

# 基于图像重构特征融合的高光谱图像分类方法

刘嘉敏\*, 郑超, 张丽梅, 邹泽华

重庆大学光电技术及系统教育部重点实验室, 重庆 400044

**摘要** 针对传统的高光谱遥感图像分类方法未能充分利用空间信息, 提出一种基于高光谱图像重构特征融合的分类方法。该方法首先将图像的每个像素点进行 LBP(Local Binary Patterns) 特征提取, 得到每个像素点的 LBP 特征值; 其次提取出每个像素点的空间邻域块, 按照图像已知的标签信息去除每个空间邻域块中冗余的背景像素点, 得到新的空间邻域块, 利用光谱距离得到每个像素点的权重值并计算重构特征值; 然后, 将像素点的 LBP 特征值和重构特征值进行叠加融合, 获得重构特征融合值; 最后, 采用  $K$  最近邻分类器将像素点进行分类, 根据测试样本点和训练样本点的欧氏距离判断测试样本点的类别。在 Indian Pines 和 Pavia University 数据集上进行实验。实验结果表明, 所提方法的分类精度分别达到 99.06% 和 99.73%。

**关键词** 遥感; 高光谱遥感; LBP 特征; 空间邻域块; 特征融合

**中图分类号** TP751.1; P407.8

**文献标识码** A

**doi:** 10.3788/CJL202148.0910001

## 1 引言

高光谱遥感技术是现代遥感领域中最具前景的技术之一<sup>[1-3]</sup>, 高光谱图像数据中含有十分丰富的地物光谱信息和空间信息, 广泛应用于农业遥感、资源勘测及变化检测等众多领域<sup>[4-6]</sup>。高光谱图像的主要特点有数据量大、波段多和光谱分辨率高<sup>[7-9]</sup>, 如何利用高光谱图像中的丰富地物信息实现地物的精细分类是目前研究者们积极探索的问题之一。

为了充分利用高光谱图像中的光谱信息, 研究者们积极提出了一些经典的光谱分类方法, 如  $K$  最近邻( $K$  Nearest Neighbor,  $KNN$ )分类法<sup>[10-11]</sup>、光谱角制图(Spectral Angle Mapping, SAM)法<sup>[12]</sup>和支持向量机(Support Vector Machine, SVM)法<sup>[13]</sup>。 $KNN$ 法是根据  $K$  个训练样本的类别采用投票的方式进行类别判断的方法, SAM 法是将像元的光谱视为高维向量, 通过计算两向量间的夹角来判定未知样本的类别, SVM 法是一种基于核分类的方法, 其有效解决了在样本数量有限的情况下出现

Hughes 问题。尽管这些方法已在实际运用中得到广泛应用, 但是这些基于光谱的分类方法都需要大量的标记样本进行支撑, 而获得标记样本的过程需要消耗大量的人力物力。同时, 上述方法在分类过程中并未考虑数据样本的空间信息。

近年来, 学者们通过研究发现, 仅仅利用图像数据的光谱信息进行分类, 分类效果不佳, 因此提出了多种信息充分利用的图像分类方法。Huang 等<sup>[14]</sup>提出了组合核支持向量机(Support Vector Machine with Composite Kernels, SVMCK)的分类算法, 该算法引入内核以充分利用图像的空间信息和光谱信息, 从而取得了较好的分类精度。Chen 等<sup>[15]</sup>提出了一种基于边缘保持滤波(Edge-Preserving Filtering, EPF)的高光谱图像分类算法, 该算法充分考虑了图像边缘像素点的空间位置, 减少边缘像素点的错分情况, 从而取得了较好的分类效果。Tu 等<sup>[16]</sup>提出了一种结合 CCJSR(Fusing Correlation Coefficient and Joint Sparse Representation)的分类方法, 该方法结合图像像素点的相关系数和稀疏关系, 从而获得更好的分类性能。Cui 等<sup>[17]</sup>提出了

收稿日期: 2020-09-04; 修回日期: 2020-09-17; 录用日期: 2020-11-18

基金项目: 国家自然科学基金(41371338)、重庆市基础研究与前沿探索项目(cstc2018jcyjAX0093)、重庆市研究生科研创新项目(CYB19039)

\*E-mail: liujm@cqu.edu.cn

一种基于类别关系的稀疏表示分类 (Class-dependent Sparse Representation Classifier, CDSRC) 方法, 该方法可以将像元间的稀疏关系和邻域关系进行有效结合, 从而提高地物分类的效果。虽然上述算法都有效利用了高光谱图像数据中的多种关系进行分类, 但未充分考虑图像数据中多种空间信息的关系。

为了充分利用高光谱数据中的空间信息以增强各类地物间的区分性, 本文提出一种图像重构特征融合分类法 (Reconstruction Feature Fusion Method, RSFM)。该方法首先利用高光谱图像数据的特性来提取图像的 LBP (Local Binary Patterns) 特征以计算 LBP 特征值, 同时提取像元的空间邻域块, 并根据标签信息去除空间邻域块中与分类无关的背景点; 接着利用光谱距离得到每个空间邻域块中像素点的权重, 计算得到中心像素点的空间重构特征值; 然后将 LBP 特征值与空间重构特征值进行融合, 获得重构的特征融合值; 最后采用 KNN 算法对特征融合值进行分类, 根据欧氏距离来判断样本数据的类别。实验结果表明, 所提方法的分类效果与其他方法相比均有明显提升, 尤其在训练样本数较少的情况下存在优势。




图 1 高光谱数据 LBP 纹理特征的计算过程

Fig. 1 Calculation process of LBP texture features in hyperspectral data

### 2.2 空间重构特征

在高光谱数据中, 构造以像元  $x_{ij}$  为中心, 尺寸为  $\omega \times \omega$  的空间区域  $\Omega(x_{ij})$ ,  $\omega$  值取正奇数, 则像元  $x_{ij}$  的空间邻域块可定义为

$$\Omega(x_{ij}) = \{x_{yz} | y \in [i - a, i + a], z \in [j - a, j + a]\}, \quad (2)$$

式中:  $x_{yz}$  为  $\Omega(x_{ij})$  中除中心像元以外的任一近邻点;  $a = (\omega - 1)/2$  为  $\Omega(x_{ij})$  的半径, 共有  $\omega^2$  个像元。

通常的空间邻域选取方法选择整个方块的像素区域作为空间邻域块, 但是对于某一类别地物的边缘像素点来说, 在邻域块内会存在不属于任何分类类别中的像素点 (这类像素点统称为背景像素点)。在空间邻域块的选取过程中, 需要去除背景像素点。

## 2 本文方法

### 2.1 LBP 特征

LBP<sup>[18]</sup> 是利用邻近像素点与中心像素点的灰度值差值来描述图像的局部纹理信息, 通过将中心像元的灰度值与相邻像元进行比较, 当相邻像元的灰度值大于中心像元时, 则编码为“1”, 否则编码为“0”, 得到的 8 位二进制数即为中心像素点的 LBP 特征值。

LBP 特征的提取是以中心像素点为中心, 以  $r$  为邻域半径来寻找空间近邻点。假设图像的邻域中心像素点为  $t_c$ , 则  $k$  个邻近点分别为  $\{t_0, t_1, \dots, t_{k-1}\}$ , 则该点的 LBP 特征值可表示为

$$L_{LBP,k,r}(t_c) = \sum_{i=0}^{k-1} s(t_i - t_c) 2^i, \quad (1)$$

$$s(x) = \begin{cases} 1, & t_i \geq t_c \\ 0, & \text{otherwise} \end{cases}$$

假定在图像中选取  $3 \times 3$  的空间邻域范围, 通过比较中心像素点和邻近像素点的灰度值, 可编码为 0 或 1, 按照顺时针方向进行编码, 可以得到中心像素点的 LBP 特征值。高光谱数据 LBP 纹理特征的计算过程如图 1 所示。

当像素点的标签  $B_{label}$  值为 0 时, 将该点从空间邻域块中去除, 否则保留。当窗口尺寸为  $3 \times 3$  时, 在不同的位置处进行背景点去除操作后的空间邻域块如图 2 所示。其中每一方格代表一个像素点,  $x_{ij}$  为中心像元。当像素点处于角落或边沿位置时, 则空间邻域块中存在大量的背景点, 因此仅保留区间内  $B_{label}$  值不为 0 的相邻像元, 滤除背景点, 这可有效提升地物分类的精度。

将空间邻域块中的背景点去除后, 可计算中心像素点的空间重构特征值, 表达式为

$$\hat{x}_{ij} = \frac{\sum_{x_{yz} \in \Omega(x_{ij})} v x_{yz}}{\sum_{x_{yz} \in \Omega(x_{ij})} v}, \quad (3)$$

式中:  $v = \exp(-\|x_{ij} - x_{yz}\|)$  为权重, 表示在邻域空间块  $\Omega(x_{ij})$  中的像元  $x_{yz}$  与中心像元  $x_{ij}$  的相似

程度,当像元  $x_{yz}$  与中心像元的相似度高时,则  $v$  值较大,若相邻像元与中心像元差异较大时,则  $v$  值较小。该重构方法充分利用了数据中的空间信息,

减少了不同类别相邻像元及背景点的影响,同时由于每个像元均由其相邻像元进行重构,对高光谱图像的分类更为有利,使分类结果更加精确。




图 2 像元  $x_{ij}$  的空间邻域块。(a)正常位置;(b)边沿位置;(c)角落位置

Fig. 2 Spatial domain blocks of pixel  $x_{ij}$ . (a) Normal position; (b) edge position; (c) corner position

### 2.3 图像重构特征融合分类方法

针对 2.2 节高光谱图像的空间信息未充分利用的问题,提出一种图像重构特征融合分类法(RSFM)。该方法的核心思想:提取像元的 LBP 特征以获得像元的 LBP 特征值,提取像元的空间邻域

块以去除空间邻域中的无关背景点,从而计算像元的空间重构特征值,并将两个特征值进行堆叠融合以得到像元  $x_{ij}$  的 LBP-空间重构特征融合值,最后对其采用 KNN 算法进行分类,具体算法流程如图 3 所示。

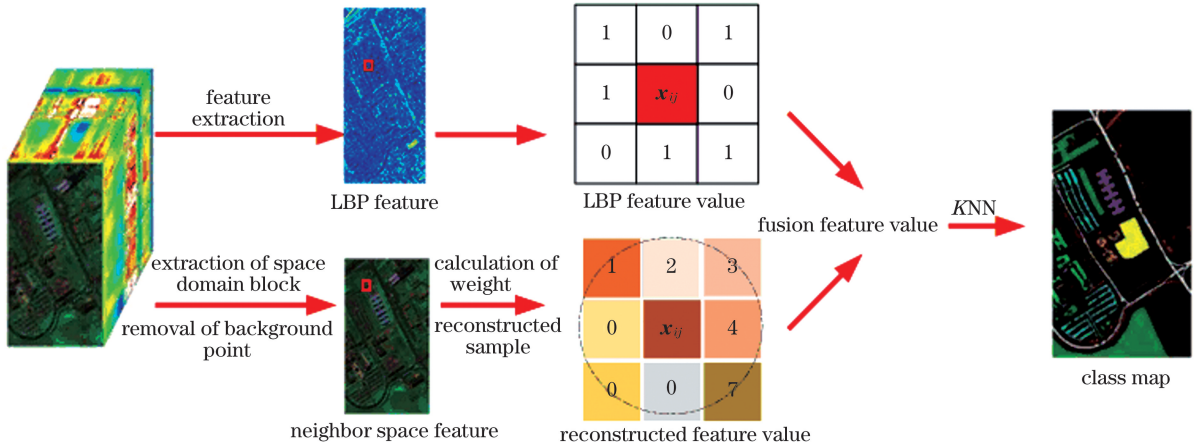


图 3 图像重构特征的融合流程

Fig. 3 Fusion process of image reconstruction features

对于图像的像元  $x_{ij}$  来说,其 LBP-空间特征融合值定义为

$$c_{x_{ij}} = \{c_{x_{ij},LBP}, c_{x_{ij},\hat{x}}\}, \quad (4)$$

式中: $c_{x_{ij},LBP}$  为像元  $x_{ij}$  的 LBP 特征值; $c_{x_{ij},\hat{x}}$  为像元  $x_{ij}$  的空间重构特征值。对图像的 LBP-空间重构特征融合值采用 KNN 算法进行分类,首先设置  $K$  值,选择  $K$  个最近相似样本,计算测试样本  $x$  与所有训练样本(样本类别已知)之间的欧氏距离,表达式为

$$d(c_x, c_{x_{ij}}) = \|c_x - c_{x_{ij}}\| = \sqrt{(c_x - c_{x_{ij}})^T (c_x - c_{x_{ij}})}. \quad (5)$$

根据欧氏距离来判断样本数据的类别,可表示为

$$L(c_x) = \operatorname{argmin} d(c_x, c_{x_{ij}}). \quad (6)$$

输入高光谱图像数据  $X$ ,空间窗口为  $\omega$ ,邻近点的个数为  $k$ ,输出测试样本的类别,RSFM 的分类流

程如下。

- 1) 根据训练样本比例,随机选取训练样本和测试样本。
- 2) 采用 LBP 特征提取方法对图像数据进行纹理特征提取,得到每个像元的 LBP 特征值。
- 3) 提取每个像元的空间邻域块,根据已知标签信息去除空间邻域块中类别标签为 0 的无关背景点。
- 4) 利用光谱距离得到每个空间邻域块中像素点的权重,计算中心像素点的空间重构特征值。
- 5) 将 LBP 特征值与空间重构值进行叠加融合,得到 LBP-空间重构特征融合值。
- 6) 采用 KNN 算法将像素点的 LBP-空间重构特征融合值进行分类,选择邻近点的个数来计算训练样本和测试样本之间的欧氏距离,根据欧氏距离来判断测试样本点的类别。



### 3 数据集和实验设置

#### 3.1 数据集

Indian Pines 数据集是 1992 年美国国家宇航局通过 AVIRIS 传感器拍摄美国印第安纳州获得的, 该数据集尺寸为  $145 \text{ pixel} \times 145 \text{ pixel}$ , 共覆盖

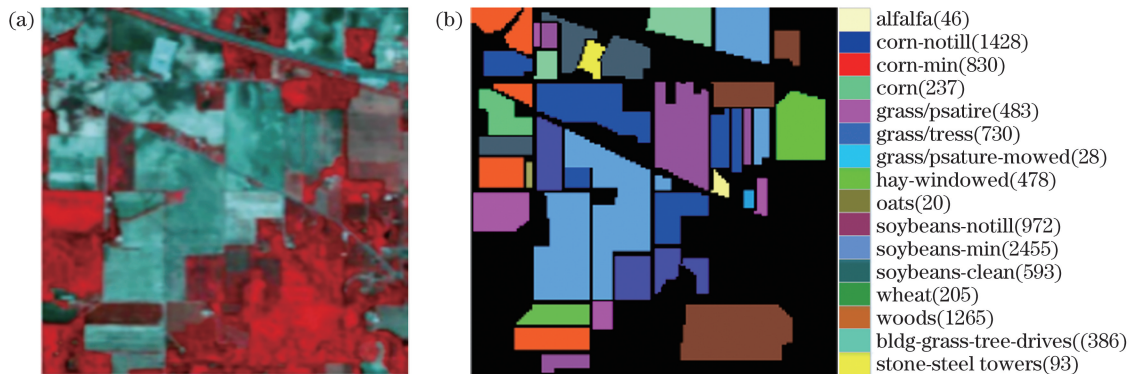


图 4 Indian Pines 高光谱影像。(a)假彩色图;(b)真实地物图

Fig. 4 Indian Pines hyperspectral image. (a) False colour image; (b) actual feature map

Pavia University 数据集是由 ROSIS 传感器采集位于意大利北部的帕维亚大学校园获得的, 该数据集的尺寸为  $610 \text{ pixel} \times 340 \text{ pixel}$ , 覆盖  $0.43 \sim 0.86 \mu\text{m}$  的波段范围, 空间分辨率为  $1.3 \text{ m/pixel}$ , 剔除由干扰因素影响的 12 个波段, 则剩余 103 个波段, 主要包括道路、土地和树木等 9 类地物。图 5 为 Pavia University 数据集的假彩色图和真实地物信息。



图 5 Pavia University 高光谱影像。(a)假彩色图;

(b)真实地物图

Fig. 5 Pavia University hyperspectral image. (a) False colour image; (b) actual feature map

#### 3.2 实验设置

实验使用 Kappa 系数、总体分类精度 (Overall Accuracy, OA) 以及平均分类精度 (Average Accuracy, AA) 作为评价各类算法的评价标准。由于每次实验存在误差, 为了减少实验误差以及确保结果的准确性, 在相同的实验条件下, 最终的实验结

果均由 10 次实验结果取均值。0.40~0.25  $\mu\text{m}$  的波段范围, 空间分辨率为  $20 \text{ m/pixel}$ , 剔除由干扰因素影响的 20 个波段, 则剩余 200 个波段, 主要包括房屋、森林、道路和植被等 16 类不同的地物。图 4 为 Indian Pines 数据集的假彩色图和真实地物信息, 其中括号中的数字代表对应类别地物的个数。

果均由 10 次实验结果取均值。

为了验证所提方法的有效性, 将与各类方法进行对比。KNN 法、SAM 法和 SVM 法仅利用了图像数据中的光谱信息, 将光谱信息和空间信息进行结合的分类方法有 SVMCK 法和 EPE 法, 利用多特征信息融合分类的方法有 CDSRC 法和 CCJSR 法, 利用 LBP 特征的分类方法有 LBP-SVM 法与 LBP-SAM 法。在实验过程中, 每种方法的所用参数都调整至最优, 同时采用交叉交叉的方式进行实验。

为了验证所提方法的分类精度受空间窗口  $\omega$  的影响, 从数据集中随机选取 1% 的标记样本作为训练样本, 剩余作为测试样本。设置邻近点的个数为 1, 由于有的类别样本数目较少, 样本数目小于 100 的类别, 则选取 10 个训练样本。空间窗口  $\omega$  对分类精度的影响曲线如图 6 所示。

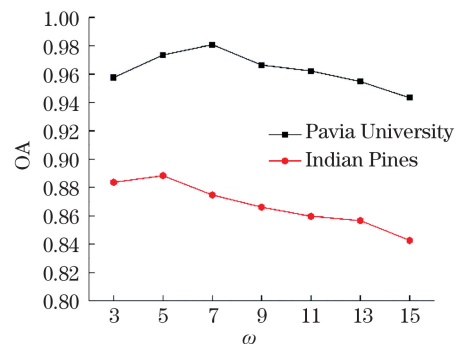


图 6 空间窗口对分类精度的影响

Fig. 6 Influence of spatial window on classification accuracy

从图 6 可以看到,所提方法的分类精度会受到空间窗口尺寸的影响,分类精度随空间窗口的调整呈现先提升后降低的变化趋势;当  $\omega$  值过小时,空间邻域块中包含的空间信息较少,当  $\omega$  值过大时,空间邻域块中可能会引入大量的异类地物,这都会使分类精度下降。由于 Indian Pines 数据集中存在 16 类地物,地物分布较为复杂,若  $\omega$  值过大则更易引入异类地物,而 Pavia University 数据集中仅有 9 类地物,地物分布较为简单,因此前者的空间窗口  $\omega$  值小于后者。根据图 6 可知,对于 Indian Pines 数据集,当  $\omega=5$  时,分类效果最优;对于 Pavia University 数据集,当  $\omega=7$  时,分类效果最优。

## 4 实验结果

### 4.1 Indian Pines 实验结果及分析

为了验证所提方法的有效性,从数据集中分别提取  $A=1\%$ 、 $2\%$ 、 $4\%$ 、 $6\%$ 、 $8\%$  和  $10\%$  的数据作为训练样本,其余样本用于测试。在不同比例下,各方法的总体分类精度如表 1 所示。

从表 1 可以看到,随着训练样本比例的增大,各类方法的分类精度均呈现上升趋势;KNN 法、SAM 法和 SVM 法仅考虑了图像中的光谱信息,所以分类效果较差,SVMCK 法和 EPF 法都是基于空-谱

联合分类的方法,能够较好地利用高光谱图像中像元间的空间位置关系来提升分类鉴别的能力,所以分类精度有所上升;CDSRC 法和 CCJSR 法均利用了图像中多种关系进行融合分类,提升了分类表现,精度也优于基于光谱分类的方法;在提取  $10\%$  的训练样本中,所提方法的分类精度分别达到  $99.06\%$ ,OA 值比仅考虑了光谱信息的 KNN 法、SAM 法及 SVM 法分别提升约为  $30.45$ 、 $30.03$ 、 $18.35$  个百分点,比利用空-谱联合的 SVMCK 法和 EPF 法分别提升约为  $2.12$  个百分点和  $4.13$  个百分点,比 CDSRC 法和 CCJSR 法分别提升约为  $16.88$  个百分点和  $3.41$  个百分点,比 LBP-SVM 法和 LBP-SAM 法分别提升约  $2.45$  个百分点和  $3.94$  个百分点。原因在于所提方法不仅考虑了像元的 LBP 纹理特征,还对数据的空间邻域块进行了优化重构,在使用空间领域信息的同时去除背景点的干扰,因次减小了待测像元被错分的可能性,有效提高了分类精度,且分类效果较于其他方法有明显提升。

为了进一步分析各个分类方法在每一类地物上的分类精度,实验选取  $10\%$  的训练样本进行测试,在 Indian Pines 数据集中每类地物的分类精度、总分类精度(OA)、平均分类精度(AA)和和 Kappa 系数如表 2 所示。

表 1 Indian Pines 数据集上不同方法的分类结果

Table 1 Classification results of different methods on Indian Pines dataset

Method	(OA $\pm$ Std) / %					
	A=1%	A=2%	A=4%	A=6%	A=8%	A=10%
KNN	55.08 $\pm$ 1.44	59.30 $\pm$ 1.43	63.54 $\pm$ 1.03	66.38 $\pm$ 0.47	67.62 $\pm$ 0.67	68.61 $\pm$ 0.60
SAM	54.53 $\pm$ 2.07	60.01 $\pm$ 1.10	63.76 $\pm$ 0.84	66.04 $\pm$ 0.66	68.11 $\pm$ 0.87	69.03 $\pm$ 0.48
SVM	56.98 $\pm$ 2.16	65.23 $\pm$ 1.49	72.29 $\pm$ 1.29	76.25 $\pm$ 1.41	79.22 $\pm$ 0.78	80.71 $\pm$ 0.72
EPF	69.40 $\pm$ 3.50	76.51 $\pm$ 4.23	87.37 $\pm$ 2.50	91.31 $\pm$ 1.92	93.24 $\pm$ 1.49	94.93 $\pm$ 0.89
LBP-SVM	78.37 $\pm$ 2.08	84.76 $\pm$ 2.01	91.48 $\pm$ 0.72	93.13 $\pm$ 0.45	94.76 $\pm$ 0.32	96.61 $\pm$ 0.34
SVMCK	80.46 $\pm$ 1.67	84.94 $\pm$ 1.78	91.56 $\pm$ 0.45	94.50 $\pm$ 0.72	96.08 $\pm$ 0.42	96.94 $\pm$ 0.52
LBP-SAM	74.08 $\pm$ 2.77	82.33 $\pm$ 2.01	88.19 $\pm$ 1.61	92.05 $\pm$ 1.28	94.82 $\pm$ 1.15	95.12 $\pm$ 0.68
CDSRC	73.84 $\pm$ 2.30	77.63 $\pm$ 0.90	79.62 $\pm$ 0.75	80.80 $\pm$ 0.53	81.22 $\pm$ 0.89	82.18 $\pm$ 0.41
CCJSR	70.55 $\pm$ 2.32	79.67 $\pm$ 1.44	87.16 $\pm$ 1.01	91.78 $\pm$ 0.52	94.38 $\pm$ 0.71	95.65 $\pm$ 0.42
RSFM	<b>86.87<math>\pm</math>1.78</b>	<b>93.26<math>\pm</math>1.11</b>	<b>96.85<math>\pm</math>0.77</b>	<b>98.12<math>\pm</math>0.39</b>	<b>98.84<math>\pm</math>0.36</b>	<b>99.06<math>\pm</math>0.31</b>

表 2 Indian pines 数据集中各类地物在不同方法下的分类结果

Table 2 Classification results of various ground objects in Indian Pines dataset under different methods

Class	KNN	SAM	SVM	EPF	LBP-SVM	SVMCK	LBP-SAM	CDSRC	CCJSR	RSFM
1	0.346	0.735	0.683	0.585	0.975	<b>1.000</b>	0.090	0.892	<b>1.000</b>	<b>1.000</b>
2	0.538	0.547	0.699	0.922	0.966	0.945	0.929	0.752	0.956	<b>0.995</b>
3	0.510	0.632	0.762	0.933	0.929	0.941	0.920	0.707	0.927	<b>0.979</b>
4	0.375	0.442	0.686	0.873	0.953	0.830	0.778	0.678	0.898	<b>0.972</b>
5	0.801	0.844	0.799	0.963	0.959	0.984	0.995	0.911	0.972	<b>0.984</b>
6	0.825	0.826	0.916	<b>1.000</b>	0.973	0.991	0.996	0.941	0.969	0.999
7	0.700	0.750	0.700	0.957	0.821	<b>1.000</b>	0.850	0.917	0.793	<b>1.000</b>
8	0.907	0.945	0.967	<b>1.000</b>	<b>1.000</b>	<b>1.000</b>	0.973	0.982	0.995	<b>1.000</b>
9	0.314	0.333	0.483	<b>1.000</b>	0.938	0.667	<b>1.000</b>	0.833	0.938	<b>1.000</b>
10	0.602	0.583	0.719	0.857	0.974	0.952	0.856	0.753	0.964	<b>0.979</b>
11	0.691	0.721	0.771	0.966	0.968	0.973	0.947	0.761	0.959	<b>0.994</b>
12	0.491	0.479	0.808	0.961	0.924	<b>0.998</b>	0.972	0.793	0.917	0.989
13	0.861	0.775	0.879	0.995	0.977	<b>1.000</b>	0.957	0.973	0.974	0.984
14	0.906	0.891	0.942	0.997	<b>1.000</b>	0.969	0.999	0.937	0.991	<b>1.000</b>
15	0.502	0.498	0.623	0.891	0.949	0.987	0.913	0.725	0.959	<b>1.000</b>
16	0.988	0.987	0.964	<b>1.000</b>	<b>0.960</b>	<b>1.000</b>	0.924	0.914	0.963	<b>1.000</b>
OA	0.682	0.697	0.795	0.948	0.966	0.964	0.951	0.813	0.959	<b>0.992</b>
AA	0.647	0.685	0.775	0.931	0.954	0.957	0.946	0.842	0.948	<b>0.971</b>
$\kappa$	0.637	0.654	0.765	0.941	0.961	0.959	0.943	0.786	0.953	<b>0.991</b>

从表 2 可以看到, KNN 法的分类精度为 68.20%, SAM 法的分类精度为 69.69%, SVM 法的分类精度为 79.47%, EPF 法的分类精度为 94.84%, LBP-SVM 法的分类精度为 96.62%, SVMCK 法的分类精度为 96.42%, LBP-SAM 法的分类精度为 95.06%, CDSRC 法的分类精度为 81.28%, CCJSR 法的分类精度为 95.93%, RSFM 法的分类精度为 99.27%, 所提方法在大多数类别

上的分类精度较高, 而且在 alfalfa 和 woods 等类别的效果尤为显著, 原因在于 RSFM 法充分利用了图像的纹理信息及空间信息, 消除图像中的冗余信息, 从而使鉴别能力更为突出, 分类效果较好。图 7 为各个分类方法的分类结果。从图 7 可以看到, 相较于其他对比方法, 所提方法在分类结果上的表现更为优异, 分类结果图更为平滑, 错分点更少。




图 7 Indian pines 数据集上各方法的分类结果。(a)假彩色图像;(b)真值图;(c) KNN 法;(d) SAM 法;(e) SVM 法;(f) EPF 法;(g) LBP-SVM 法;(h) SVMCK 法;(i) LBP-SAM 法;(j) CDSRC 法;(k) CCJSR 法;(l) RSFM 法

Fig. 7 Classification results of each methods on Indian Pines dataset. (a) False colour image; (b) ground truth; (c) KNN method; (d) SAM method; (e) SVM method; (f) EPF method; (g) LBP-SVM method; (h) SVMCK method; (i) LBP-SAM method; (j) CDSRC method; (k) CCJSR method; (l) RSFM method

### 4.2 Pavia University 实验结果及分析

在 Pavia University 数据集中,表 3 为不同方法在不同训练样本比例下的总体分类精度。从表 3 可以看到,随着训练样本比例的增加,各方法的分类精度呈上升趋势,当训练样本所占比例为 1%、2%、4%、6%、8% 和 10% 时,所提方法的分类精度较其他方法均有明显提升;当取 10% 的训练样本时,所提方法的分类精度分别达到 99.73%,

OA 值比仅考虑了光谱信息的 KNN 法、SAM 法及 SVM 法分别提升约为 16.11,16.13,8.61 个百分点,比利用空-谱联合的 SVMCK 法和 EPF 法分别提升约为 0.82 个百分点和 1.72 个百分点,比 CDSRC 法和 CCJSR 法分别提升约为 14.7 个百分点和 6.33 个百分点,比 LBP-SVM 法和 LBP-SAM 法分别提升约为 1.76 个百分点和 3.41 个百分点。

表 3 不同分类方法在 Pavia University 数据集上的分类结果

Table 3 Classification results of different classification methods on Pavia University dataset

Method	(OA±Std) / %					
	A=1%	A=2%	A=4%	A=6%	A=8%	A=10%
KNN	77.79±0.71	79.88±0.48	81.79±0.47	82.52±0.35	83.18±0.19	83.62±0.18
SAM	77.80±0.64	79.82±0.52	81.75±0.45	82.57±0.22	83.11±0.41	83.60±0.20
SVM	84.97±0.63	87.97±0.67	89.47±0.30	90.39±0.34	90.90±0.11	91.12±0.20
EPF	93.11±1.63	95.16±1.26	96.24±0.81	97.18±0.61	97.86±0.40	98.01±0.24
LBP-SVM	90.78±0.76	94.61±0.42	96.11±0.29	97.03±0.31	97.65±0.27	97.97±0.13
SVMCK	92.54±3.34	96.21±0.53	97.86±0.32	98.34±0.26	98.75±0.07	98.91±0.15
LBP-SAM	91.74±1.18	92.67±1.24	94.04±0.81	95.69±0.71	96.11±0.53	96.32±0.42
CDSRC	81.04±0.89	82.63±0.53	83.79±0.28	84.21±0.42	84.58±0.25	85.03±0.23
CCJSR	78.17±0.67	82.95±0.51	87.80±0.40	90.26±0.36	92.33±0.21	93.40±0.27
RSFM	<b>96.51±0.59</b>	<b>98.38±0.49</b>	<b>99.13±0.30</b>	<b>99.44±0.24</b>	<b>99.58±0.18</b>	<b>99.73±0.16</b>

表 4 为 Pavia University 数据集中各类地物在不同方法下的分类结果,图 8 为各类算法所对应的分类结果。从表 4 和图 8 可以看到,所提方法的 OA、AA 和 Kappa 系数相对于其他几种分类方法均

有提升,且在 asphalt 和 corn-min 等类别的分类效果尤为显著,得到的分类结果图中所提方法的图像分布较为平滑,分类效果较好,由此更加验证了所提方法的有效性和可行性。

表 4 Pavia University 数据集中各类地物在不同方法下的分类结果

Table 4 Classification results of various ground objects in Pavia University dataset under different methods

Class	KNN	SAM	SVM	EPF	LBP-SVM	SVMCK	LBP-SAM	CDSRC	CCJSR	RSFM
1	0.918	0.917	0.913	0.994	0.966	0.999	0.997	0.891	0.952	<b>1.000</b>
2	0.872	0.874	0.939	<b>1.000</b>	0.994	0.987	0.993	0.884	0.975	0.998
3	0.627	0.647	0.861	0.774	0.970	0.989	0.941	0.724	0.835	<b>1.000</b>
4	0.961	0.946	0.959	0.984	0.941	<b>1.000</b>	0.970	0.942	0.990	0.999
5	0.989	0.998	0.997	<b>1.000</b>	0.920	<b>1.000</b>	0.999	0.997	0.947	<b>1.000</b>
6	0.705	0.710	0.866	0.951	0.998	0.977	0.906	0.709	0.928	<b>0.999</b>
7	0.690	0.671	0.864	<b>1.000</b>	0.975	0.998	0.960	0.764	0.879	<b>1.000</b>
8	0.655	0.654	0.787	0.999	0.988	0.988	0.949	0.717	0.806	<b>1.000</b>
9	0.998	0.996	0.993	0.999	0.839	0.997	<b>1.000</b>	<b>1.000</b>	0.856	<b>1.000</b>
OA	0.835	0.835	0.912	0.981	0.979	0.910	0.965	0.851	0.937	<b>0.998</b>
AA	0.824	0.824	0.909	0.967	0.955	0.993	0.958	0.847	0.908	<b>0.999</b>
$\kappa$	0.778	0.778	0.882	0.975	0.971	0.986	0.956	0.801	0.916	<b>0.998</b>






图 8 Pavia University 数据集上各方法的分类结果。(a)假彩色图像;(b)真值图;(c) KNN 法;(d) SAM 法;(e) SVM 法;(f) EPF 法;(g) LBP-SVM 法;(h) SVMCK 法;(i) LBP-SAM 法;(j) CDSRC 法;(k) CCJSR 法;(l) RSFM 法

Fig. 8 Classification results of each methods on Pavia University dataset. (a) False colour image; (b) ground truth; (c) KNN method; (d) SAM method; (e) SVM method; (f) EPF method; (g) LBP-SVM method; (h) SVMCK method; (i) LBP-SAM method; (j) CDSRC method; (k) CCJSR method; (l) RSFM method

## 5 结 论

传统的高光谱分类方法未能将高光谱数据集的空间特征及图像的邻域信息充分利用,针对这一问题,提出一种基于图像重构特征融合图像分类的方法。该方法首先在提取像元 LBP 特征的同时提取该点的空间邻域块,随后根据图像标签信息去除邻域块中的背景点,利用光谱距离得到空间邻域块中像素点的权重并计算其空间重构特征值,接着将像素点的 LBP 特征值与空间重构特征值进行叠加融合,可以得到重构特征融合值,最后采用  $K$  最近邻分类算法对特征进行分类,计算测试样本点和训练样本点的欧氏距离,根据距离来判断测试样本点的类别。实验结果表明,所提的 RSFM 法与相关分类方法相比,能够得到更好的分类性能,在 Indian Pines 数据集上分类精度提升约为 2.12~30.45 个百分点,在 Pavia University 数据集上分类精度提升约为 0.82~16.12 个百分点。

但是所提方法仅利用了图像数据的纹理信息和空间信息,并未对图像深层信息进行利用。对此,后续的研究工作可以考虑引入光谱信息或使用空间修

正的方法进行补偿,同时也可以考虑引入深度学习网络对图像的深层信息进行挖掘,使分类效果可以得到进一步提升。

## 参 考 文 献

- [1] Du P J, Xia J S, Xue Z H, et al. Review of hyperspectral remote sensing image classification[J]. Journal of Remote Sensing, 2016, 20(2): 236-256. 杜培军, 夏俊士, 薛朝辉, 等. 高光谱遥感影像分类研究进展[J]. 遥感学报, 2016, 20(2): 236-256.
- [2] Wang X F, Zhang J P, Yan Q J, et al. Target detection for hyperspectral image based on support vector data description [J]. Chinese Journal of Lasers, 2014, 41(s1): s114003. 王晓飞, 张钧萍, 阎秋静, 等. 基于支持向量数据描述的高光谱图像目标检测[J]. 中国激光, 2014, 41(s1): s114003.
- [3] Liu L X, Li M Z, Zhao Z G, et al. Recent advances of hyperspectral imaging application in biomedicine [J]. Chinese Journal of Lasers, 2018, 45(2): 0207017. 刘立新, 李梦珠, 赵志刚, 等. 高光谱成像技术在生物医学中的应用进展[J]. 中国激光, 2018, 45(2):



- 0207017.
- [4] Huang H, Wang L H, Shi G Y. Spatially-regularized manifold discriminant analysis algorithm for hyperspectral image classification [J]. *Acta Optica Sinica*, 2020, 40(2): 0228001.  
黄鸿, 王丽华, 石光耀. 面向高光谱影像分类的空间正则化流形鉴别分析方法 [J]. *光学学报*, 2020, 40(2): 0228001.
- [5] Luo F L, Du B, Zhang L P, et al. Feature learning using spatial-spectral hypergraph discriminant analysis for hyperspectral image [J]. *IEEE Transactions on Cybernetics*, 2019, 49(7): 2406-2419.
- [6] Du B, Huang Z Q, Wang N, et al. Joint weighted nuclear norm and total variation regularization for hyperspectral image denoising [J]. *International Journal of Remote Sensing*, 2017, 66(7): 1646-1657.
- [7] Bi X J, Zhou Z Y. Hyperspectral image classification algorithm based on two-channel generative adversarial network [J]. *Acta Optica Sinica*, 2019, 39(10): 1028002.  
毕晓君, 周泽宇. 基于双通道 GAN 的高光谱图像分类算法 [J]. *光学学报*, 2019, 39(10): 1028002.
- [8] Feng F B, Li W, Du Q, et al. Dimensionality reduction of hyperspectral image with graph-based discriminant analysis considering spectral similarity [J]. *Remote Sensing*, 2017, 9(4): 323-327.
- [9] Fang L Y, Wang C, Li S T, et al. Hyperspectral image classification via multiple-feature-based adaptive sparse representation [J]. *IEEE Transactions on Instrumentation and Measurement*, 2017, 66(7): 1646-1657.
- [10] Ji L, Zhang X, Zhang L M, et al. Hyperspectral image classification algorithm based on space-spectral weighted nearest neighbor [J]. *Laser & Optoelectronics Progress*, 2020, 57(6): 061013.  
纪磊, 张欣, 张丽梅, 等. 基于空谱加权近邻的高光谱图像分类算法 [J]. *激光与光电子学进展*, 2020, 57(6): 061013.
- [11] Huang H, Zheng X L. Hyperspectral image classification with combination of weighted spatial-spectral and KNN [J]. *Optics and Precision Engineering*, 2016, 24(4): 873-881.  
黄鸿, 郑新磊. 加权空-谱与最近邻分类器相结合的高光谱图像分类 [J]. *光学精密工程*, 2016, 24(4): 873-881.
- [12] Awad M M. Forest mapping: a comparison between hyperspectral and multispectral images and technologies [J]. *Journal of Forestry Research*, 2018, 29(5): 1395-1405.
- [13] Wang K, Cheng L G, Yong B. Spectral-similarity-based kernel of SVM for hyperspectral image classification [J]. *Remote Sensing*, 2020, 12(13): 2154.
- [14] Huang H, Duan Y L, Shi G Y, et al. Fusion of weighted mean reconstruction and SVMCK for hyperspectral image classification [J]. *IEEE Access*, 2018, 6: 15224-15235.
- [15] Chen Z K, Jiang J J, Zhou C, et al. SuperBF: superpixel-based bilateral filtering algorithm and its application in feature extraction of hyperspectral images [J]. *IEEE Access*, 2019, 7: 147796-147807.
- [16] Tu B, Zhang X F, Kang X D, et al. Hyperspectral image classification via fusing correlation coefficient and joint sparse representation [J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, 15(3): 340-344.
- [17] Cui M S, Prasad S. Class-dependent sparse representation classifier for robust hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(5): 2683-2695.
- [18] Ye Z, Dong R, Bai L, et al. Hyperspectral image classification based on segmented local binary patterns [J]. *Sensing and Imaging*, 2020, 21(1): 1-16.

## Hyperspectral Image Classification Method Based on Image Reconstruction Feature Fusion

Liu Jiamin\*, Zheng Chao, Zhang Limei, Zou Zehua

*Key Laboratory of Optoelectronic Technique System of the Ministry of Education, Chongqing University, Chongqing 400044, China*

### Abstract

**Objective** Hyperspectral remote-sensing images contain abundant information and provide a large amount of data. For this reason, hyperspectral remote-sensing imaging is widely used in environmental detection, target recognition, and other fields. This paper focuses on feature extraction and classification methods for hyperspectral images. The

traditional classification method does not fully utilize the spatial information in hyperspectral datasets and tends to ignore the effect of background points on the classification. The present paper proposes a classification based on feature fusion using a hyperspectral image reconstruction method. The fused features fully include the spatial information of the data image. The method accurately classifies the images in the Indian Pines and Pavia University datasets. Our basic strategy and findings are anticipated to assist the design of new classification methods of hyperspectral images.

**Methods** The proposed method fuses the features extracted by image reconstruction. The method first extracts the local binary patterns (LBPs) of each pixel to obtain the LBP feature value. Second, it extracts the spatial neighborhood block of each pixel and removes the redundant background pixels in each block based on the known label information of the image. The result is a new spatial neighborhood block. Each pixel is weighted by the spectral distance, and its characteristic value is calculated and reconstructed. The LBP eigenvalue of each pixel and its reconstructed eigenvalue are superimposed into a reconstructed fused eigenvalue. Finally, the pixels are classified by a  $K$  nearest neighbor (KNN) classifier, and the type of each test sample point is determined by the Euclidean distance between the test sample and the training samples. The classification performance of the method is experimentally evaluated on the two hyperspectral datasets from the Indian Pines and Pavia University.

**Results and Discussions** The classification performances of our method and several existing methods are evaluated by the Kappa coefficient, overall accuracy, and average accuracy. To achieve robust results, 10 experiments are conducted under the same experimental conditions, and the results are averaged to give the final result. The proposed reconstruction feature fusion method (RSFM) outperformed the related classification algorithms. Among the competing methods, the KNN, spectral angle mapper (SAM), and state vector machine (SVM) methods use only the spectral information in the image data. SVM with composite kernel and edge-preserving filtering (EPF) combine the spectral and spatial information, class-dependent sparse representation classifier and correlation coefficient and joint sparse representation fuse the multifeature information, and LBP-SVM and LBP-SAM use the LBP features. Relative to the existing algorithms, our method improves the classification accuracies of the Indian Pines and Pavia University datasets by around 2.12–30.45 percentage points (Table 2) and 0.82–16.12 percentage points (Table 3), respectively. The proposed method not only considers the LBP texture characteristics of the pixel, but also optimizes the reconstruction of the spatial domain of the data. When using the spatial domain information, it removes the interfering background points, thus reducing the number of pixels to be measured. The misclassification probability is reduced, and the classification effect is significantly improved over those of the other methods.

**Conclusions** The proposed hyperspectral classification method effectively improves the classification accuracy of hyperspectral images by extracting the LBP feature of each pixel (thus obtaining the LBP feature value) and removing the interference of spatial background points, which eliminates the redundant information in the image. Consequently, the pixel misclassification probabilities are reduced, and the discrimination ability is enhanced. Experiments on two widely used hyperspectral datasets confirmed the superior performance of the proposed RSFM method over other relevant classification algorithms. The classification accuracy is improved by approximately 2.12–30.45 percentage points on the Indian Pines dataset and 0.82–16.12 percentage points on the Pavia University dataset. Therefore, the method is both valid and feasible.

**Key words** remote sensing; hyperspectral remote sensing; local binary patterns feature; spatial neighborhood block; feature fusion

**OCIS codes** 280.4788; 100.4145; 100.5010; 300.6170