soybean-clean	10	583	46.18	85.66	86.66	85.79	88.16
C13	Wheat	10	195	93.33	99.18	98.56	99.38	99.28
C14	Woods	10	1255	63.19	87.24	87.25	91.99	92.37
C15	Buildings-Grass	10	376	49.57	91.91	92.93	91.96	94.73
C16	Stone-Steel-Towers	10	83	85.54	98.55	99.76	97.42	99.04
	OA			47.13	80.22	83.16	83.68	84.93
	AA			60.65	89.68	91.20	91.13	91.74
	κ (%)			41.17	77.70	80.95	81.54	82.92

表 2 KSC 数据集 5 种方法的每类准确率,OA,AA,Kappa 系数(%)
Table 2 OA,AA,per-class accuracy and κ (%) of five different methods on the KSC data set

序号	名称	训练样本	测试样本	LDA	MDA	RMDA	近邻图	L0 图
C1	Scrub	10	751	78.19	92.78	95.34	94.76	98.34
C2	Willow swamp	10	233	75.54	88.67	90.64	85.40	89.56
C3	Cabbage palm hammock	10	246	70.33	92.93	97.64	96.70	99.53
C4	palm/oak hammock	10	242	55.79	87.02	88.51	70.56	72.52
C5	Slash pine	10	151	67.95	87.95	96.16	85.84	90.84
C6	Oak/broadleaf hammock	10	219	67.03	88.13	99.36	89.67	99.70
C7	Hardwood swamp	10	95	90.11	99.79	100	100	100
C8	Graminoid marsh	10	421	78.15	93.40	94.63	88.30	99.17
C9	Spartina marsh	10	510	89.02	96.71	97.57	99.93	97.84
C10	Cattail marsh	10	394	94.72	95.18	100	98.76	100
C11	Salt marsh	10	409	88.26	93.59	93.50	95.32	98.86
C12	Mud flats	10	493	88.76	85.07	98.62	94.75	99.93
C13	water	10	917	100	99.32	100	99.92	100
	OA			84.20	93.24	96.73	94.15	97.28
	AA			80.30	92.35	96.31	92.30	95.87
	κ (%)			82.43	92.47	96.36	93.49	96.96

图 7 是 5 种不同的方法在 IP 数据集上的分类效果图. 从这些结果中,可以得到以下几个结论:
(1)将 LDA 推广到 MDA 后,分类精度获得了很大的提升,在 IP 数据集上表现得更加明显. 这说明,在光谱信息的基础上,融入空间信息,能有效减轻高光谱图像中存在的“同物异谱和同谱异物”现象对分类的影响. 从图 7(a)到图 7(b),可以看出有大量异常值被消除.




图 7 Indian Pines 数据集上 5 种方法的分类效果图
Fig. 7 Classification maps of five different methods on the IP data set

(2)与 MDA 相比,RMDA 增加了去噪环节,分类精度获得了较大提升,其中,KSC 数据集提升更大. 这说明高光谱图像在成像的过程中易受噪声干扰,有效的去噪方法能有效提升模型的性能. K 近邻图基于像素对的欧式距离,对噪声非常敏感,导致 K 近邻图正则 MDA 模型在 KSC 数据集上分类精度提升较小. 而基于稀疏编码的 L0 图对噪声有一定的鲁棒性,因此,本文方法在 KSC 数据集上的分类效果的提升明显高于 K 近邻图正则 MDA.
(3)在所有对比方法中,本文方法可以获得最高的 OA 和 κ 值. 具体而言,在 IP 数据集上,本文方法能够将 MDA 的 OA 提升 4.71%,Kappa 系数提升 5.22%;在 KSC 数据集上,能够将 MDA 的 OA 提升 4.04%,Kappa 系数提升 4.49%. 对于每一类的分类准确率,本文方法在 IP 数据集的 16 个类别中能够获得 7 个最高值,在 KSC 数据集的 13 个类别中能够获得 9 个最高值,充分证实了本文方法的有效性.

3 结语

本文在 MDA 模型的基础上提出了 L0 图正则 MDA 模型,克服了 MDA 模型中度量矩阵的奇异性问题,同时也利用了无标签样本的信息,提升了模型的分类性能. 在两个数据集上进行的实验结果表明,本文方法的分类性能优于其他方法,在整体分类准确率(OA)和 Kappa 系数等方面都有一定程度的提升. 在 L0 图和近邻图的对比过程中,验证了 L0 图更好的噪声抑制能力,而且,L0 图比近邻图少一个参数,模型相对简单. 本文的工作还有一些有待改进的地方,比如,本文方法参数依然较多,寻找最优参数相对困难;在总样本较大的情形下,对内存要求较高. 后续的工作可以考虑如何优化模型,更加有效地利用训练样本

的空间信息和无标签样本的信息,或者优化参数的寻优过程,进一步提升方法的实用性.

[参考文献]

- [1] ZHAO J,ZHONG Y F,SHU H,et al. High-resolution image classification integrating spectral-spatial-location cues by conditional random fields[J]. IEEE transactions on image processing,2016,25(9):4033-4045.
- [2] FAUVEL M,TARABALKA Y,BENEDIKTSSON J A,et al. Advances in spectral-spatial classification of hyperspectral images[J]. Proceedings of the IEEE,2013,101(3):652-675.
- [3] FAUVEL M,BENEDIKTSSON J A,CHANUSSOT J,et al. Spectral and spatial classification of hyperspectral data using SVMs and morphological profiles[J]. IEEE transactions on geoscience and remote sensing,2008,46(11):3804-3814.
- [4] CAMPS-VALLS G,GOMEZ-CHOVA L,MUNOZ-MARI J,et al. Composite kernels for hyperspectral image classification[J]. IEEE geoscience and remote sensing letters,2006,3(1):93-97.
- [5] TARABALKA Y,BENEDIKTSSON J A,CHANUSSOT J,et al. Multiple spectral-spatial classification approach for hyperspectral data[J]. IEEE transactions on geoscience and remote sensing,2010,48(11):4122-4132.
- [6] HANG R L,LIU Q S,SONG H H,et al. Matrix-based discriminant subspace ensemble for hyperspectral image spatial-spectral feature fusion[J]. IEEE transactions on geoscience and remote sensing,2016,54(2):783-794.
- [7] HANG R L,LIU Q S,SUN Y B,et al. Robust matrix discriminative analysis for feature extraction from hyperspectral images[J]. IEEE journal of selected topics in applied earth observations and remote sensing,2017,10(5):2002-2011.
- [8] GAO Y,JI R R,CUI P,et al. Hyperspectral image classification through bilayer graph-based learning[J]. IEEE transactions on image processing,2014,23(7):2769-2778.
- [9] BAI J,XIANG S M,PAN C H. A graph-based classification method for hyperspectral images[J]. IEEE transactions on geoscience and remote sensing,2013,51(2):803-817.
- [10] YANG L X,YANG S Y,JIN P L,et al. Semi-supervised hyperspectral image classification using spatio-spectral Laplacian support vector machine[J]. IEEE geoscience and remote sensing letters,2014,11(3):651-655.
- [11] CHENG B,YANG J C,YAN S C,et al. Learning with l1-graph for image analysis[J]. IEEE transactions on image processing a publication of the IEEE signal processing society,2010,19(4):858-66.
- [12] GU Y F,FENG K. L1-graph semisupervised learning for hyperspectral image classification[C]//Geoscience and Remote Sensing Symposium. Munich:IEEE,2012:1401-1404.
- [13] YE J P,JANARDAN R,LI Q. Two-dimensional linear discriminant analysis[J]. Photogrammetric engineering and remote sensing,2004,5(6):1431-1441.

[责任编辑:陆炳新]