

联合超像素主成分分析降维和扩展随机游走概率优化的 高光谱图像分类

胡德嘉^{1,2}, 黄媛^{1,2}, 杨斌^{1,2*}, 贺新光^{1,2}

¹湖南师范大学地理科学学院, 湖南 长沙 410081;

²地理空间大数据挖掘与应用湖南省重点实验室, 湖南 长沙 410081

摘要 针对高光谱图像分类中小规模训练样本下空间信息利用不足和分类精度下降问题,提出一种联合超像素降维和类别后验概率优化的高光谱图像分类方法。首先根据高光谱图像的空间纹理结构,采用熵率超像素分割算法自适应地识别均匀同质超像素区域,对每个区域逐一应用主成分分析,挖掘能表征图像空间-光谱信息的超像素混合特征;然后将混合特征输入支持向量机中计算各像元初始类别概率向量,采用扩展随机游走算法利用图像空间邻域信息对初始类别进行后验概率优化;最后根据各像元最大类别概率确定分类结果。在 Indian Pines、Pavia University 和 Salinas 等 3 组通用高光谱数据集上开展实验,与其他 6 种方法进行对比,实验结果表明:在有限训练样本条件下,所提方法的总体分类精度分别为 98.29%、97.29% 和 99.72%,优于对比方法的分类结果。

关键词 图像处理; 高光谱图像分类; 超像素降维; 扩展随机游走; 支持向量机

中图分类号 TP751

文献标志码 A

DOI: 10.3788/LOP220621

Hyperspectral Image Classification Combining Superpixel Principal Component Analysis Dimensionality Reduction with Extended Random Walk Probability Optimization

Hu Dejia^{1,2}, Huang Yuan^{1,2}, Yang Bin^{1,2*}, He Xinguang^{1,2}

¹College of Geographic Sciences, Hunan Normal University, Changsha 410081, Hunan, China;

²Hunan Key Laboratory of Geospatial Big Data Mining and Application, Changsha 410081, Hunan, China

Abstract A hyperspectral image classification method based on joint hyperpixel dimension reduction and category posterior probability optimization is proposed to address the issues of inadequate utilization of spatial information and decline in classification accuracy under small- and medium-sized training samples. First, the entropy rate hyperpixel segmentation algorithm, based on the spatial texture structure of hyperspectral images was used to adaptively detect homogeneous hyperpixel regions, and principal component analysis was applied to each region individually to mine the hyperpixel mixture features that can represent the spatial-spectral information of images. Then, the initial category probability vector of each pixel was calculated using the mixed features provided in the support vector machine, and the extended random walk algorithm was used to optimize the initial category using the image space neighborhood information. Finally, the classification result was calculated based on the maximum classification probability of each pixel. Experiments were performed on three general hyperspectral datasets, including Indian Pines, Pavia University, and Salinas, and compared with the other six methods. Even with a small number of training samples, the experimental results show that the proposed method's overall classification accuracy is 98.29%, 97.29%, and 99.72%, respectively, which is superior to the classification results of the comparison methods.

Key words image processing; hyperspectral image classification; superpixel dimensionality reduction; extended random walk; support vector machine

收稿日期: 2022-01-25; 修回日期: 2022-04-06; 录用日期: 2022-06-14; 网络首发日期: 2022-06-24

基金项目: 湖南省自然资源厅科技项目

通信作者: *yangbin@hunnu.edu.cn

1 引言

近年来随着卫星和传感器技术不断提升,高光谱遥感在世界范围获得了迅猛发展^[1]。高光谱图像是指高光谱传感器在可见光和近红外光谱区域,按一定规则连续地捕获数百个窄波段的光谱信息^[2],从而生成具有超高光谱分辨率的遥感图像。得益于高光谱图像中包含丰富的空间、光谱信息,其在农业^[3]、医疗^[4]、军事^[5]、资源开发^[6]和环境检测^[7]等多个领域被广泛使用。高光谱分类一直是高光谱图像在各领域应用的热点,然而大量的空间、光谱信息为分类带来足够多特征的同时,也带来了许多新的挑战。例如随着参与处理的高光谱波段数量的增加,图像分类精度呈现出先增后减的趋势,这被称作“维度灾难”或休斯现象^[8];再如随着图像空间分辨率的提升,图像样本点标注的成本也越来越大,如何在小样本情况下保证图像的分类精度已经成为当下亟待解决的问题^[9]。

近二十年来,一些经典的机器学习和深度学习方法已被引入高光谱图像分类领域,例如K邻近法^[10]、极限学习机^[11]、随机森林^[12]、支持向量机(SVM)^[13]、深度置信网络^[14]和栈式自编码网络^[15]等。虽然它们已在众多分类任务中被验证是有效的,但是随着高光谱图像海量信息的产生,这类仅基于谱特征建立分类模型的方法难以取得进一步的发展。值得一提的是,SVM通过核变换技术将光谱信息投影到高维特征空间,再利用超平面进行分割,进而实现对像素的分类,使其能在少量样本情况下稳定地完成训练和分类,具有较强的稳定性和容错性,且解决了样本特征线性不可分问题^[16]。因此,SVM至今仍是高光谱分类任务中不可忽视的分类方法。

随着对高光谱分类方法研究的深入,空间信息也被逐渐关注并引入分类任务中,目前利用空间信息和光谱信息进行分类的方法,已经成为高光谱图像分类领域的研究热点。根据对空谱信息的处理方式可将这些方法大致分为3类。第1类方法是指根据地物的纹理信息和分布特征对图像进行预处理,即按照一定的规则提取图像中固有的纹理和形状等空间特征,之后将这些含有空间特征的预处理结果输入图像分类器。最常用预处理方法为图像滤波技术和分割技术:李非燕等^[17]使用Gabor滤波器提取高光谱图像中的Gabor特征;齐永锋等^[18]则利用三维滤波器在保留光谱特征的前提下提取图像的纹理信息;Jiang等^[19]在主成分分析(PCA)的基础上提出超像素主成分分析(SuperPCA)方法,通过分割图像获得具有同质性的子区块,提取图像固有的低维空间特征。第2类方法的基本思想是利用空间信息对分类结果进行后验概率优化,具体为基于相邻像素之间的空间相关性对依靠光谱信息分类的结果进行矫正。例如:Tarabalka等^[20]利用马尔可夫随机场(MRF)对通过SVM得到的分类结

果进行矫正,假设目标像素和它的相邻像素类别趋近,提出结合MRF与SVM的方法(MRF-SVM);Kang等^[21]根据MRF-SVM进一步提出基于扩展随机游走(ERW)的后处理方法,假设只有在目标像素同一侧的像素才具有相同标签值,保证地物边界区域能被更准确划分。第3类方法指同时对图像的空间信息和光谱信息进行特征提取和处理,常见于端到端的深度学习方法,在经过足量训练后,深层神经网络可以充分地学习和表征空谱特征。近年来,众多深度学习模型已被引入高光谱图像分类领域并取得令人瞩目的分类效果^[22]。Li等^[23]采用three-dimensional convolutional neural network(3DCNN)在不对高光谱数据进行任何预处理和后处理的情况下,直接将三维卷积核作用在三维高光谱图像上,有效地提取图像的空间特征和光谱特征;Zhong等^[24]则基于残差网络^[25]提出一种深度空间光谱残差网络(SSRN),该网络通过构建光谱残差块和空间残差块,可区分地连续提取和学习图像中的光谱特征和空间特征。虽然这3类利用空谱信息分类的方法相比单纯依靠光谱信息的方法在性能上有了相当提升,但仍存在一些局限性。其中,第1类方法只提取了图像中简单的超像素空谱特征,忽略了复杂的局部空间特征;第2类空间信息后处理方法,没有考虑到在高维光谱信息处理中常出现的休斯现象以及算力上的严重损耗;至于第3类方法,虽然展示了深度学习强大的特征提取能力,但往往需要大量的训练样本作为支撑,而训练样本严重缺失正是目前高光谱分类领域所面临的巨大挑战。

因此,为了能在少量样本的情况下,充分利用高光谱图像的空谱信息提高分类精度,本文基于SVM分类器,提出一种联合SuperPCA降维和ERW概率优化的高光谱图像分类方法(SE_SVM)。一方面,所提方法采用成熟的SVM分类器,保证了小样本条件下分类模型的鲁棒性和抗过拟合能力;另一方面,其注重对图像空谱信息的联合利用,通过SuperPCA和ERW分别实现对超像素级别和像素级别空间信息的提取和分析。此外,SuperPCA降维使得高维度的高光谱图像维度降低,避免休斯现象出现的同时,也大幅节约分类所需的时间。

2 基本原理

所提SE_SVM方法的框架如图1所示,该方法具体分为5个步骤:1)利用PCA提取待分类高光谱图像的第一主成分;2)采用熵率超像素分割(ERS)^[26]算法对第一主成分进行超像素分割;3)基于分割形成的同质区域对高光谱图像进行超像素主成分分析降维;4)将降维后的低维图像矩阵输入SVM分类器中进行初分类;5)利用ERW算法对初始分类结果进行后验概率优化,根据各像元最大类别概率确定分类结果。

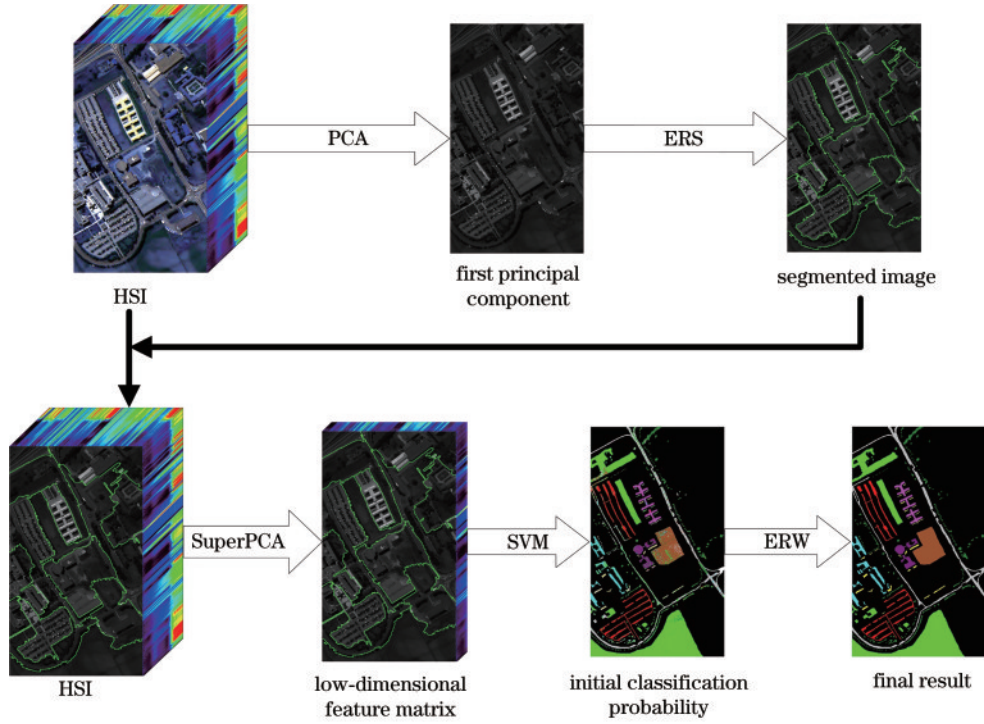


图 1 基于 SE_SVM 的高光谱图像分类框架

Fig. 1 Hyperspectral image classification framework based on SE_SVM

下面对 SE_SVM 框架中所运用的 3 个重要技术方法 ERS、SuperPCA 和 ERW 分别进行详细介绍。记原始高光谱图像为 $\mathbf{X} \in \mathbf{R}^{N_1 \times N_2 \times L}$, N_1 、 N_2 和 L 分别表示图像的行数、列数和光谱维度值。若将 \mathbf{X} 转换为二维矩阵, 则 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_i, \dots, \mathbf{x}_N] \in \mathbf{R}^{L \times N}$, 其中, 图像的像素数量 $N = N_1 \times N_2$, 图像中第 i 个像素的光谱维向量 $\mathbf{x}_i \in \mathbf{R}^L (1 \leq i \leq N)$ 。

2.1 熵率超像素分割

超像素分割最初应用于计算机视觉领域, 是指将数字图像中相邻且纹理相似的区域细分为多个图像子区域的过程, 其中, 基于图的超像素分割方法已被广泛应用于高光谱图像分类^[27]。该方法将图像映射为图 $G = (V, E)$, 其中, V 表示图的顶点集, E 表示一系列顶点 v_i 和顶点 v_j 之间的边 $e_{i,j}$ 组成的边集, 边的权值 $w_{i,j}$ 表示顶点 v_i 和 v_j 的相似度, 然后把图分割问题转换为子集选择的问题, 利用目标函数找到一组边的集合 $A \subseteq E$, 使得图 $G' = (V, A)$ 包含所有的连接子图, 最终通过目标函数去除原始边集 E 中的某些边来达到分割图像的目的。

Shi 等^[28]在经典的归一化切割图像方法^[29]的基础上, 引入基于图上随机游动熵率的目标函数提出 ERS 方法。在 ERS 中, 图 $G' = (V, A)$ 的图上随机游动熵率 $H(A)$ 可以描述为

$$H(A) = - \sum_i \mu_i \sum_i P_{i,j}(A) \log [P_{i,j}(A)], \quad (1)$$

$$P_{i,j}(A) = \begin{cases} \frac{w_{i,j}}{w_i}, & i \neq j \text{ and } e_{i,j} \in A \\ 0, & i \neq j \text{ and } e_{i,j} \notin A \\ 1 - \frac{\sum_{j: e_{i,j} \in A} w_{i,j}}{w_i}, & i = j \end{cases}, \quad (2)$$

式中: 随机游走的平稳分布 $\mu_i = \frac{w_i}{w_T}$; w_i 表示所有通过顶点 v_i 的边的权值和; 正则化常数 $w_T = \sum_{i=1}^{|V|} w_i$, 其中, $|V|$ 为图的顶点数; $P_{i,j}(A)$ 为随机游走的概率。

ERS 的目标函数可以用随机游动熵率项 $H(A)$ 和平衡项 $B(A)$ 描述:

$$A^* = \max_A \{H(A) + \lambda B(A)\} \quad \text{s.t. } A \subseteq E, \quad (3)$$

式中: 可变权重因子 $\lambda \geq 0$, 用来协调随机游动熵率项 $H(A)$ 和平衡项 $B(A)$ 之间的比例关系, 通过使目标函数取最大值来实现对图像的超像素分割。

具体地, 对高光谱图像 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_i, \dots, \mathbf{x}_N] \in \mathbf{R}^{L \times N}$ 进行熵率超像素分割: 由于第一主成分涵盖了高光谱图像中的主要信息^[30], 所以将第一主成分图作为超像素分割的基础图像, 首先利用 PCA 提取 \mathbf{X} 的第一主成分 F_1 , 接着根据式 (3) 对 F_1 进行 ERS 超像素分割:

$$F_1 = \bigcup_{k=1}^y X_k \quad \text{s.t. } X_k \cap X_g = \emptyset, k \neq g, \quad (4)$$

式中: y 为分割形成的超像素数量; $X_k (1 \leq k \leq y)$ 为第

k 个超像素。在所提模型中,ERS 的分割结果将作为 SuperPCA 的输入。

2.2 超像素主成分分析

常规 PCA 方法直接把原始图像矩阵 \mathbf{X} 整体转换成低维矩阵 $\mathbf{X}' = [\mathbf{x}'_1, \mathbf{x}'_2, \dots, \mathbf{x}'_i, \dots, \mathbf{x}'_N] \in \mathbf{R}^{d \times N}$, 其中, $\mathbf{x}'_i \in \mathbf{R}^d, 1 \leq i \leq N, d < L$ 。但是在高光图像中存在许多同质区域,处在这些同质区域内的像素往往属于同一个类别,而 PCA 降维忽略了图像中非同质区域间的差异。受此启发,有学者提出了 SuperPCA 这种“分而治之”的降维方法^[19]。在本研究中,SuperPCA 首先利用第 2.1 节的 ERS 方法获取高光图像 \mathbf{X} 中的同质区域,之后分别对这些同质区域进行 PCA 降维,具体地:首先对 \mathbf{X} 进行 ERS 超像素分割,得到分割后的同质区域 $\mathbf{X}_k (1 \leq k \leq y)$;然后基于 \mathbf{X}_k 对原高光图像 \mathbf{X} 中相应的区域进行普通 PCA 降维,求得 \mathbf{X}'_k , 每个 \mathbf{X}'_k 保留相等主成分数;最后组合 \mathbf{X}'_k 形成 SuperPCA 的结果 $\mathbf{K} = [\mathbf{x}''_1, \mathbf{x}''_2, \dots, \mathbf{x}''_i, \dots, \mathbf{x}''_N] \in \mathbf{R}^{d \times N}$, 其中, $\mathbf{x}''_i \in \mathbf{R}^d, 1 \leq i \leq N, d < L$ 。

2.3 扩展随机游走算法

虽然 SuperPCA 提取了高光图像的空谱混合特征,但超像素级的特征提取丢失了大量局部空间特征,这导致部分地物的边缘区域在 SVM 中进行分类时有一定概率被错分。而 ERW 作为一种空间后处理方法,通过编码高光图像的空间信息至加权图,刻画相邻像素的空间相关性以及标签像素和测试像素的距离信息,并以此对分类器得到的像素类别概率向量进行优化,是一种简单有效可避免由特征提取导致的过度平滑现象的方法。因此,在 SVM 分类后加入 ERW 对初始分类结果进行后验概率优化。

首先,将经 SuperPCA 降维后含有 M 类地物 N 个像素的超像素混合特征 $\mathbf{K} = [\mathbf{x}''_1, \mathbf{x}''_2, \dots, \mathbf{x}''_i, \dots, \mathbf{x}''_N] \in \mathbf{R}^{d \times N}$ 输入支持向量机分类器,求得初始像素类别概率向量 $\mathbf{C}_s = \{\mathbf{r}_1, \mathbf{r}_2, \dots, \mathbf{r}_i, \dots, \mathbf{r}_N\}$, 其中 $\mathbf{r}_i = [r_i^1, r_i^2, \dots, r_i^M]^T$, 且 $\sum_{m=1}^M r_i^m = 1$, 之后再求解以下能量函数的最小值以实现 \mathbf{C}_s 的优化:

$$E^m(\mathbf{P}_m) = E_{\text{spatial}}^m(\mathbf{P}_m) + \eta E_{\text{aspatial}}^m(\mathbf{P}_m), \quad (5)$$

$$E_{\text{spatial}}^m(\mathbf{P}_m) = \mathbf{P}_m^T \mathbf{L} \mathbf{P}_m, \quad (6)$$

$$E_{\text{aspatial}}^m(\mathbf{P}_m) = \sum_{q=1, q \neq m}^M \mathbf{P}_q^T \mathbf{A}_q \mathbf{P}_q + (\mathbf{P}_m - 1)^T \mathbf{A}_m (\mathbf{P}_m - 1), \quad (7)$$

式中: m 表示不同的类别; \mathbf{P}_m 是待分类像素随机游走到标签像素的概率; η 表示权重因子; $E_{\text{spatial}}^m(\mathbf{P}_m)$ 表示相邻像素之间的空间相关性; $E_{\text{aspatial}}^m(\mathbf{P}_m)$ 表示 \mathbf{C}_s 的拉普拉斯算子; \mathbf{A} 表示由 \mathbf{C}_s 组成的对角线矩阵; \mathbf{L} 表示加权图的拉普拉斯矩阵。具体地,图像中第 i 个像素和第 j 个像素的 L_{ij} 可描述为

$$L_{ij} = \begin{cases} -\omega_{ij}, & v_i \text{ and } v_j \text{ are adjacent contacts} \\ d_i, & i = j \\ 0, & \text{else} \end{cases}, \quad (8)$$

式中: ω_{ij} 表示连接第 i 个像素和第 j 个像素的边权;第 i 个像素的阶数 $d_i = \sum \omega_{ij}$, 它是所有连接着第 i 个像素的加权边的总和。求解式(5)完成对 \mathbf{C}_s 的优化,获得最终像素类别概率向量 \mathbf{C}_i , 并按每个像素最大类别概率确定所属类别。

3 实验与讨论

为验证所提 SE_SVM 方法的有效性,选择了 4 种相关的 SVM 分类方法以及 2 种深度学习方法与其进行对比实验。所选对比方法分别是 SVM^[15]、PCA_SVM^[30]、SPCA_SVM^[19]、ERW_SVM^[21]、3DCNN^[23] 和 SSRN^[24]。其中:SVM 方法是经典的机器学习方法,它着眼于对图像光谱信息的提取和表征;PCA_SVM 利用 PCA 对图像光谱信息进行预处理,去除波段中的冗余信息并实现降维,之后用 SVM 分类器进行分类;SPCA_SVM 和 ERW_SVM 是 2 种新近提出的机器学习分类方法,SPCA_SVM 通过 SuperPCA 划分图像的同质区域并进行降维,有效提取了图像的空间纹理信息,而 ERW_SVM 通过编码构建像元间的空间关系加权图,并基于此对像素类别概率向量进行后处理优化;3DCNN 和 SSRN 则是 2 种最近在高光图像分类领域被广泛认可的深度神经网络分类方法。实验中采用总体精度(OA)、平均精度(AA)和 Kappa 系数作为各方法分类结果的评价指标。实验环境为 Windows 10 系统, Intel(R) Core(TM) i7-4710 处理器主频 2.5 GHz, 内存 8 GB, NVIDIA GeForce GTX 960M 显卡。

3.1 数据集

为准确比较各分类方法的性能,在 3 个具有代表性的公开数据集上进行对比实验,它们分别是 Indian Pines、Pavia University 和 Salinas 高光图像数据集。这 3 个数据集的空间分辨率、光谱分辨率以及采集的时间和地点各不相同,数据集大小和地物类别数量也有较大差异。对不同的数据集进行分类,可以有效反应模型本身性能的优劣。实验将各数据集划分为训练集、验证集和测试集,各部分的数量关系详细记录在表 1~3 中,在 Indian Pines 数据集上训练集、验证集和测试集的比例为 5%、5% 和 90%, 在 Pavia University 数据集上为 1%、1% 和 98%, 在 Salinas 数据集上为 1%、1% 和 98%。为关注小训练样本下高光图像的分类情况,本实验在划分时较传统的机器学习方法大量减少了训练样本的选取。

Indian Pines 数据集:此数据集是 1992 年 6 月由机载成像光谱仪(AVIRIS)采集的位于印第安纳州西北部关于印第安纳松树的高光谱影像,空间分辨率为 20 m, 波长范围为 0.4~2.5 μm , 图像尺寸为

145 pixel×145 pixel,共包含 220 个波段,去除吸水波段后保留 200 个可用于分类的有效波段,数据集中的目标地物共 16 类,主要类别为一些处于生长期农作物的目标地物,目标地物像素共计 10294 个。此数据集的假彩色

合成影像和地面真实标签图如图 2 所示。结合图 2 和表 1 可以看出,在 Indian Pines 数据集中,有几类地物如 Alfalfa、Grass-pasture-mowed 和 Oats 等的样本数量非常少,这在一定程度上为分类增加了难度。



图 2 Indian Pines 数据集假彩色图像(波段 34, 17, 10)及地面真实标签图
Fig. 2 False-color image (bands 34, 17, 10) and ground truth label map of Indian Pines dataset

表 1 Indian Pines 数据集划分情况
Table 1 Data partitioning of Indian Pines dataset

Label	Class	Labeled sample	Training	Validation	Test
1	Alfalfa	46	3	2	41
2	Corn-notill	1428	71	71	1286
3	Corn-mintill	830	43	43	744
4	Corn	237	12	12	213
5	Grass-pasture	483	24	24	435
6	Grass-trees	730	36	36	658
7	Grass-pasture-mowed	28	2	1	25
8	Hay-windrowed	478	24	24	430
9	Oats	20	1	1	18
10	Soybean-notill	972	48	48	876
11	Soybean-mintill	2455	122	122	2211
12	Soybean-clean	593	30	30	533
13	Wheat	205	10	10	185
14	Woods	1265	63	63	1139
15	Buildings-Grass-Trees-Drives	386	19	19	348
16	Stone-Steel-Towers	93	4	5	84
	Total	10249	512	511	9226

Pavia University 数据集:此数据集是 2003 年由机载反射光学光谱成像仪(ROSIS)采集的位于意大利北部帕维亚地区的帕维亚大学影像,在此影像中含有许多城市常见的沥青、碎石等地物类型。数据集的空间分辨率为 1.3 m,波长范围 0.43~0.86 μm,图像尺寸 610 pixel×340 pixel,去除 12 个噪声波段后保留了 103 个可用于分类的有效波段,数据集中的目标地物共有 9 类,目标地物像素共计 42776 个。此数据集的假彩色合成影像和地面真实标签图如图 3 所示。

Salinas 数据集:此数据集同样是由 AVIRIS 采集的影像,其地理位置位于加利福尼亚州的萨利纳斯山谷,采集时间为 1998 年 10 月。数据集的空间分辨率为 3.7 m,波长范围 0.4~2.5 μm,图像尺寸 512 pixel×217 pixel,共包含 224 个波段,去除吸水波段还保留 204 个可用于分类的有效波段,数据集中的目标地物

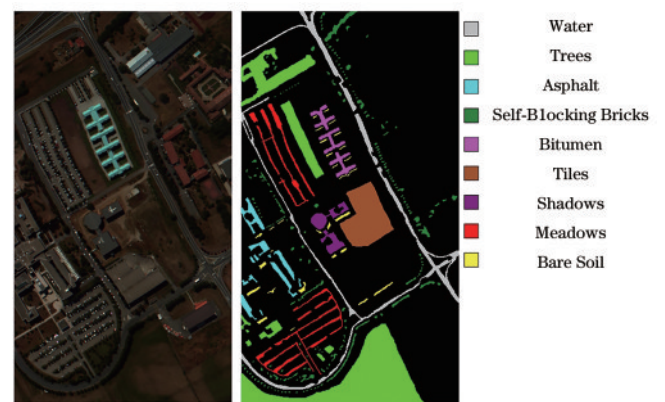


图 3 Pavia University 数据集假彩色图像(波段 68, 27, 19)及地面真实标签图
Fig. 3 False-color image (bands 68, 27, 19) and ground truth label map of Pavia University dataset

表 2 Pavia University 数据集划分情况

Table 2 Data partitioning of Pavia University dataset

Label	Class	Labeled sample	Training	Validation	Test
1	Asphalt	6631	66	66	6499
2	Meadows	18649	186	186	18277
3	Gravel	2099	21	21	2057
4	Trees	3064	31	31	3002
5	Painted metal sheets	1345	13	13	1319
6	Bare Soil	5029	50	50	4929
7	Bitumen	1330	13	13	1304
8	Self-Blocking Bricks	3682	37	37	3608
9	Shadows	947	9	9	929
Total		42776	426	426	41924

共有 16 类,目标地物像素共 54129 个。此数据集的假彩色合成影像和地面真实标签图如图 4 所示,和




图 4 Salinas 数据集假彩色图像(波段 68, 27, 19)及地面真实标签图

Fig. 4 False-color image (bands 68, 27, 19) and ground truth label map of Salinas dataset

Indian Pines 数据集类似, Salinas 数据集中同样包含了大量农业相关的作物。

表 3 Salinas 数据集划分情况

Table 3 Data partitioning of Salinas dataset

Label	Class	Labeled sample	Training	Validation	Test
1	Broccoli_green_weeds_1	2009	20	20	1969
2	Broccoli_green_weeds_2	3726	37	37	3652
3	Fallow	1976	20	20	1936
4	Fallow_rough_plow	1394	14	14	1366
5	Fallow_smooth	2678	27	27	2624
6	Stubble	3959	40	40	3879
7	Celery	3579	36	36	3507
8	Grapes_untrained	11271	112	112	11047
9	Soil_vinyard_develop	6203	62	62	6079
10	Corn_senesced_green_weeds	3278	33	33	3212
11	Lettuce_romaine_4wk	1068	11	11	1046
12	Lettuce_romaine_5wk	1927	19	19	1889
13	Lettuce_romaine_6wk	916	9	9	898
14	Lettuce_romaine_7wk	1070	11	11	1048
15	Vinyard_untrained	7268	73	73	7122
16	Vinyard_vertical_trellis	1807	18	18	1771
Total		54129	542	542	53045

3.2 参数设置与分析

采用机器学习方法对高光谱图像进行分类时,其性能一定程度上取决于模型参数的设置。所提 SE_SVM 方法的两个主要参数分别为高光谱图像进行 SuperPCA 降维后保留的主成分维数 x 以及生成的超像素个数 y 。下文将在合理范围内对这两个参数的设置进行讨论,以期得到相对优良的参数值或参数值分布。本小节将按照表 1~3 中划分的训练集样本训练模型,并基于在验证集样本上的总体分类精度结果确定参数设置,下一节则利用测试集样本评估模型的性能。

图 5 展示了不同参数设置下, SE_SVM 在各数据集验证集上的总体分类精度情况。图中 5 行 3 列共包含了 15 个小的折线图;每列表示不同的数据集,从左至右依次是 Indian Pines、Pavia University 和 Salinas 数据集;每行表示不同的主成分维数,从上至下依次取 5、10、20、50、100;每个折线图的横坐标表示超像素的数量,纵坐标表示总体分类精度,图中每个圆形标记点表示在实验中超像素数取 1、3、5、10、20、30、40、50、75、100、150、200 时所对应的总体分类精度值,总体精度值最大点用英文字符“Max”标出。

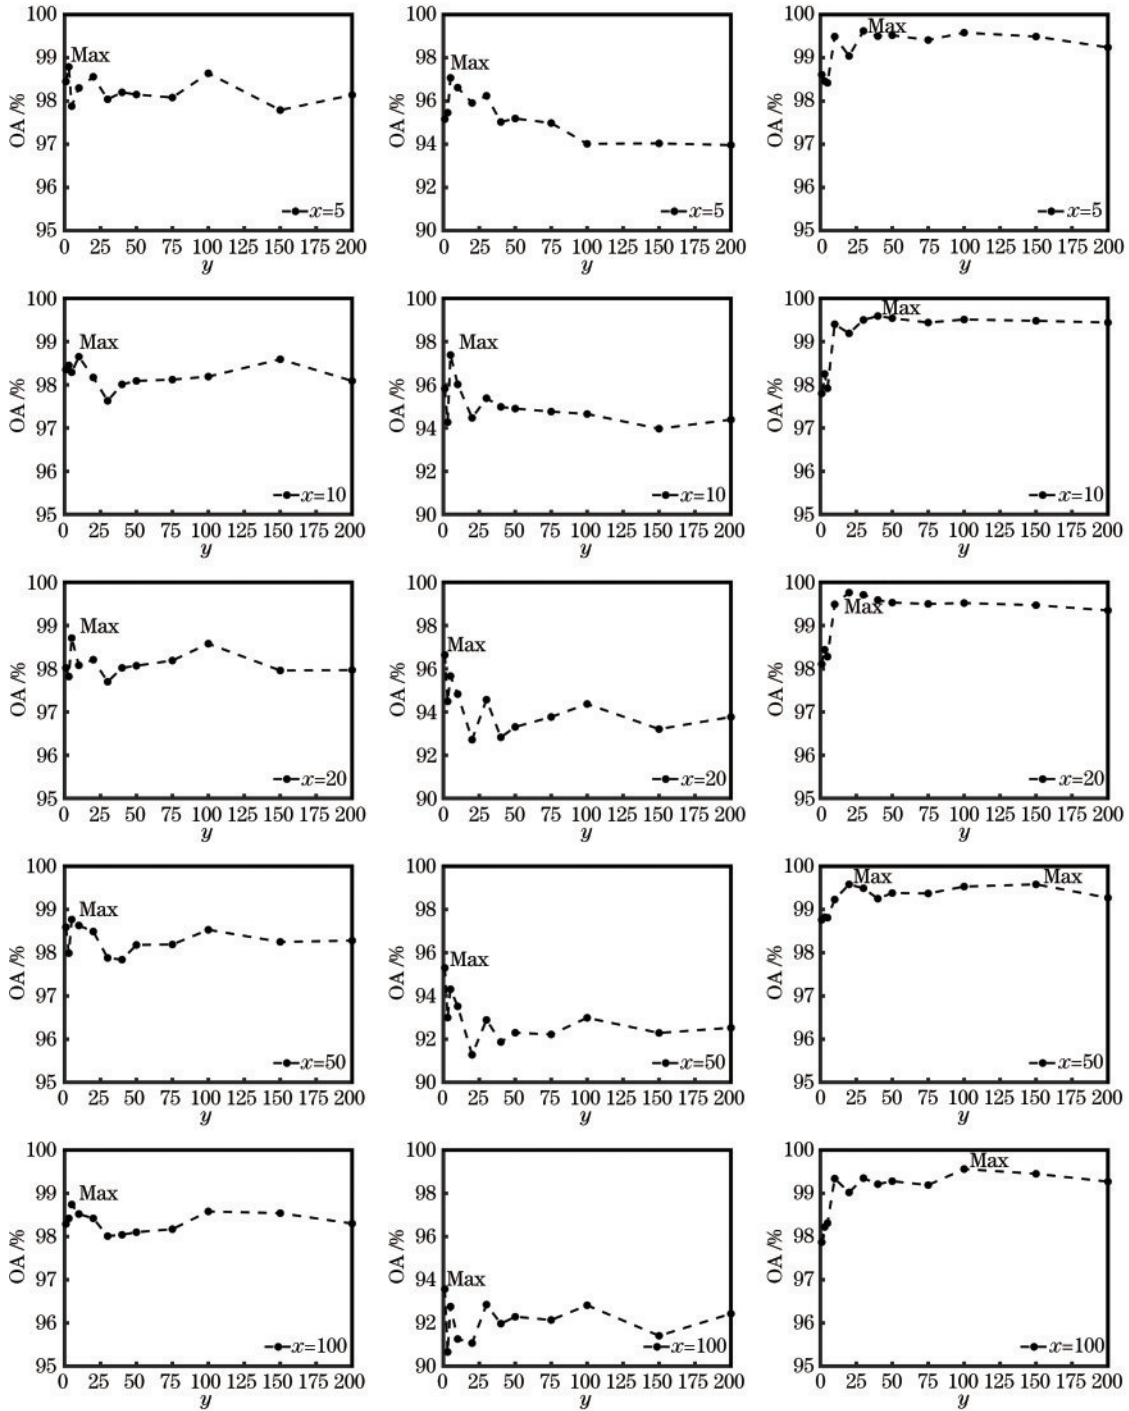


图 5 高光谱数据集总体分类精度随主成分维数和超像素个数变化折线图

Fig. 5 Line graphs of overall classification accuracy of hyperspectral dataset with the number of principal components and the number of superpixels

观察图 5 第 1 列 5 个小折线图可以发现:在 Indian Pines 数据集上,主成分维数的变化对总体分类精度的影响不大,在考虑低维矩阵更利于模型的后续计算后,主成分维数取 5~20 是合适的参数设置;而超像素数的变化则会让总体精度产生一定的波动,整体的波动趋势表现为先增后减,在超像素数取 3~10 范围内取得总体精度最大值。在 Salinas 数据集上,主成分维数的变化对总体精度的影响同样不显著,主成分维数取 5~20 是合适的参数设置;而超像素数的逐渐增大对总体分类精度的影响表现为先增后减,和另外两个数据集稍有

98% 逐渐下降至 88%~94%,因此主成分维数取 5~10 是合适的参数设置;而随着超像素数的逐渐增大对总体精度的影响与在 Indian Pines 数据集上展现出类似的波动,在超像素数取 3~25 范围内时取得总体精度最大值。在 Salinas 数据集上,主成分维数的变化对总体精度的影响同样不显著,主成分维数取 5~20 是合适的参数设置;而超像素数的逐渐增大对总体分类精度的影响表现为先增后减,和另外两个数据集稍有

不同的是,总体精度达到峰值时超像素数的取值范围更广,为 5~50。综上所述,得到了相对合适的参数分布范围,为相关工作提供了一个可供选择的参数设置。同时,此次实验的结果也验证了 SE_SVM 方法的有效性,在各个数据集的验证集上均能取得较高的整体分类精度。

因此,确定 SE_SVM 参数设置如下:在对 Indian Pines、Pavia University、Salinas 这 3 个数据集进行分类时, x 分别取 20、10、20, y 分别取 3、5、10。其余对比方法沿用原文的参数设置,对于原文没有进行实验的数据集,则在参考原文参数的基础上,利用测试集和验证集训练后以确定参数设置。

3.3 结果与分析

本小节将从分类的定量结果和视觉效果图上比较 7 种方法在小规模训练样本下的分类性能。为保证比较实验的公正性,各方法对每类地物的分类准确率和相关评估标准,均采用 10 次重复实验结果的平均值,表 4~6 详细记录了它们在 3 个数据集测试集上的分类结果。

观察表 4~6 可以发现:SVM 和 PCA_SVM 方法的分类效果并不理想,在 3 个数据集上的 OA 均不超 90%;SPCA_SVM 方法在 3 个数据集上的 OA 则提升至 90% 以上;ERW_SVM 方法在不同的数据集上表现出更优良的分类性能,在 3 个数据集上的 OA 都超过

表 4 7 种方法在 Indian Pines 数据集上的分类精度

Table 4 Classification accuracy achieved by seven different methods on Indian Pines dataset unit: %

Label	SVM	PCA_SVM	SPCA_SVM	ERW_SVM	3DCNN	SSRN	SE_SVM
1	0.00	16.73	0.00	100.00	26.83	36.59	100.00
2	61.95	52.39	93.23	95.84	81.17	96.81	97.56
3	69.03	62.02	92.67	98.40	79.65	98.13	98.42
4	57.75	50.24	91.86	99.13	67.14	69.48	94.51
5	85.68	75.75	97.78	98.54	86.21	97.70	99.20
6	83.66	78.86	99.69	95.76	97.26	99.70	98.72
7	0.00	0.00	0.00	99.50	36.00	0.00	98.80
8	85.07	90.09	100.00	99.26	99.77	100.00	100.00
9	0.00	0.00	0.00	100.00	0.00	0.00	98.00
10	74.08	64.40	94.42	97.57	91.31	97.14	98.57
11	67.99	58.10	91.32	96.72	84.48	98.51	98.05
12	59.86	50.14	87.28	95.70	66.48	92.70	96.81
13	91.84	91.34	100.00	99.74	98.38	100.00	99.79
14	89.88	83.89	99.30	95.31	98.42	100.00	98.94
15	59.72	55.80	98.52	98.64	72.62	94.24	99.83
16	98.29	97.61	97.66	96.21	25.00	38.10	98.90
OA	73.28	65.99	94.38	96.84	85.00	95.99	98.29
AA	61.55	57.96	77.73	97.90	69.42	76.19	98.51
Kappa	69.12	60.21	93.57	96.40	82.89	95.42	98.05

表 5 7 种方法在 Pavia University 数据集上的分类精度

Table 5 Classification accuracy achieved by seven different methods on Pavia University dataset unit: %

Label	SVM	PCA_SVM	SPCA_SVM	ERW_SVM	3DCNN	SSRN	SE_SVM
1	84.80	80.70	78.26	94.61	89.00	99.45	94.37
2	91.89	89.08	96.45	96.65	97.76	98.73	97.34
3	77.97	73.95	86.21	99.84	86.78	88.24	98.69
4	94.15	89.46	96.85	99.54	89.48	90.41	98.57
5	98.94	100.00	99.74	99.49	89.38	99.93	99.92
6	85.35	84.04	95.87	97.80	78.86	99.19	97.43
7	81.84	66.80	69.15	100.00	81.20	95.09	99.72
8	76.25	68.84	80.82	97.57	82.32	89.95	98.47
9	100.00	99.99	99.08	99.80	94.40	98.72	99.73
OA	88.21	84.83	91.08	97.06	90.86	96.96	97.29
AA	87.91	83.65	89.16	98.37	87.68	95.52	98.25
Kappa	84.19	79.54	88.07	96.07	87.82	96.02	96.38

表 6 7 种方法在 Salinas 数据集上的分类精度

Table 6 Classification accuracy achieved by seven different methods on Salinas dataset unit: %

Label	SVM	PCA_SVM	SPCA_SVM	ERW_SVM	3DCNN	SSRN	SE_SVM
1	99.52	98.98	100.00	100.00	97.16	99.44	99.99
2	99.10	98.53	100.00	100.00	100.00	100.00	100.00
3	93.51	90.76	100.00	99.30	99.48	100.00	99.86
4	97.76	98.66	96.30	96.08	99.56	99.93	98.52
5	98.05	93.56	97.79	99.99	95.01	97.48	99.97
6	99.95	99.82	100.00	100.00	99.90	100.00	99.97
7	98.38	97.83	99.99	99.85	97.38	99.91	99.95
8	74.15	72.72	98.98	97.36	92.80	85.79	99.98
9	98.69	97.75	99.03	99.98	99.87	100.00	100.00
10	85.11	88.60	95.35	98.70	94.43	97.54	98.42
11	91.71	90.66	92.89	99.74	91.98	95.32	100.00
12	95.74	97.67	93.40	100.00	98.73	100.00	100.00
13	96.49	96.13	100.00	99.24	98.55	97.88	99.39
14	97.06	97.15	97.04	99.32	98.28	98.76	95.00
15	73.66	76.39	99.99	99.12	70.67	97.29	99.87
16	98.34	99.69	100.00	100.00	91.81	97.97	100.00
OA	88.85	88.52	98.65	99.06	93.11	96.15	99.72
AA	93.58	93.43	98.17	99.29	95.35	97.95	99.43
Kappa	87.55	87.17	98.50	98.96	92.31	95.72	99.69

了 96%;而基于三维卷积核同时提取图像空谱特征的 3DCNN 方法在 3 个数据集上的 OA 在 90% 左右;相较于只基于常规卷积运算的 3DCNN 方法,结合了残差网络的 SSRN 方法的分类性能得到了一定提升,在 3 个数据集上的 OA 都超过了 95%;至于所提方法

SE_SVM,无论是单个地物类别的分类准确率,还是总体分类精度和结果可靠性都较其余 6 种方法更优秀,在 Indian Pines、Pavia University 和 Salinas 这 3 个高光谱数据集上,OA 分别达到了 98.29%、97.29% 和 99.72%,AA 分别为 98.51%、98.25% 和 99.43%,Kappa 系数分别为 98.05%、96.8% 和 99.69%。

结合表 1 和表 4 可知,在 Indian Pines 数据集中,由于 Alfalfa、Grass-pasture-mowed 和 Oats 这 3 类地物划分的训练样本量非常少,分别只有 3、2 和 1。致使 SVM、PCA_SVM 和 SPCA_SVM 这 3 种方法对这几类地物的特征提取严重缺失,无法辨认出正确类别,两种深度神经网络 3DCNN 和 SSRN 方法,同样缺失对这几类地物准确分类的能力;而 ERW_SVM 和 SE_SVM 方法可以有效鉴别出这 3 类地物。结合表 2 和表 5 可知,在 Pavia University 数据集中 Gravel 和 Trees 地物划分的训练样本相对较少,ERW_SVM 和 SE_SVM 方法对这 2 类地物分类的准确率比其他 5 种方法更高。这表明在小规模训练样本下,通过结合 ERW 后验概率优化算法,SVM 分类器能稳定获得优

良的分类结果。

图 6~8 直观地展示了各方法在 3 个数据集测试集上的分类效果。从图中可以看出:SVM 方法错分严重,在结果图的很多类别区块中离散分布大量椒盐噪声,显然不符合实际地表覆盖情况;PCA_SVM 方法相较 SVM 方法,分类性能略有提升,在某些地物类别中噪声点明显减少,如在分类结果图 6(c)的右下地块;利用 SuperPCA 降维结合上下文空间信息输入分类器后,SPCA_SVM 方法的分类结果中噪声点大幅减少;ERW_SVM 方法利用空间-光谱信息后处理优化分类结果的方式,同样达到了去除噪声点、提升分类精度的作用;至于 3DCNN 和 SSRN 两种深度学习方法,虽然可以利用卷积运算同时提取图像光谱空间特征,但是在小样本条件下,各个神经网络层无法得到充足的训练,因此分类效果并不理想。观察图 6~8(f)、(g)子图可以发现:虽然相较于经典机器学习方法 SVM 和 PCA_SVM 方法,椒盐噪声已经几乎消失,但是在对小样本地物进行分类时,3DCNN 和 SSRN 仍存在较多错分结果。




图 6 7 种方法在 Indian Pines 数据集上的分类结果图。(a) 地面真实标签图;(b) SVM;(c) PCA_SVM;(d) SPCA_SVM;(e) ERW_SVM;(f) 3DCNN;(g) SSRN;(h) SE_SVM

Fig. 6 Classification result graphs of seven methods on Indian Pines dataset. (a) Ground truth label map; (b) SVM; (c) PCA_SVM; (d) SPCA_SVM; (e) ERW_SVM; (f) 3DCNN; (g) SSRN; (h) SE_SVM

而 SE_SVM 方法对图像空间信息进行了充分利用,反映到分类结果图上就是,分类结果明显优于其他方法,不仅类与类之间的边缘地区被更清晰地划分,每个类别中也极少参杂其他类别的噪声点,整体结果最贴近真实地面标签图。实验结果表明,所提方法 SE_SVM 即使在少量样本的情况下,仍能取得令人满意的分类结果。

3.4 各方法的耗时对比与分析

为全面验证所提方法的分类性能,表 7 记录了本次对比实验中各方法分类所需的时间,记录结果取 10 次重复实验耗时的平均值,需指出的是,深度神经

网络由于网络层数的加深,需进行大量梯度运算,相同算力条件下训练所消耗的时间远超经典的机器学习方法,因此本次耗时对比不考虑 3DCNN 和 SSRN 方法。

由表 7 可知,基于降维处理的 PCA_SVM、SPCA_SVM 和 SE_SVM 这 3 种方法完成分类所用时间明显少于另外 2 种方法。在 Indian Pines 和 Salinas 数据集上,PCA_SVM 和 SE_SVM 只需不到 20 s 即可完成分类,SPCA_SVM 不超过 27 s,SVM 花费了 40 s 以上的时间,而 ERW_SVM 则至少需要耗时 80 s。在 Pavia University 数据集上,几种对比方法花费的时长




图7 7种方法在 Pavia University 数据集上的分类结果图。(a)地面真实标签图；(b) SVM；(c) PCA_SVM；(d) SPCA_SVM；
(e) ERW_SVM；(f) 3DCNN；(g) SSRN；(h) SE_SVM

Fig. 7 Classification result graphs of seven methods on the Pavia University dataset. (a) Ground truth label map; (b) SVM; (c) PCA_SVM; (d) SPCA_SVM; (e) ERW_SVM; (f) 3DCNN; (g) SSRN; (h) SE_SVM




图8 7种方法在 Salinas 数据集上的分类结果图。(a)地面真实标签图；(b) SVM；(c) PCA_SVM；(d) SPCA_SVM；
(e) ERW_SVM；(f) 3DCNN；(g) SSRN；(h) SE_SVM

Fig. 8 Classification result graphs of seven methods on the Salinas dataset. (a) Ground truth label map; (b) SVM; (c) PCA_SVM; (d) SPCA_SVM; (e) ERW_SVM; (f) 3DCNN; (g) SSRN; (h) SE_SVM

表7 5种方法在 Indian Pines、Pavia University 和 Salinas 数据集上的运行时间

Table 7 Running time of five methods on the Indian Pines, Pavia University, and Salinas datasets unit: s

Dataset	SVM	PCA_SVM	SPCA_SVM	ERW_SVM	SE_SVM
Indian Pines	42.87	5.74	10.38	80.82	15.49
Pavia University	15.16	10.2	25.12	35.48	16.71
Salinas	40.63	12.83	26.63	85.18	19.58

相差较小,原因在于该数据集中地物类别较少,即使面对原始数据,SVM也能快速完成计算,但ERW_SVM仍耗费了最多的时间。

结合表4~6可以发现,在分类耗时较少的3种方法中,SE_SVM和SPCA_SVM方法的总体分类精度远高于PCA_SVM方法。因此,综合考虑分类精度和时间成本后,SPCA_SVM和SE_SVM方法是相对优良的方法,尤其是所提SE_SVM方法花费少量时间便可获得精度最优的分类结果。

4 结 论

提出一种联合超像素降维和扩展随机游走概率优化的高光谱图分类方法SE_SVM,旨在解决高光谱分类中存在的对图像空间信息利用不足和小规模训练样本下分类精度下降的问题。利用SuperPCA降维和提取超像素混合空谱特征并输入SVM进行初分类,结合ERW构建高光谱图像像元空间关系加权图,对初始分类结果进行后验概率优化提升分类精度。对比实验结果表明:联合SuperPCA降维和ERW概率优化的方法实现了对图像空间信息的充分利用,在Indian Pines、Pavia University和Salinas等3个高光谱数据集上,以少量样本对模型进行训练和分类,所提SE_SVM方法相较于相关对比方法表现出一定的优越性,总体分类精度最高、分类结果也更可靠;其次,在对比了几种机器学习方法的时间损耗后发现,SE_SVM方法在计算速度上同样处于第一梯队。仍需指明的是:SuperPCA降维的参数设置是通过大量实验得到的,因此如何自适应获取合适的SuperPCA降维参数将是接下来的研究重点。

参 考 文 献

[1] 刘嘉敏,郑超,张丽梅,等.基于图像重构特征融合的高光谱图像分类方法[J].中国激光,2021,48(9):0910001.
Liu J M, Zheng C, Zhang L M, et al. Hyperspectral image classification method based on image reconstruction feature fusion[J]. Chinese Journal of Lasers, 2021, 48(9): 0910001.

[2] 李丹,孔繁镛,朱德燕.基于局部高斯混合特征提取的高光谱图像分类[J].光学学报,2021,41(6):0610001.
Li D, Kong F Q, Zhu D Y. Hyperspectral image

classification based on local Gaussian mixture feature extraction[J]. Acta Optica Sinica, 2021, 41(6): 0610001.

[3] Lee M A, Huang Y B, Yao H B, et al. Determining the effects of storage on cotton and soybean leaf samples for hyperspectral analysis[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7(6): 2562-2570.

[4] Li Q L, Wang Y T, Liu H Y, et al. Sublingual vein extraction algorithm based on hyperspectral tongue imaging technology[J]. Computerized Medical Imaging and Graphics, 2011, 35(3): 179-185.

[5] Yuan Y, Wang Q, Zhu G K. Fast hyperspectral anomaly detection via high-order 2-D crossing filter[J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(2): 620-630.

[6] Zhang T T, Zeng S L, Gao Y, et al. Using hyperspectral vegetation indices as a proxy to monitor soil salinity[J]. Ecological Indicators, 2011, 11(6): 1552-1562.

[7] Matthews M W, Bernard S, Evers-King H, et al. Distinguishing cyanobacteria from algae in optically complex inland waters using a hyperspectral radiative transfer inversion algorithm[J]. Remote Sensing of Environment, 2020, 248: 111981.

[8] Hughes G. On the mean accuracy of statistical pattern recognizers[J]. IEEE Transactions on Information Theory, 1968, 14(1): 55-63.

[9] 孔燕萍,覃亚丽.基于深度学习的高光谱图像分类算法[J].传感器与微系统,2020,39(7):138-141.
Kong Y P, Qin Y L. Hyperspectral image classification algorithm based on deep learning[J]. Transducer and Microsystem Technologies, 2020, 39(7): 138-141.

[10] Blanzieri E, Melgani F. Nearest neighbor classification of remote sensing images with the maximal margin principle[J]. IEEE Transactions on Geoscience and Remote Sensing, 2008, 46(6): 1804-1811.

[11] Li W, Chen C, Su H J, et al. Local binary patterns and extreme learning machine for hyperspectral imagery classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(7): 3681-3693.

[12] Ham J, Chen Y C, Crawford M M, et al. Investigation of the random forest framework for classification of hyperspectral data[J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43(3): 492-501.

[13] Melgani F, Bruzzone L. Classification of hyperspectral remote sensing images with support vector machines[J]. IEEE Transactions on Geoscience and Remote Sensing, 2004, 42(8): 1778-1790.

[14] Chen Y S, Zhao X, Jia X P. Spectral-spatial classification of hyperspectral data based on deep belief network[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2015, 8(6): 2381-2392.

[15] Chen Y S, Lin Z H, Zhao X, et al. Deep learning-based classification of hyperspectral data[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7(6): 2094-2107.

[16] 闫敬文,陈宏达,刘蕾.高光谱图像分类的研究进展[J].

- 光学精密工程, 2019, 27(3): 680-693.
- Yan J W, Chen H D, Liu L. Overview of hyperspectral image classification[J]. Optics and Precision Engineering, 2019, 27(3): 680-693.
- [17] 李非燕, 霍宏涛, 李静, 等. 基于多特征和改进稀疏表示的高光谱图像分类[J]. 光学学报, 2019, 39(5): 0528004.
Li F Y, Huo H T, Li J, et al. Hyperspectral image classification via multiple-feature-based improved sparse representation[J]. Acta Optica Sinica, 2019, 39(5): 0528004.
- [18] 齐永锋, 陈静, 火元莲. 一种融合 Gabor 滤波与 3D/2D 卷积的高光谱图像分类算法[J]. 光电子·激光, 2021, 32(5): 477-484.
Qi Y F, Chen J, Huo Y L. A hyperspectral image classification algorithm combining Gabor filtering and 3D/2D convolution[J]. Journal of Optoelectronics·Laser, 2021, 32(5): 477-484.
- [19] Jiang J J, Ma J Y, Chen C, et al. SuperPCA: a superpixelwise PCA approach for unsupervised feature extraction of hyperspectral imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(8): 4581-4593.
- [20] Tarabalka Y, Fauvel M, Chanussot J, et al. SVM- and MRF-based method for accurate classification of hyperspectral images[J]. IEEE Geoscience and Remote Sensing Letters, 2010, 7(4): 736-740.
- [21] Kang X D, Li S T, Fang L Y, et al. Extended random walker-based classification of hyperspectral images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(1): 144-153.
- [22] Hu W, Huang Y Y, Wei L, et al. Deep convolutional neural networks for hyperspectral image classification[J]. Journal of Sensors, 2015, 2015: 258619.
- [23] Li Y, Zhang H K, Shen Q. Spectral-spatial classification of hyperspectral imagery with 3D convolutional neural network[J]. Remote Sensing, 2017, 9(1): 67.
- [24] Zhong Z L, Li J, Luo Z M, et al. Spectral-spatial residual network for hyperspectral image classification: a 3-D deep learning framework[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(2): 847-858.
- [25] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [26] Liu M Y, Tuzel O, Ramalingam S, et al. Entropy rate superpixel segmentation[C]//The 24th IEEE Conference on Computer Vision and Pattern Recognition CVPR, June 20-25, 2011, Colorado Springs, CO, USA. New York: IEEE Press, 2011: 2097-2104.
- [27] Saranathan A M, Parente M. Uniformity-based superpixel segmentation of hyperspectral images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(3): 1419-1430.
- [28] Shi J B, Malik J. Normalized cuts and image segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(8): 888-905.
- [29] 陈善学, 张欣. 基于二次空间处理的联合稀疏表示高光谱图像分类[J]. 信号处理, 2021, 37(11): 2134-2147.
Chen S X, Zhang X. Joint sparse representation of hyperspectral image classification based on quadratic space processing[J]. Journal of Signal Processing, 2021, 37(11): 2134-2147.
- [30] 张亮. 基于 PCA 和 SVM 的高光谱遥感图像分类研究[J]. 光学技术, 2008, 34(S1): 184-187.
Zhang L. Study on the hyperspectral remote sensed image classify based on PCA and SVM[J]. Optical Technique, 2008, 34(S1): 184-187.