

联合超像素降维和后处理优化的高光谱图像分类方法

黄媛, 贺新光, 万义良

1. 湖南师范大学 地理科学学院, 长沙 410081;

2. 湖南师范大学 地理空间大数据挖掘与应用湖南省重点实验室, 长沙 410081

摘要: 针对高光谱图像样本标签量少且空间—光谱信息利用不充分而导致图像分类精度较低的问题, 本文提出一种联合超像素降维和后验概率优化的高光谱图像分类方法。该方法首先基于高光谱图像的空间—光谱信息为每个样本构建局部邻域集合, 并从局部邻域集合中提取超像素稀疏混合特征来充分表征图像的空谱信息和相关变化信息, 然后将全局稀疏混合特征输入支持向量机分类器中生成像素的类别概率向量, 最后采用后验概率模型优化类别概率向量, 并依据概率最大值得到分类标签图。在3组常用的小规模数据集 Indian Pines、Pavia University 和 Salinas 以及一组大规模数据集 HoustonU 上的实验结果表明: 本研究所提出的分类方法能够自适应地充分提取高光谱图像的高判别性特征信息, 且在少量样本标签情形下, 该方法在这4组实验数据集上分别获得了 98.58%、96.88%、98.54% 和 91.01% 的总体分类精度, 优于文中对比的 7 种先进分类方法。

关键词: 遥感, 高光谱图像分类, 超像素降维, 混合特征提取, 后处理优化, 支持向量机

中图分类号: TP701/P2

引用格式: 黄媛, 贺新光, 万义良. 2024. 联合超像素降维和后处理优化的高光谱图像分类方法. 遥感学报, 28(2): 494–510

Huang Y, He X G and Wan Y L. 2024. Hyperspectral-image classification method combining superpixel dimension reduction with post-processing optimization. National Remote Sensing Bulletin, 28(2): 494–510 [DOI: 10.11834/jrs.20221497]

1 引言

高光谱图像 HSI (Hyperspectral Image) 是由成像光谱仪在数十甚至上百个波段内对地面物体成像的结果, 与多光谱图像相比, HSI 包含了大量的地物信息, 有效提高了在遥感图像分类方面的识别精度, 被广泛地应用于农业 (Liang 等, 2015)、军事 (徐栋 等, 2020) 和矿产资源开发 (Carrino 等, 2018; 董新丰 等, 2020) 等领域。然而由于 HSI 的高维特性, 导致图像在分类过程中产生 Huge 现象, 致使分类精度随着参与运算波段数目的增加而先升后降 (董安国 等, 2019)。因此, 如何从 HSI 中提取高识别力特征以促进分类精度的提高仍是一个非常值得研究的问题。

为提高 HSI 分类的准确率, 提出了包括支持向量机 SVM (Support Vector Machine) (Melgani 和 Bruzzone, 2004)、极限学习机 (Li 等, 2015)、K-近邻法 (Blanzieri 和 Melgani, 2008) 和决策树 (华晔 等, 2012) 等在内的许多基于谱特征的机器学习分类方法。由于 SVM 具有能够以稳健有效的方式处理高维数据和小训练样本数据的特性, 从而在高光谱图像分类任务中脱颖而出 (闫敬文 等, 2019; Camps-Valls 和 Bruzzone, 2005)。到目前为止, SVM 仍被广泛作为模型分类器而应用于 HSI 的分类任务 (Jiang 等, 2018; Duan 等, 2021; 李丹 等, 2021)。已有文献表明 (李非燕 等, 2019; 付青 等, 2020; 魏祥坡 等, 2020), 仅依靠高光谱图像的谱特征, 而忽略空间信息的分类方法,

收稿日期: 2021-07-23; 预印本: 2022-01-17

基金项目: 湖南省自然资源厅科技项目经费资助(编号: 2021-45)

第一作者简介: 黄媛, 研究方向为高光谱影像处理与分析。E-mail: huangyuan@hunnu.edu.cn

通信作者简介: 贺新光, 研究方向为地理时空大数据挖掘与应用。E-mail: xghe@hunnu.edu.cn

其分类效果往往不是很理想。对此, 众多学者 (Duan 等, 2021; 程文娟和陈文强, 2020; 张祥东等, 2021; 高奎亮等, 2021) 相继提出了多种联合空间和光谱信息的特征提取方法, 致力于高精度地识别出 HSI 的地物类型。例如, Duan 等 (2021) 在光谱信息的基础上, 构建了一种基于自适应纹理平滑的双通道空间特征提取算法; 程文娟和陈文强 (2020) 利用卷积核提取 HSI 的空间—光谱特征并跨层融合, 发展了一种多尺度跨层特征融合注意力机制的分类方法; 张祥东等 (2021) 设计了一种能同步提取 HSI 空间信息和光谱信息的卷积神经网络模型。然而, 这些基于空—谱联合特征的分类方法并没有很好的关注到 HSI 的空域与谱域信息之间的联系。值得注意的是, HSI 的同一类别像素通常以不同的区域聚集在一起, 导致图像是由许多均匀的同质区域组成。目前, 已经有学者 (李丹等, 2021; Zheng 等, 2019; Jiang 等, 2018) 关注到了这个现象。如李丹等 (2021) 基于局部邻域集合提取图像的高斯混合特征, 充分捕获了 HSI 的空间纹理结构信息、不同谱段间联系和空—谱变化信息; Zheng 等 (2019) 根据超像素分割和距离加权线性回归分类器设计了一种分类方法, 并应用于 HSI 的分类得到了良好的结果。尤其是, Jiang 等 (2018) 提出的一种以均匀同质区域为混合特征提取单元的超像素主成分分析 SPCA (Superpixelwise Principal Component Analysis) 方法, 该方法可有效提取 HSI 的高区分性特征信息, 并在小样本标签下具有优良的分类性能。但是, SPCA 方法中采用的熵率超像素分割算法 (宋熙煜等, 2015) 生成的超像素紧密度和边缘贴合度一般, 不能很好的形成均匀区域。然而, Xu 等 (2018) 基于简单线性迭代聚类 SLIC (Simple Linear Iterative Clustering) 发展了一种区域聚类 RC (Regional Clustering) 算法。该方法可自然平衡 HSI 的空间信息和光谱信息, 是一种适合 HSI 分类的空间预处理方法。另一方面, Li 等 (2020) 在传统线性判别分析的基础上考虑了巴氏误差界优化和非凸问题, 提出了一种鲁棒的稀疏线性判别分析 SLDA (Sparse Linear Discriminant Analysis) 方法。受 SPCA 的启发, 本文通过有效结合 RC 和 SLDA 发展了一种超像素稀疏线性判别分析 SSLDA (Superpixelwise SLDA) 方法。然而, 预实验表明, 基于 SSLDA 方法提取的 HSI 空谱特征信息尽管能

够很好地表征高光谱图像信息, 但在部分异质边缘区域的像元识别率欠佳。为了优化 HSI 的初始类别概率向量, Kang 等 (2015) 基于扩展的随机游走 ERW (Extended Random Walker) 构建了一种分类方法, 并应用于三组常用的高光谱数据集, 获得了良好的分类结果。为了弥补 SSLDA 在部分异质边缘区域像元识别率欠佳的问题, 本文应用 ERW 进一步优化基于 SSLDA 获得的初始类别概率向量。相较于 Kang 等 (2015), 本文首先利用 SSLDA 提取 HSI 的高判别性稀疏混合特征, 然后输入 SVM 获得 HSI 的初始类别概率向量, 以期提高分类方法的精度和效率。

综上所述, 为了充分利用高光谱图像的空间—光谱信息, 且在样本标签量少的情况下提高图像的分类精度, 本文提出一种联合超像素降维和后验概率优化的高光谱图像分类方法。首先基于 HSI 的空间—光谱信息, 利用已发展的超像素稀疏线性判别分析法在空间邻域信息的基础上为每个样本分配不同的局部邻域, 并在局部邻域集合中提取超像素稀疏混合特征; 再将全局稀疏混合特征代表 HSI 的空间—光谱特征输入支持向量机分类器中, 生成像素的类别概率向量; 最后采用后验概率模型—随机游走法刻画 HSI 相邻像素之间的空间相关性, 并优化类别概率向量且依据概率最大值得到分类标签图, 从而完成图像分类任务。为了验证所提出的方法是否可以在 HSI 的图像分类任务中取得优良的识别性能, 将其应用到 3 组小规模数据集 Indian Pines、Pavia University 和 Salinas, 以及一组大规模数据集 HoustonU 上进行分类实验, 并与 7 种先进方法进行对比分析。

2 研究方法

2.1 超像素稀疏线性判别分析法

为有效提取高判别性的 HSI 特征信息和减少模型的整体运行时间, 本文首先拓展了一种超像素稀疏线性判别分析方法, 致力于获取一组超像素稀疏混合特征来充分表征 HSI 的空间—光谱信息及其相关变化信息。相比于归一化切割算法 (Shi 和 Malik, 2000)、分水岭分割算法 (Vincent 和 Soille, 1991)、基于图的分割算法 (Felzenszwalb 和 Huttenlocher, 2004) 和 SLIC (Achanta 等, 2012)。SSLDA 方法中采用的区域聚类不仅降低了计算复

杂度, 还同时集成了HSI的空间—光谱信息, 得到一组既表现出空间相关性又表现出光谱相似性的聚类分区。SSLDA方法在这些聚类子块集合中应用稀疏线性判别法降低HSI的光谱维度, 并提取混合特征。因此, 超像素降维方法主要分为局部邻域集合的提炼和稀疏混合特征的提取两大步骤, 具体操作如下:

令 $X \in R^{m_1 \times m_2 \times d}$ 表示 HSI 数据集, 其中 $m_1 \times m_2$ 为图像尺寸, d 为原始光谱维度。把 3D 立方体矩阵 X 重塑成 2D 矩阵为 $X = [x_1, x_2, \dots, x_i, \dots, x_N] \in R^{d \times N}$, $N = m_1 \times m_2$, 其中 $x_i = [x_{i1}, x_{i2}, \dots, x_{ij}, \dots, x_{id}]^T$ 是列向量, 表示 HSI 中的第 i 个像素向量。

(1) 初始化聚类。根据预先设置的分区数 S , 等距离初始化聚类中心 $C = \{c_1, c_2, \dots, c_k, \dots, c_S\} \in R^{d \times S}$, 其中 $c_k = [x_{c_k1}, x_{c_k2}, \dots, x_{c_kj}, \dots, x_{c_kd}]^T$; 根据聚类中心初始化局部邻域集合 $Z = \{Z_1, Z_2, \dots, Z_k, \dots, Z_S\}$, 其中 $Z_k = \{x_k^1, x_k^2, \dots, x_k^o\}$, x_k^o 表示局部邻域集合 Z_k 包含的第 o 个像元。

(2) 计算空间距离和光谱距离。定义像元 x_i 和聚类中心 c_k 的空间坐标分别为 $(x_i^{\text{spa}}, y_i^{\text{spa}})$ 和 $(x_{c_k}^{\text{spa}}, y_{c_k}^{\text{spa}})$, 在 c_k 的 $N_x \times N_y$ 矩形搜索范围内计算像元 x_i 到 c_k 的空间距离 D_{Spa} 和光谱距离 D_{Spe} 。其中 D_{Spa} 利用欧氏距离度量获得, 而 D_{Spe} 采用光谱信息散度—光谱角获得。具体定义为 (Xu 等, 2018):

$$D_{\text{Spa}} = \sqrt{(x_i^{\text{spa}} - x_{c_k}^{\text{spa}})^2 + (y_i^{\text{spa}} - y_{c_k}^{\text{spa}})^2} / r \quad (1)$$

$$D_{\text{Spe}} = \text{SID}(x_i, c_k) \times \tan(\text{SAM}(x_i, c_k)) \quad (2)$$

式中, r 表示归一化搜索范围的对角线长度。且

$$\text{SID}(x_i, c_k) = \sum_{j=1}^d (p_{ij} - p_{c_kj}) \log \left(\frac{p_{ij}}{p_{c_kj}} \right) \quad (3)$$

$$\text{SAM}(x_i, c_k) = \cos^{-1} \left(\frac{\langle x_i, c_k \rangle}{\|x_i\| \cdot \|c_k\|} \right) \quad (4)$$

式中, $p_{ij} = x_{ij} / \sum_{j=1}^d x_{ij}$, $p_{c_kj} = x_{c_kj} / \sum_{j=1}^d x_{c_kj}$; $\langle \cdot, \cdot \rangle$ 表示向量的内积; $\|\cdot\|$ 表示向量的模。

(3) 计算空—谱距离 $D(x_i, c_k)$ 。根据空间距离 D_{Spa} 和光谱距离 D_{Spe} 计算像元 x_i 与聚类中心 c_k 的空—谱距离 (Xu 等, 2018):

$$D(x_i, c_k) = (1 - \sigma) \times D_{\text{Spe}} + \sigma \times D_{\text{Spa}} \quad (5)$$

式中, $\sigma \in [0, 1]$ 表示平衡空间项和光谱项的权重因子。

(4) 更新聚类中心。根据式 (1)—(5) 计算各聚类中心 c_k 的 $N_x \times N_y$ 搜索范围内所有像元 x_i 与 c_k 的距离, 以各聚类中心子块内距离最小值对应的像元更新聚类中心, 为 $C^u = \{c_1^u, c_2^u, \dots, c_k^u, \dots, c_S^u\}$, 其中 c_k^u 的表达式为

$$c_k^u = \min_{x_i \in Z_k} \{D(x_i, c_k^{u-1})\} \quad (6)$$

式中, Z_k 表示第 k 个局部邻域集合; u 表示更新迭代次数。

(5) 终止迭代。一般迭代次数设置为 10 次, 完成迭代后输出最终局部邻域集合 $Z = \{Z_1, Z_2, \dots, Z_k, \dots, Z_S\}$ 和中心 $C = \{c_1, c_2, \dots, c_k, \dots, c_S\}$, 否则重复步骤 2—4 直到完成迭代。

(6) 降低局部邻域集合 Z_k 的光谱维度。由于 SLDA 方法不仅能最大程度减少数据冗余信息, 还能提取出最具判别性的稀疏特征, 并对图像中包含的异常值和噪声具有一定的鲁棒性。因此, 为了准确表征 HSI 的空间—光谱特征, 利用 SLDA 提取邻域集合 Z_k 的稀疏混合特征。为此, 求解以下目标函数得到线性变换矩阵 w_k^* (Li 等, 2020):

$$w_k^* = \arg \min_{w_k} \{\vartheta \|w_k\|_1 + \delta w_k^T S_w w_k\} \quad (7)$$

式中, $w_k \neq 0$; ϑ 和 δ 为调整参数, 值均大于 0; $S_w = \frac{1}{o} \sum_{i=1}^o (x_i - c_k)(x_i - c_k)^T$ 为类内散度矩阵。然后, 通过以下公式得到局部邻域集合 Z_k 的稀疏混合特征

$$Y_k = w_k^{*T} \times Z_k \quad (8)$$

(7) 输出 HSI 的所有邻域集合的稀疏混合特征 Y_k , 并表示为 $Y = \{Y_1, Y_2, \dots, Y_k, \dots, Y_S\} = \{y_1, y_2, \dots, y_i, \dots, y_N\}$ 。

2.2 核主成分分析法

基于同质局部邻域集合的 SSLDA 方法所提取的超像素稀疏混合特征, 虽然能够充分挖掘 HSI 的纹理结构信息和判别性光谱特征, 但是却忽略了不同局部邻域集合之间存在的内在联系, 从而导致得到的稀疏混合特征仍存在一定的数据冗余。考虑到核主成分分析 KPCA (Kernel Principal Component Analysis) (Yu 等, 2021) 利用核函数, 不仅获得数据的主成分信息, 还能使非线性数据线性可分 (Schölkopf 等, 1997)。因此, 本文对超像素稀疏混合特征应用 KPCA, 以至于能够得到更加精简和高区分性的特征信息。KPCA 的主要步骤

如下:

(1) 针对 HSI 的全局稀疏混合特征 Y , 利用非线性映射函数 $\phi(\cdot)$ 把 Y 映射到高维空间。由于 $\phi(\cdot)$ 不能显性给出, 因此令 $K = [\phi(Y)]^T \phi(Y)$, 则 Y 的主成分特征 t_i 计算如下 (Yu 等, 2021):

$$t_i = \alpha_i^T K \quad (9)$$

式中, $K \in \mathbb{R}^{N \times N}$ 表示通过高斯核函数得出的矩阵, α_i 表示 K 的第 i 个特征值 λ_i 对应的特征向量。

(2) 根据 $K\alpha_i = \lambda_i \alpha_i$ 计算出特征值 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$, 并取前 K 个特征值对应的特征向量 $\{\alpha_1, \alpha_2, \dots, \alpha_K\}$ 。

(3) 利用特征向量 α_i 和式 (9) 计算出 Y 的前 K 个主成分组成的特征矩阵 $T = [t_1, t_2, \dots, t_K]^T \in \mathbb{R}^{K \times N}$ 。

2.3 扩展的随机游走法

由于超像素降维提取的空谱特征容易导致分类方法在部分异质边缘区域的错分率较高, 然而扩展的随机游走算法 (Grady, 2006) 具有计算简单、搜索速度快、不受噪声影响和能够同时识别多个对象的特点。因此, 本文采用 ERW 编码 HSI 的空间信息至加权图中, 以刻画相邻像素之间的空间相关性, 并用之优化由 SVM 得到的初始类别概率向量。

首先, 利用已计算的主成分特征矩阵 T 代表高光谱图像的空间—光谱特征输入 SVM 分类器中, 得到的初始类别概率向量 $R_1 = \{r_1, r_2, \dots, r_i, \dots, r_N\} \in \mathbb{R}^{M \times N}$, 其中 $r_i = [r_i^1, r_i^2, \dots, r_i^M]^T$, 且 $\sum_{m=1}^M r_i^m = 1$, M 表示类别数量。ERW 对不同类别 m 的空间概率优化通过以下能量函数 (Duan 等, 2021) 来实现:

$$E^m(Q_m) = E_{\text{spa}}^m(Q_m) + \gamma E_{\text{aspa}}^m(Q_m) \quad (10)$$

式中, Q_m 表示根据训练样本的位置索引和标签值形成的类别 m 的区域像元集合; $E_{\text{spa}}^m(Q_m)$ 表示第 m 类像元集合相邻像素之间的空间相关性; $E_{\text{aspa}}^m(Q_m)$ 表示第 m 类像元初始类别概率的拉普拉斯—贝尔特拉米算子; γ 表示权重因子; 且有:

$$E_{\text{spa}}^m(Q_m) = Q_m^T L Q_m \quad (11)$$

$$E_{\text{aspa}}^m(Q_m) = \sum_{i=1, i \neq m} Q_i^T \Lambda_i Q_i + (Q_m - 1)^T \Lambda_m (Q_m - 1) \quad (12)$$

式中, Λ 表示由初始类别概率组成的对角线矩阵; L 表示对原始 HSI 利用 KPCA 计算的第一主成分特征的拉普拉斯矩阵 (Grady, 2006):

$$L_{ij} = \begin{cases} -\omega_{ij}, & v_i \text{ 和 } v_j \text{ 是相邻节点} \\ d_i, & i = j \\ 0, & \text{其他} \end{cases} \quad (13)$$

式中, v_i 和 v_j 表示图的顶点, 其中图是依据图像尺寸构建而成。 $\omega_{ij} = \exp\left(-\beta(g_i - g_j)^2\right)$ 表示连接 v_i 和 v_j 两个顶点的边界的权重值, 其中 β 为自由参数; $d_i = \sum \omega_{ij}$ 表示顶点 v_i 的阶数。

然后, 利用 (10) 式对不同类别的初始概率向量优化后得到所有类别的后验概率向量 R_2 。最后, 根据概率最大值获得 HSI 的分类标签图。

2.4 本文的算法

联合上述的超像素稀疏线性判别分析、核主成分分析和扩展的随机游走方法, 本文提出一种联合超像素降维和后验概率优化的高光谱图像分类模型, 为方便表达简称为 SKERW_SVM。其模型框架如图 1 所示, 算法的详细流程如下:

输入: 高光谱图像 $X \in \mathbb{R}^{m_1 \times m_2 \times d}$, 降维参数 l , 超像素数量 S 和核主成分数量 K 。

(1) 初始化聚类中心 $C = \{c_1, c_2, \dots, c_k, \dots, c_S\}$ 和局部邻域集合 $Z = \{Z_1, Z_2, \dots, Z_k, \dots, Z_S\}$;

(2) 基于式 (5)—(6) 和迭代次数不断更新 C 和 Z , 并获得最终的局部邻域集合;

(3) 利用式 (7)—(8) 计算 Z 中各邻域集合的超像素稀疏混合特征, 即得 $Y = \{Y_1, Y_2, \dots, Y_k, \dots, Y_S\}$;

(4) 采用式 (9) 获得 Y 的前 K 个主成分特征组成的矩阵 $T = [t_1, t_2, \dots, t_K]^T$;

(5) 针对 T 并按照一定比例选取训练样本和测试样本;

(6) 将训练样本和测试样本输入 SVM 分类器中, 得到初始类别概率向量 $R_1 = \{r_1, r_2, \dots, r_i, \dots, r_N\}$;


(7) 应用式 (10) 来优化初始类别概率, 得到 R_2 , 并依据概率最大值获得高光谱图像的分类标签图。

输出: HSI 的类别标签图。

2.5 评价指标

为了定量评估不同算法的分类性能, 本文采

用总体精度 OA (Overall Accuracy)、平均精度 AA (Average Accuracy) 和 Kappa 系数作为评价指标。OA 是指正确识别像素占图像总像素的百分比。AA 是指每类正确识别像素百分比的平均值。Kappa 系数是利用混淆矩阵计算出的统计量, 用来衡量预测标签和真实标签之间的一致性。



RC: 区域聚类算法; SLDA: 稀疏线性判别分析方法; KPCA: 核主成分分析方法; SVM: 支持向量机方法; ERW: 扩展的随机游走方法。

图1 联合超像素降维和后验概率优化的光谱图像分类模型 (SKERW_SVM) 框架图

Fig. 1 Outline of Hyperspectral-image classification method combining superpixel dimension reduction with post-processing optimization (SKERW_SVM)

各评价指标的具体定义为

$$OA = \frac{\sum_{i=1}^M F_{ii}}{\sum_{i=1}^M \sum_{j=1}^M F_{ij}} \quad (14)$$

$$AA = \frac{\sum_{i=1}^M CA_i}{\sum_{i=1}^M N_i} \quad (15)$$

$$Kappa = \frac{OA - F_e}{1 - F_e} \quad (16)$$

式中, M 表示高光谱图像类别数量; F 表示混淆矩阵; N_i 表示图像第 i 类测试样本总数; 且 $CA_i = \sum_{i=1}^M F_{ii} / N_i$ 和 $F_e = \sum_{i=1}^M F_{i \cdot} F_{\cdot i} / (\sum_{i=1}^M N_i)^2$; 其中 $F_{i \cdot}$ 和 $F_{\cdot i}$ 表示混淆矩阵第 i 行和第 i 列的和。OA、AA 和 Kappa

系数的值通常在 0—1, 三者值越高, 模型的分类性能越好。

3 实验与分析

实验在 Windows10 平台, 内存为 16GB 的 Intel (R) Core (TM) i7-10750H CPU 2.60GHz 计算机硬件环境中运行。软件环境为 MATLAB 2018b。

3.1 数据集介绍

本文采用 3 组常用的小规模数据集 Indian Pines、Pavia University 和 Salinas, 以及一组大规模数据集 HoustonU 来评估分类方法的性能。图 2 绘制了这 4 组数据集的假彩色图像和标准地物分类图像, 并给出了合成各数据集假彩色图像的波段序号。

(1) Indian Pines 是由 AVIRIS 传感器在 1992 年美国印第安纳州西北部的印第安松树场上空采集, 有 145×145 个像素和 224 个光谱带, 波长范围为 0.4—2.5 μm 。实验中选择去除 24 个吸水通道后的 200 个波段图像作为输入数据。其包含 16 类地物, 如图 2 (a) 所示。其中大部分地物为处于不同生长阶段的作物, 由于不同作物之间具有相似的光谱反射率, 因此具有一定的挑战性 (Mou 等, 2020)。

(2) Pavia University 是 2003 年在 Pavia 大学上空由 ROSIS 传感器采集的 610×340 图像大小的场景影像, 波长范围为 0.43—0.86 μm 。将 12 个噪声波段筛出后, 剩余 103 个波段图像应用于本次实验。图像包含沥青 (Asphalt)、碎石 (Gravel) 和裸露土壤 (Bare Soil) 等 9 类地物, 如图 2 (b) 所示。

(3) Salinas 是由 AVIRIS 传感器在加利福尼亚州的 Salinas 山谷采集的 224 个波段图像组成的数据集, 各波段图像尺寸为 512×217 像素, 其中包含了 16 个地物类别。除未分类像素外, 标准地物分类图像共 54129 标签像素可用, 如图 2 (c) 所示。在分类实验中, 选择去除了 20 个吸水带后的 204 个波段图像作为实验数据。

(4) HoustonU 是 2018 年 IEEE GRASS 数据融合分类挑战大赛发布的竞赛数据集, 由搭载在飞机上的 CASI 高光谱成像仪于 2017 年 2 月 16 日在休斯顿大学校园及其附近区域拍摄的场景图像, 包括 50 个波段和 20 类地物, 波长范围为 0.38—

1.05 μm , 图像的尺寸为 601×2384 像素, 有标签的像元共 504856 个, 如图 2 (d) 所示。与上述 3 组常用数据集相比, HoustonU 的地物类型和有标签样本量多, 空间范围广, 分类任务更加复杂。

有关本文数据集的详细介绍可参考网站 http://www.ehu.es/ccwintco/index.php?title=Hyperspectral_Remote_Sensing_Scenes 和 http://hyperspectral.ee.uh.edu/?page_id=1075 [2021-07-23]。




图2 可视化4组数据集的假彩色图像和标准地物分类图像
Fig. 2 Pseudo color and Ground-truth for following four datasets

3.2 参数分析

本节对 SKERW_SVM 方法中降维后的光谱维度 l 、超像素数量 S 和用于分类的核主成分数量 K 3 个重要参数进行优化分析。为检验所提出的方法在少量标签样本下的分类能力，本文将 3 组常用的 Indian Pines、Pavia University 和 Salinas 数据集的有标签样本分别随机划分为训练、验证和测试样本集，具体的划分样本数如表 1—3 所示。在这一节，选取训练样本训练模型，而依据验证样本集上的总体分类精度确定最优参数值，然后，在下一节利用测试集评估模型分类性能。图 3 展示了 l 、 S 和 K 的不同取值对 SKERW_SVM 方法在 3 组常用数据集上分类性能的影响。首先，初始化 $S = 100$ 和 $K = 20$ ，取 $l=1, 3, 5, 10, 15, 20, 25, 30, 35, 40$ ，和 50 分别对 3 组数据集进行分类实验，以识别参数 l 的最优值，如图 3 第 1 行的 3 小图所示，当 l 为 30、20 和 15 时，对应在 Indian Pines、Pavia University 和 Salinas 上获得最大 OA 值。然后，在 l 为最优值的条件下，讨论参数 S 的最优值。由于无论 KPCA 中的主成分数 K 取何值，与未使用 KPCA 的分类方法相比，其分类效果均有不同程度的提高。因此，在分析参数 S 时，不考虑 KPCA 的使用，以强调 S 对分类结果的影响。取 $S=10, 15, 20, 25, 30, 35, 40, 50, 60, 80, 100$ 和 120，分别对 3 组数据集进行分类实验，图 3 第 2 行的 3 小图呈现了所获得的总体分类精度。从图 3 第 2 行的 3 小图可知，在设置的参数范围内，Indian Pines、Pavia University 和 Salinas 数据集对应的最优 S 值分别为 50、20 和 15。由于参数 S 的最优取值与图像的纹理结构关系密切，合适的超像素数量有利于充分挖掘同质区域的高区分性特征。然而，无论 S 的大小如何，SKERW_SVM 的分类性能总是高于未进行超像素分割的方法，这与 Jiang 等 (2018) 中的结论是一致的。因此，对于 Salinas 数据集，尽管 SKERW_SVM 的最优参数 S 值稍小于该数据集的类别数，但本文提出的 SSLDA 方法仍能对模型分类性能起到提高的作用。最后，在 $\{1, 3, 5, 10, 15, 20, 25, 30\}$ 的集合中，当 l 和 S 均为最优值的条件下，讨论 3 组数据集上的最优 K 值。由图 3 第 3 行的 3 小图知，在 Indian Pines、Pavia University 和 Salinas 数据集上的最优参数 K 值依次为 20、25 和 20。

表 1 Indian Pines 数据集划分情况


Table 1 Data partitioning of the Indian Pines dataset				
类别号	类别	训练集	验证集	测试集
1	苜蓿	5	10	31
2	非犁耕玉米	70	80	1278
3	少犁耕玉米	50	60	720
4	玉米	20	40	177
5	草地/牧草	40	50	393
6	草地/树木	40	50	640
7	草地/修剪过的牧草	5	5	18
8	干草堆	40	40	398
9	燕麦	5	5	10
10	非犁耕大豆	50	60	862
11	少犁耕大豆	80	90	2285
12	清理过的大豆	50	60	483
13	小麦	20	40	145
14	木材	50	60	1155
15	建筑—草地—树木—机器	30	40	316
16	石钢塔	5	10	78
总计		560	700	8989

表 2 Pavia University 数据集划分情况

Table 2 Data partitioning of the Pavia University dataset				
类别号	类别	训练集	验证集	测试集
1	柏油路面	66	130	6435
2	草地	186	300	18163
3	砂砾屋顶建筑	21	40	2038
4	树木	31	60	2973
5	金属屋顶建筑	13	25	1307
6	裸地	50	100	4879
7	沥青屋顶建筑	13	25	1292
8	砖砌路面	37	80	3565
9	阴影	9	20	918
总计		426	780	41570

表 3 Salinas 数据集划分情况

Table 3 Data partitioning of the Salinas dataset				
类别号	类别	训练集	验证集	测试集
1	有杂草的西兰花地 1	20	40	1949
2	有杂草的西兰花地 2	30	60	3636
3	休耕地	20	40	1916
4	粗犁休耕地	15	30	1349
5	平整休耕地	30	60	2588
6	残茬地	40	80	3839
7	芹菜地	40	80	3459
8	未修建的葡萄藤	112	220	10939
9	待发展葡萄园区	62	120	6021
10	有杂草的枯玉米地	32	60	3186
11	4 周生菜地	10	20	1038
12	5 周生菜地	20	40	1867
13	6 周生菜地	10	20	886
14	7 周生菜地	10	20	1040
15	未管理的葡萄园	72	170	7026
16	葡萄园垂直支架区	20	40	1747
总计		543	1100	52486



图中 l 为降维后的光谱维度系数, S 为超像素系数, K 为用于分类的核主成分系数

图3 SKERW_SVM方法中参数 l 、 S 和 K 的不同取值对Indian Pines、Pavia University和Salinas数据集总体分类精度的影响
Fig. 3 The influences of the size of parameters l , S and K on the overall classification accuracy (%) of the proposed SKERW_SVM method for the Indian Pines, the Pavia University, and the Salinas datasets

3.3 实验设置

为评估SKERW_SVM在HSI分类任务上是否具有优良的分类性能,本文实验选择5个相关分类方法与SKERW_SVM在已选用的高光谱数据集上进行仿真对比实验。对比方法分别是:(1)传统的支持向量机分类器(Melgani和Bruzzone, 2004),简称为SVM;(2)利用主成分分析(PCA)提取HSI的光谱特征并将其作为HSI的图像信息输入SVM中的方法(Prasad和Bruce, 2008),简称为PCA_SVM;(3)采用一种结构轮廓SP(Structural Profile)自适应地提取HSI的空-谱特征并输入SVM的方法(Duan等, 2021),简称为SP_SVM;(4)一种以均质区域为混合特征提取单元的SPCA

并结合SVM的方法(Jiang等, 2018),简称为SPCA_SVM;(5)应用ERW编码HSI的空间信息至加权图中,并用之优化由SVM获得的类别概率向量的方法(Kang等, 2015),简称为ERW_SVM。此外,为评估SSLDA、KPCA和ERW对SKERW_SVM分类结果的阶段性贡献,本研究也进行了消融实验。其对比方法包括:(1)仅利用SSLDA提取混合特征即输入SVM的方法,简称为SSLDA_SVM;(2)利用SSLDA和KPCA提取混合特征并输入SVM的方法,简称为SKPCA_SVM。在所有对比方法的分类实验中,涉及与本文提出的SKERW_SVM方法同样的参数时,均设置一致。其中,SVM分类器采用径向基核函数,通过5次交叉验证方法选择分类模型参数。

由于训练样本和测试样本是按照一定比例随机分布，从而导致分类精度容易产生较小的误差，因此对所有方法均重复 10 次，取平均值作为最终

3.4 结果与分析

根据表 1—3 所示的各数据集训练样本和测试

样本的数量随机生成训练集和测试集，分析 SKERW_SVM 与所选对比方法分别在小规模数据集 Indian Pines、Pavia University 和 Salinas 上的分类效果，各分类模型的 OA、AA 和 Kappa，及单个类别的精度结果分别如表 4—6 所示，可视化各模型

的分类标签图分别如图 4—6 所示。

表 4 8 种算法在 Indian Pines 数据集上的分类精度
Table 4 Classification accuracy of eight methods on the Indian Pines dataset

类别号	SVM	PCA_SVM	SP_SVM	SPCA_SVM	ERW_SVM	SSLDA_SVM	SKPCA_SVM	SKERW_SVM
1	76.19	59.09	100.00	50.00	100.00	88.45	71.43	100.00
2	75.12	58.79	96.61	90.13	96.00	87.65	91.30	99.06
3	59.71	59.63	98.89	85.87	98.91	81.40	84.11	100.00
4	54.92	38.16	98.59	73.22	96.64	88.63	79.92	98.34
5	83.49	81.50	99.58	97.74	99.57	93.09	93.98	99.79
6	88.63	87.98	100.00	100.00	99.86	94.97	94.28	99.73
7	92.31	88.89	100.00	0.00	100.00	94.95	100.00	100.00
8	92.50	90.43	100.00	100.00	100.00	99.75	95.98	99.58
9	73.68	50.00	100.00	100.00	100.00	83.55	70.59	100.00
10	76.28	64.21	91.93	93.94	98.98	88.79	90.67	98.00
11	75.52	72.00	96.36	94.81	96.67	92.26	93.77	97.85
12	57.00	49.75	96.31	71.33	97.67	85.06	76.99	94.27
13	94.53	94.09	100.00	99.51	100.00	95.81	97.84	100.00
14	94.33	90.95	99.92	99.14	99.29	98.84	99.92	99.14
15	61.34	49.36	100.00	99.22	99.48	98.33	93.66	98.97
16	100.00	97.18	98.80	94.59	96.84	97.54	100.00	100.00
OA	76.69	70.30	97.47	92.41	98.06	91.45	91.77	98.58
AA	78.47	70.75	98.56	84.34	98.75	91.82	89.65	99.05
Kappa	73.50	66.16	97.12	91.34	97.78	90.23	90.62	98.38

注：加粗表示最高分类精度。

表 5 8 种算法在 Pavia University 数据集上的分类精度
Table 5 Classification accuracy of eight methods on the Pavia University dataset

类别号	SVM	PCA_SVM	SP_SVM	SPCA_SVM	ERW_SVM	SSLDA_SVM	SKPCA_SVM	SKERW_SVM
1	80.20	76.18	90.21	75.20	91.12	85.52	85.61	92.59
2	91.17	88.12	99.06	96.02	96.61	91.59	92.54	97.24
3	67.97	65.11	90.94	89.70	99.95	75.89	68.83	99.95
4	96.65	94.84	91.84	85.26	99.58	86.40	96.76	99.70
5	98.81	100.00	86.54	95.63	99.93	98.34	99.26	99.70
6	85.30	87.47	99.58	90.99	97.80	88.04	90.66	96.86
7	100.00	35.00	94.66	86.22	100.00	61.23	74.20	100.00
8	80.42	68.71	92.36	79.87	98.25	80.02	71.88	97.19
9	100.00	100.00	87.01	90.02	99.88	100.00	99.89	99.89
OA	87.19	84.01	95.51	89.13	96.53	87.89	88.62	96.88
AA	88.95	79.49	92.47	87.66	98.12	85.23	86.63	98.13
Kappa	82.74	78.26	94.03	85.50	95.35	83.76	84.70	95.83

注：加粗表示最高分类精度。

表 6 8 种算法在 Salinas 数据集上的分类精度

Table 6 Classification accuracy of eight methods on the Salinas dataset

类别号	SVM	PCA_SVM	SP_SVM	SPCA_SVM	ERW_SVM	SSLDA_SVM	SKPCA_SVM	SKERW_SVM
1	100.00	99.95	100.00	100.00	100.00	95.05	98.43	100.00
2	99.22	99.68	100.00	100.00	100.00	99.52	97.04	100.00
3	86.12	93.73	99.55	95.60	99.55	98.40	81.38	99.76
4	97.17	99.13	97.56	99.05	97.34	97.20	97.96	92.45
5	97.63	93.33	91.71	93.91	99.96	96.33	97.97	100.00
6	100.00	100.00	100.00	100.00	100.00	99.74	99.95	100.00
7	96.92	100.00	100.00	99.92	99.94	97.36	96.41	99.89
8	71.42	78.69	96.49	95.31	94.68	81.14	78.29	96.98
9	99.36	98.94	100.00	98.66	99.98	92.98	94.89	99.37
10	80.17	93.96	96.95	98.66	99.20	71.22	80.13	95.89
11	97.20	96.53	97.23	100.00	97.36	93.48	89.63	97.09
12	90.73	98.31	97.47	98.27	100.00	95.04	95.49	96.15
13	95.01	97.49	91.16	96.03	100.00	86.76	89.37	98.46
14	92.20	98.43	100.00	94.93	99.34	82.08	97.35	100.00
15	57.19	77.47	98.00	95.90	96.68	84.11	84.23	99.73
16	97.79	99.12	100.00	100.00	100.00	99.68	99.48	100.00
OA	85.40	91.24	97.98	97.52	98.22	89.43	89.28	98.54
AA	91.13	95.30	97.88	97.90	99.00	91.88	92.38	98.49
Kappa	83.77	90.23	97.75	97.23	98.02	88.20	88.02	98.38

注：加粗表示最高分类精度。




图 4 8 种算法在 Indian Pines 数据集上的可视化分类结果

Fig. 4 Classification maps obtained by eight methods on the Indian Pines dataset





图5 8种算法在Pavia University数据集上的可视化分类结果

Fig. 5 Classification maps obtained by eight methods on the Pavia University dataset






图6 8种算法在Salinas数据集上的可视化分类结果

Fig. 6 Classification maps obtained by eight methods on the Salinas dataset

由表4—6可见SKERW_SVM方法在3组小规模数据集的少训练样本分类实验中都获得了最高的OA和Kappa值,以及多个单类别精度的最高值。这是由组成所提方法的SSLDA、KPCA和ERW共同作用产生的结果,因方法依次利用了高判别性的稀疏混合特征信息、不同局部邻域之间的内在联系以及相邻像素之间的空间相关性,从而在训练样本有限的条件下,SKERW_SVM仍能表现出优良的分类性能。如在Indian Pines和Salinas数据集的分类实验中,SKERW_SVM的OA值和Kappa系数都以超过98%的分类精度,成为对比方法中的最优模型;在Pavia University的实验中,SKERW_SVM取得了高达98.13%的平均精度。其次,在Salinas的实验中,与SVM相比,由于PCA_SVM、SP_SVM、SPCA_SVM、SSLDA_SVM、SKPCA_SVM和SKERW_SVM均考虑了对原始谱域降低维度,提取判别性的特征信息后再输入分类器进行标签识别,从而减少了数据冗余和避免了休斯现象,因此他们的分类精度较SVM有大幅度的提升。如表6所示,SKERW_SVM在Salinas数据集上的OA、AA和Kappa值比SVM分别提高了13.14%、7.63%和14.61%。然而,在Indian Pines和Pavia University数据集上,除PCA_SVM外,其余6种方法均比SVM的识别率高,这可能是由于

本文确定的降维参数值不是PCA_SVM方法的最优参数,从而导致提取的谱特征信息不够充分。然后,从表4—6可以明显发现,联合空谱信息的SKERW_SVM等HSI分类方法明显高于仅考虑光谱信息的PCA_SVM,正如闫敬文等(2019)和Duan等(2021)所指出:仅利用光谱信息的方法难以实现HSI的精确分类。最后,观察在Indian Pines和Pavia University数据集上的实验结果,SKERW_SVM的OA值较SP_SVM分别提升了1.11%和1.37%的正确率,较SPCA_SVM分别提高了6.17%和7.75%的正确率。且在Salinas的分类实验中,SKERW_SVM较SP_SVM和SPCA_SVM分别提升了0.56%和1.02%的正确率。这是由于,虽然SP_SVM关注到光谱信息和空间信息的重要性,却未考虑两者之间的相关性,而SKERW_SVM不仅利用了HSI的空间—光谱特征,还注意到HSI图像存在均匀同质区域,并基于这些局部邻域集合结合稀疏算法提取混合特征,有效提高了属于不同目标的像素可分性;另一方面,由于图像分割生成的聚类区域并不能与所有地物的边缘贴合一致,导致在部分超像素分割边缘的目标像素中识别率普遍偏低,而SKERW_SVM利用HSI相邻像素之间的空间相关性弥补了这一问题,从而使得SKERW_SVM在分类精度上大于SPCA_SVM。

观察图4—6，并对比图2中的标准地物分类图像可以发现，SVM和PCA_SVM得到的分类结果图像产生类似于“椒盐噪声”的现象，SKERW_SVM、SP_SVM和ERW_SVM得到的分类标签图最接近标准地物分类图像，这与表4—6得到的结果一致。受制于光谱信息的局限性，SVM和PCA_SVM对HSI的分类能力不高。由于SPCA_SVM、SSLDA_SVM和SKPCA_SVM考虑了高光谱图像的空间结构信息、光谱信息和空—谱变化信息，因此分类精度较仅基于谱域的SVM有一定程度的提高，这种现象在Indian Pines数据集上尤为明显。但因为SPCA_SVM、SSLDA_SVM和SKPCA_SVM方法在部分分割区域边缘贴合度一般，导致基于这些区域的光谱降维容易在异质边缘产生“噪声”。而SKERW_SVM利用了后验概率模型—扩展的随机游走算法弥补了超像素降维带来的“后遗症”，从而提高了模型整体的识别能力。

在消融实验中，对比SKPCA_SVM和SSLDA_SVM可以发现，KPCA整体上提高了模型的分类性能，这是由于KPCA把不同区域的稀疏混合特征融合在一起，进一步增强了不同类别像元之间的区分度和降低了数据冗余。观察SKERW_SVM和SKPCA_SVM的分类精度（表4—6）和分类结果图像（图4—6）可以发现，ERW解决了基于局部邻域集合提取的稀疏混合特征输入SVM后在异质边缘区域产生的“噪声”问题，显著提高了模型的性能。如在Indian Pines数据集上，SKERW_SVM的OA值比SKPCA_SVM提升了6.81的百分点。此外，本文提出的SKERW_SVM在3个数据集上的分类性能均较优于ERW_SVM方法，这间接体现了所提出的SSLDA方法可有效提高模型的分类精度。这是由于SSLDA在利用高光谱图像空间纹理信息构建的局部邻域集合的基础上，挖掘了HSI的高判别性稀疏混合特征，那充分表达了HSI的空谱信息和相关变化信息，从而减少了光谱维度，以及在分类的过程中加大了样本间的可分性，从而提高了SKERW_SVM的分类性能。

为了进一步验证本文提出的SKERW_SVM在大规模数据集上是否仍然具有优良的分类性能，本文选取HoustonU数据集作为实验对象，分析SKERW_SVM与5种对比方法的分类效果。为确定SKERW_SVM在HoustonU上的最优参数，将该数

据集的有标签样本随机划分为训练集、验证集和测试集，具体的划分样本数量分布如表7所示。首先，利用训练集和验证集获得SKERW_SVM的参数 l 、 S 和 K 的最优值分别为25、15和25。然后，依据划分的训练集和测试集开展对比实验，表8列出了各分类方法的分类精度，且图7展示了他们的分类标签图。从表8可以看到，本文的SKERW_SVM在HoustonU数据集上以最高的OA、AA和Kappa值成为对比方法中的最优方法，尤其是相较于SPCA_SVM和PCA_SVM，SKERW_SVM的OA值分别提高了3.56%和9.32%的正确率，这表明本文提出的HSI分类方法在大规模数据集上具有一定的有效性。观察图7可以发现，利用SKERW_SVM、SP_SVM和ERW_SVM获得的分类标签图比应用SVM和PCA_SVM得到的结果图像更不容易产生类似于“椒盐噪声”的现象，且更接近于HoustonU的标准地物分类图像，这也进一步验证SKERW_SVM具有优良的分类性能。

表7 HoustonU数据集划分情况
Table 7 Data partitioning of the HoustonU dataset

类别号	类别	训练集	验证集	测试集
1	健康草地	500	500	8799
2	受践踏草地	500	500	31502
3	人造草坪	68	68	548
4	常绿树林	500	500	12595
5	落叶树林	500	500	4021
6	裸土	451	451	3614
7	水面	26	26	214
8	住宅区	500	500	38772
9	商业区	2237	500	221015
10	道路	500	500	44866
11	人行道	500	500	33029
12	人行横道	151	151	1216
13	主要干道	500	500	45348
14	公路	500	500	8865
15	铁路	500	500	5937
16	停车场1	500	500	10500
17	停车场2	14	14	118
18	汽车	500	500	5547
19	火车	500	500	4369
20	体育场座椅	500	500	5824
总计		9947	8210	486699

表 8 6种算法在 HoustonU 数据集上的分类精度

Table 8 Classification accuracy of six methods on the HoustonU dataset

类别号	SVM	PCA_SVM	SP_SVM	SPCA_SVM	ERW_SVM	SKERW_SVM
1	88.96	75.34	57.89	70.96	56.98	82.95
2	95.59	91.20	91.07	92.41	89.03	81.87
3	100.00	100.00	100.00	100.00	100.00	100.00
4	86.69	84.76	79.55	85.12	78.81	91.62
5	66.63	60.88	75.66	68.10	70.72	93.68
6	94.08	90.19	100.00	95.37	97.22	99.34
7	99.62	100.00	100.00	100.00	100.00	100.00
8	88.39	74.04	97.91	91.55	97.22	96.98
9	94.01	93.98	96.91	96.03	97.43	85.10
10	68.17	64.63	80.88	76.20	85.83	76.94
11	68.06	62.39	65.39	68.97	74.66	81.85
12	26.72	22.93	27.42	20.07	25.72	80.16
13	75.32	69.80	91.21	78.32	90.23	86.10
14	64.37	54.35	94.84	64.01	88.60	97.04
15	86.26	83.90	99.11	97.45	98.22	97.85
16	84.76	75.04	94.96	89.07	91.82	87.30
17	94.63	97.87	100.00	98.50	92.99	100.00
18	71.75	59.24	73.51	79.99	94.39	99.30
19	72.46	74.16	98.69	97.75	97.99	100.00
20	95.16	90.32	99.80	95.14	99.69	100.00
OA	85.64	81.69	90.03	87.45	90.97	91.01
AA	81.08	76.25	86.24	83.25	86.38	91.90
Kappa	81.41	76.40	87.05	83.77	88.29	90.45

注：加粗表示最高分类精度。




图 7 6种算法在 HoustonU 数据集上的可视化分类结果

Fig. 7 Classification maps obtained by six methods on the HoustonU dataset

与此同时，为了更好的说明本文提出方法的分类性能，实验记录了各对比方法在4组数据集上的仿真运行时间，如表9所示。通过比较发现，PCA_SVM在Pavia University数据集上的运行时间最少，而SPCA_SVM在另外3组数据集上耗时最短，但PCA_SVM和SPCA_SVM的分类精度较SP_SVM、ERW_SVM和SKERW_SVM方法却相对

较低。其次，尽管ERW_SVM的分类精度仅次于SKERW_SVM，然而它的实验运行时间在所有对比方法中最长，尤其是在Indian Pines数据集上，ERW_SVM的时间成本约为SKERW_SVM的四倍。因此，综合考虑分类精度和时间成本，本文提出的方法在高光谱图像分类任务是更可取的。

表9 6种算法在Indian Pines、Pavia University、Salinas和HoustonU数据集上的运行时间
Table 9 The computing time of six methods on the Indian Pines, Pavia University, Salinas and HoustonU datasets

数据集	算法					
	SVM	PCA_SVM	SP_SVM	SPCA_SVM	ERW_SVM	SKERW_SVM
Indian Pines	35.47	8.03	6.81	5.85	36.91	9.52
Pavia University	13.51	6.32	11.39	7.52	16.93	12.28
Salinas	35.26	6.10	6.85	4.52	37.27	23.01
HoustonU	1922.56	1547.94	1546.84	1167.47	1953.24	1706.53

4 结 论

本文提出了一种联合超像素降维和后验概率优化的高光谱图像分类方法，旨在解决小样本标签条件下空间—光谱信息利用不充分导致的图像分类精度较低的问题。提出的方法采用区域聚类的图像分割方法，为HSI的像元构建局部邻域集合，这准确地利用了高光谱图像的空间信息。其次，基于同质的局部邻域集合应用降维方法提取高判别性的稀疏混合特征，深度挖掘了HSI的空间纹理信息、不同维度光谱间的联系以及空间—光谱变化信息。同时，应用的后验概率模型有效降低了因超像素降维导致的部分分割边缘像素错分率较高的现象，这在很大程度上提高了分类精度。在4组高光谱数据集上的实验结果充分证明了所提方法的有效性，结果表明：本文方法能够自适应地提取高光谱图像的高判别性特征信息，并在少量的样本标签下，分类精度均优于目前几种先进的分类方法，且时间损耗适中。

志 谢 由衷地感谢巴斯克大学计算情报小组分享了开源可用的Indian Pines、Pavia University和Salinas数据集，以及IEEE GRSS图像分析和数据融合技术委员会与休斯顿大学的高光谱图像分析实验室分发的HoustonU数据集！

参考文献(References)

Achanta R, Shaji A, Smith K, Lucchi A, Fua P and Süsstrunk S. 2012.

SLIC superpixels compared to state-of-the-art superpixel methods. IEEE Transactions on Pattern Analysis and Machine Intelligence, 34(11): 2274-2282 [DOI: 10.1109/TPAMI.2012.120]
Blanzieri E and Melgani F. 2008. Nearest neighbor classification of remote sensing images with the maximal margin principle. IEEE Transactions on Geoscience and Remote Sensing, 46(6): 1804-1811 [DOI: 10.1109/TGRS.2008.916090]
Camps-Valls G and Bruzzone L. 2005. Kernel-based methods for hyperspectral image classification. IEEE Transactions on Geoscience and Remote Sensing, 43(6): 1351-1362 [DOI: 10.1109/TGRS.2005.846154]
Carrino T A, Crósta A P, Toledo C L B and Silva A M. 2018. Hyperspectral remote sensing applied to mineral exploration in southern Peru: a multiple data integration approach in the Chapi Chiara gold prospect. International Journal of Applied Earth Observation and Geoinformation, 64: 287-300 [DOI: 10.1016/j.jag.2017.05.004]
Cheng W J and Chen W Q. 2020. Hyperspectral image classification based on MCFN-Attention. Computer Engineering and Applications, 56(24): 201-206 (程文娟, 陈文强. 2020. 基于MCFN-Attention的高光谱图像分类. 计算机工程与应用, 56(24): 201-206) [DOI: 10.3778/j.issn.1002-8331.1911-0102]
Dong A G, Zhang Q, Liu H C and Liang M M. 2019. Hyperspectral image classification based on TSNE and multiscale sparse auto-encoder. Computer Engineering and Applications, 55(21): 177-182, 219 (董安国, 张倩, 刘洪超, 梁苗苗. 2019. 基于TSNE和多尺度稀疏自编码的高光谱图像分类. 计算机工程与应用, 55(21): 177-182, 219) [DOI: 10.3778/j.issn.1002-8331.1903-0155]
Dong X F, Gan F P, Li N, Yan B K, Zhang L, Zhao J Q, Yu J C, Liu R Y and Ma Y N. 2020. Fine mineral identification of GF-5 hyperspectral image. Journal of Remote Sensing (Chinese), 24(4): 454-464 (董新丰, 甘甫平, 李娜, 闫柏琨, 张磊, 赵佳琪, 于峻川, 刘睿源, 马燕妮. 2020. 高分五号高光谱影像矿物精细识别. 遥感学报, 24(4): 454-464) [DOI: 10.11834/jrs.20209194]
Duan P H, Ghamisi P, Kang X D, Rasti B, Li S T and Gloaguen R. 2021. Fusion of dual spatial information for hyperspectral image

- classification. *IEEE Transactions on Geoscience and Remote Sensing*, 59(9): 7726-7738 [DOI: 10.1109/TGRS.2020.3031928]
- Felzenszwalb P F and Huttenlocher D P. 2004. Efficient graph-based image segmentation. *International Journal of Computer Vision*, 59(2): 167-181 [DOI: 10.1023/B:VISI.0000022288.19776.77]
- Fu Q, Guo C and Luo W L. 2020. A hyperspectral image classification method based on spectral-spatial features. *Laser and Optoelectronics Progress*, 57(20): 202803 (付青, 郭晨, 罗文浪. 2020. 一种利用空谱联合特征的高光谱图像分类方法. *激光与光电子学进展*, 57(20): 202803) [DOI: 10.3788/LOP57.202803]
- Gao K L, Yu X C, Song Z H, Zhang J, Liu B and Sun Y F. 2021. Deep capsule network combined with spatial-spectral information for hyperspectral image classification. *National Remote Sensing Bulletin*, 25(6): 1257-1269 (高奎亮, 余旭初, 宋治杭, 张晋, 刘冰, 孙一帆. 2021. 联合空谱信息的高光谱影像深度胶囊网络分类. *遥感学报*, 25(6): 1257-1269) [DOI: 10.11834/jrs.20210309]
- Grady L. 2006. Random walks for image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 28(11): 1768-1783 [DOI: 10.1109/TPAMI.2006.233]
- Hua Y, Zhang T, Xi H W, Wang Y F and Huang X L. 2012. Research on method of hyperspectral remote sensing image classification based on decision tree. *Computer Technology and Development*, 22(6): 198-202 (华晔, 张涛, 奚后玮, 王玉斐, 黄秀丽. 2012. 基于决策树的高光谱遥感影像分类方法研究. *计算机技术与发展*, 22(6): 198-202)
- Jiang J J, Ma J Y, Chen C, Wang Z Y, Cai Z H and Wang L Z. 2018. SuperPCA: a superpixelwise PCA approach for unsupervised feature extraction of hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 56(8): 4581-4593 [DOI: 10.1109/TGRS.2018.2828029]
- Kang X D, Li S T, Fang L Y, Li M X and Benediktsson J A. 2015. Extended random walker-based classification of hyperspectral images. *IEEE Transactions on Geoscience and Remote Sensing*, 53(1): 144-153 [DOI: 10.1109/TGRS.2014.2319373]
- Li C N, Shao Y H, Yin W T and Liu M Z. 2020. Robust and sparse linear discriminant analysis via an alternating direction method of multipliers. *IEEE Transactions on Neural Networks and Learning Systems*, 31(3): 915-926 [DOI: 10.1109/TNNLS.2019.2910991]
- Li D, Kong F Q and Zhu D Y. 2021. Hyperspectral image classification based on local Gaussian mixture feature extraction. *Acta Optica Sinica*, 41(6): 0610001 (李丹, 孔繁镨, 朱德燕. 2021. 基于局部高斯混合特征提取的高光谱图像分类. *光学学报*, 41(6): 0610001) [DOI: 10.3788/AOS202141.0610001]
- Li F Y, Huo H T, Li J and Bai J. 2019. Hyperspectral image classification via multiple-feature-based improved sparse representation. *Acta Optica Sinica*, 39(5): 0528004 (李非燕, 霍宏涛, 李静, 白杰. 2019. 基于多特征和改进稀疏表示的高光谱图像分类. *光学学报*, 39(5): 0528004) [DOI: 10.3788/AOS201939.0528004]
- Li W, Chen C, Su H J and Du Q. 2015. Local binary patterns and extreme learning machine for hyperspectral imagery classification. *IEEE Transactions on Geoscience and Remote Sensing*, 53(7): 3681-3693 [DOI: 10.1109/TGRS.2014.2381602]
- Liang L, Di L P, Zhang L P, Deng M X, Qin Z H, Zhao S H and Lin H. 2015. Estimation of crop LAI using hyperspectral vegetation indices and a hybrid inversion method. *Remote Sensing of Environment*, 165: 123-134 [DOI: 10.1016/j.rse.2015.04.032]
- Melgani F and Bruzzone L. 2004. Classification of hyperspectral remote sensing images with support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*, 42(8): 1778-1790 [DOI: 10.1109/TGRS.2004.831865]
- Mou L C, Lu X Q, Li X L and Zhu X X. 2020. Nonlocal graph convolutional networks for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 58(12): 8246-8257 [DOI: 10.1109/TGRS.2020.2973363]
- Prasad S and Bruce L M. 2008. Limitations of principal components analysis for hyperspectral target recognition. *IEEE Geoscience and Remote Sensing Letters*, 5(4): 625-629 [DOI: 10.1109/LGRS.2008.2001282]
- Schölkopf B, Smola A and Müller K R. 1997. Kernel principal component analysis//7th International Conference on Artificial Neural Networks. Lausanne: Springer: 583-588 [DOI: 10.1007/BFb0020217]
- Shi J B and Malik J. 2000. Normalized cuts and image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(8): 888-905 [DOI: 10.1109/34.868688]
- Song X Y, Zhou L L, Li Z G, Chen J, Zeng L and Yan B. 2015. Review on superpixel methods in image segmentation. *Journal of Image and Graphics*, 20(5): 599-608 (宋熙煜, 周利莉, 李中国, 陈健, 曾磊, 闫斌. 2015. 图像分割中的超像素方法研究综述. *中国图象图形学报*, 20(5): 599-608) [DOI: 10.11834/jig.20150502]
- Vincent L and Soille P. 1991. Watersheds in digital spaces: an efficient algorithm based on immersion simulations. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 13(6): 583-598 [DOI: 10.1109/34.87344]
- Wei X P, Yu X C, Zhang P Q, Zhi L and Yang F. 2020. CNN with local binary patterns for hyperspectral images classification. *Journal of Remote Sensing (Chinese)*, 24(8): 1000-1009 (魏祥坡, 余旭初, 张鹏强, 职露, 杨帆. 2020. 联合局部二值模式的CNN高光谱图像分类. *遥感学报*, 24(8): 1000-1009) [DOI: 10.11834/jrs.20208333]
- Xu D, Yang M, Miao Y H, Yan J and Sun M. 2020. Research and application of accurate extraction method of island shoreline based on hyperspectral remote sensing of unmanned aerial vehicle. *Marine Sciences*, 44(12): 54-60 (徐栋, 杨敏, 苗宇宏, 严晋, 孙苗. 2020. 基于无人机高光谱遥感的海岛岸线精准提取方法研究与应用. *海洋科学*, 44(12): 54-60) [DOI: 10.11759/hyxx20200529002]
- Xu X, Li J, Wu C S and Plaza A. 2018. Regional clustering-based spatial preprocessing for hyperspectral unmixing. *Remote Sensing of Environment*, 204: 333-346 [DOI: 10.1016/j.rse.2017.10.020]
- Yan J W, Chen H D and Liu L. 2019. Overview of hyperspectral image classification. *Optics and Precision Engineering*, 27(3): 680-693 (闫敬文, 陈宏达, 刘蕾. 2019. 高光谱图像分类的研究进展. *光学精密工程*, 27(3): 680-693) [DOI: 10.3788/OPE.20192703.0680]
- Yu H Y, Xu Z, Wang Y L, Jiao T and Guo Q D. 2021. The use of KP-CA over subspaces for cross-scale superpixel based hyperspectral

- image classification. Remote Sensing Letters, 12(5): 470-477 [DOI: 10.1080/2150704X.2021.1897180]
- Zhang X D, Wang T J, Zhu S J and Yang Y. 2021. Hyperspectral image classification based on dilated convolutional attention neural network. Acta Optica Sinica, 41(3): 0310001 (张祥东, 王腾军, 朱劭俊, 杨耘. 2021. 基于扩张卷积注意力神经网络的高光谱图像分类. 光学学报, 41(3): 0310001) [DOI: 10.3788/AOS202141.0310001]
- Zheng C Y, Wang N N and Cui J. 2019. Hyperspectral image classification with small training sample size using superpixel-guided training sample enlargement. IEEE Transactions on Geoscience and Remote Sensing, 57(10): 7307-7316 [DOI: 10.1109/TGRS.2019.2912330]

Hyperspectral-image classification method combining superpixel dimension reduction with post-processing optimization

HUANG Yuan, HE Xinguang, WAN Yiliang

1. College of Geographic Sciences, Hunan Normal University, Changsha 410081, China;
2. Key Laboratory of Geospatial Big Data Mining and Application, Hunan Province, Changsha 410081, China

Abstract: Hyperspectral image (HSI) classification is one of the fundamental tasks in the field of applied remote sensing. As technological advances have increased the spatial and spectral resolutions available for data acquisition, the problem of achieving accurate HSI classification is becoming more challenging. This problem is especially true for the HSI data with small labeled training samples and insufficient utilization of spatial-spectral information in HSI classification models. Aiming at these problems, this paper proposes a new HSI classification method (expressed as SKERW_SVM) by combining the Superpixel Dimension Reduction (SDR) with post-processing optimization.

First, we develop a Superpixel Sparse Linear Discriminant Analysis (SSLDA) method by combining Regional Clustering (RC) with SLDA. In the SSLDA method, the RC is applied to construct a homogeneous local neighborhood set with high spatial correlation and spectral similarity for each pixel of the HSI. The SLDA is used to extract superpixel sparse mixture features that can fully characterize spatial-spectral information and related change information of the HSI based on the constructed homogeneous regions. Then, the extracted sparse mixture features are inputted into the support vector machine to generate the class probabilities of all pixels. Finally, the original class probabilities are optimized in the post-processing step by the extended random walker that can express the spatial relationship among adjacent pixels quantitatively. The classification map is obtained according to the maximum probability.

To assess the performance of the proposed method, a series of experiments is conducted on three small-scale HSI datasets, including Indian Pines, University of Pavia, and Salinas, as well as a large-scale HSI dataset HoustonU. The proposed SKERW_SVM obtains overall accuracies of 98.58%, 96.88%, 98.54%, and 91.01% on Indian Pines, University of Pavia, Salinas, and HoustonU, respectively. Experimental results demonstrate that our SKERW_SVM can fully mine the joint spatial-spectral features of HSI and achieve higher classification accuracy under the case of small labeled training samples compared with several related advanced methods. Moreover, the operation time consumed by SKERW_SVM is more appropriate than that by other methods.

Under the lack of the labeled HSI pixel condition, the proposed HSI classification method by combining the SDR with post-processing optimization can efficiently extract the high-discrimination mixture feature information of HSI and significantly enhance classification performance. The SDR based on the homogeneous local regions, one of the components of the SKERW_SVM classification model, can greatly reduce the data redundancy and fully extract the information of spatial and spectral signatures compared with pixel-wise dimension-reduction methods. Meanwhile, the extended random walker in the post-processing step can fully use the spatial information of HSI by constructing a relationship graph to optimize the original class probabilities, thereby further improving the classification performance.

Key words: remote sensing, hyperspectral image classification, superpixel dimension reduction, mixture feature extraction, post-processing optimization, support vector machine

Supported by Science and Technology Project of Department of Natural Resources of Hunan Province (No. 2021-45)