

# 融合低秩和形态学的高光谱影像特征提取

江楠<sup>1</sup>, 张国明<sup>2</sup>, 王俊淑<sup>3</sup>, 韦玉春<sup>3</sup>

(1.生态环境部珠江流域南海海域生态环境监督管理局, 广东 广州 510611)

(2.江苏省卫生统计信息中心, 江苏 南京 210008)

(3.南京师范大学虚拟地理环境教育部重点实验室, 江苏 南京 210023)

**[摘要]** 高光谱遥感影像具有较高的光谱分辨率,能够精细刻画地物的反射光谱,具有很高的地物分类与识别能力。但高维波段之间通常具有较高的相关性,冗余度高,为影像处理和分析带来负担。针对高光谱影像特点的特征提取和选择为有效提取信息提供了保障。提出一种融合低秩和形态学的特征提取方法(MSEMP),利用低秩来精简高光谱影像中的冗余信息,获取秩最小的光谱紧致表达,并在此基础上利用多形态多尺度结构元素提取形态学剖面,获取影像空间特征。实验对 AVIRIS 和 ROSIS 传感器的两组数据进行测试,通过 MSEMP 提取特征后进行分类实验,可以获得较高的分类结果,证明了低秩和形态学相结合的特征提取方法的有效性。

**[关键词]** 高光谱遥感影像,形态学,低秩,特征提取

**[中图分类号]** TP751.1 **[文献标志码]** A **[文章编号]** 1672-1292(2020)02-0052-07

## Feature Extraction of Hyperspectral Remote Sensing Image Based on Low Rank and Morphology

Jiang Nan<sup>1</sup>, Zhang Guoming<sup>2</sup>, Wang Junshu<sup>3</sup>, Wei Yuchun<sup>3</sup>

(1.Ecology and Environment Administration for Pearl River Basin and South China Sea, Ministry of Ecology and Environment, Guangzhou 510611, China)

(2.Health Statistics and Information Center of Jiangsu Province, Nanjing 210008, China)

(3.Key Laboratory for Virtual Geographic Environment of Ministry of Education, Nanjing Normal University, Nanjing 210023, China)

**Abstract:** Hyperspectral remote sensing images with high spectral resolution can describe the reflection spectrum of ground objects in detail, and represent a good ability to classify and identify the ground objects. However, there is usually a high correlation and redundancy among bands, which brings burden to image processing and analysis. Feature extraction and selection of hyperspectral images provide a guarantee for the effective information extraction. In this paper, a feature extraction method, MSEMP, which integrates low rank and morphological profiles is proposed. Low-rank is utilized to simplify the redundant information and obtain the spectral compact expression with the minimum rank of hyperspectral data. Based on low rank representation of hyperspectral image, morphological profiles are extracted by using multi-shaped and multi-scale elements. The proposed algorithm is tested on AVIRIS and ROSIS data, and experimental results show that the classification accuracy based on MSEMP is higher compared with other methods. It indicates that MSEMP is an efficient feature extraction method.

**Key words:** hyperspectral remote sensing image, morphology, low rank, feature extraction

高光谱遥感影像光谱信息丰富,为刻画地物提供了更多的信息,使得精细分类与识别成为可能。但丰富的光谱信息在为高光谱影像分析与处理提供便利的同时,也带来了数据量的急剧增长,增加了后续图像处理的难度。以分类为例,若将全部光谱信息作为分类器的输入,会导致一系列问题,如分类速度下降、过拟合等。高光谱遥感影像的信息主要集中在低维空间,通过对原始数据进行低维映射,可降低高光谱影像数据分析与计算的复杂度。因此,现有高光谱影像分类前通常对数据进行降维处理<sup>[1-3]</sup>,在压缩数据和去除噪声的同时最大程度地保留信息量,即寻求高维数据的低秩表达<sup>[4-12]</sup>。通过低秩表达,可缓解高光谱影像波段之间强相关性、高冗余性和不规则噪声的负面影响<sup>[13]</sup>。

收稿日期:2019-05-08.

基金项目:国家自然科学基金项目(41471283)、江苏省自然科学基金项目(BK20171037)、江苏省高校自然科学研究面上项目(17KJB420003).

通讯作者:王俊淑,博士,实验师,研究方向:大数据、数据挖掘、遥感图像处理. E-mail: jlsdwjs@126.com

高光谱影像可以看作是数据立方体,其高维光谱信息与二维空间结构融合在一起<sup>[14-16]</sup>,有效地利用空间结构信息对于高光谱影像分析与处理非常重要.利用空间纹理信息可探索影像相邻像元之间的邻接性,能有效提高分类效果. Contourlet 变换<sup>[17]</sup>、低秩半全变差正则化模型<sup>[18]</sup>、小波理论及其变形<sup>[19]</sup>、分形理论<sup>[20]</sup>、马尔可夫随机场<sup>[21]</sup>、蒙特卡罗模型<sup>[22]</sup>可用于提取丰富的空间纹理特征;局部二进制模型(LBP)<sup>[23]</sup>、灰度共生矩阵(GLCM)以及对应的三维扩展模型<sup>[24-25]</sup>也可用于纹理信息提取,但通常具有较高的时间和空间复杂度.与之相比,形态学运算由于每个像元邻域没有严格的界定,可根据像元结构定义自适应邻域进行形态学剖面信息提取,具有较低的时间和空间计算复杂度<sup>[26]</sup>,更适合处理数据量较大和复杂程度较高的高光谱影像.但固定大小的单结构元提取的空间纹理模式单一,无法刻画复杂的空间结构.针对现有形态学剖面过度依赖结构元参数的问题<sup>[27]</sup>,本文通过鲁棒主成分分析对高光谱影像进行低秩表达,在此基础上,利用多形态多尺度结构元素提取高光谱影像,扩展形态学剖面特征,综合描述不同纹理模式的空间结构,弱化不同结构元参数对特征提取结果的影响,以获取高质量的高光谱影像特征表达.

## 1 基于鲁棒主成分分析的高光谱影像低秩表达

低秩表达(LRR)适用于探索不同子空间数据之间的相关性,可获得一个更紧致、区分度更高的表达,被认为是挖掘不同子空间数据之间相关性信息的有效工具,已被成功应用于人脸识别、背景分离、视频处理等方面.高光谱影像相邻波段相关性高,呈现低秩特性.主成分分析(PCA)<sup>[4]</sup>是低秩表达的一个特例,可获得高光谱影像的低秩结构.高光谱成像受传感器姿态、数据传输等外部条件影响,经常会混入幅值较大的异常值和噪声,此时使用 PCA 估计低秩结构的结果可能会与原始数据差距甚远.鲁棒主成分分析(RPCA)对于任意形式、任意幅值的稀疏噪声都具有鲁棒性,能够较好地估计高光谱影像的低秩结构.RPCA 将观测矩阵  $D$  分解为低秩矩阵  $A$  和稀疏矩阵  $E$  的和,目标是在最小化矩阵  $A$  的秩、减少  $\|E\|_0$  的同时,获得矩阵  $D$  的低秩近似  $A$ ,这是一个双目标优化问题:

$$\min_{A,E} (\text{rank}(A), \|E\|_0) \text{ 满足 } D=A+E. \quad (1)$$

引入折中因子  $\lambda (>0)$ ,将式(1)转为单目标优化问题:

$$\min_{A,E} \text{rank}(A) + \lambda \|E\|_0 \text{ 满足 } A+E=D. \quad (2)$$

Candès 等人<sup>[8]</sup>对目标函数进一步放松约束,重新描述了该问题:

$$\min_{A,E} \|A\|_* + \beta \|E\|_1 \text{ 满足 } D=A+E. \quad (3)$$

核范式  $\|A\|_*$  (即矩阵  $A$  奇异值的和)用于近似  $A$  矩阵的秩, $l_0$  范式  $\|E\|_0$  被  $l_1$  范式  $\|E\|_1$  取代, $\|E\|_1$  表示矩阵元素绝对值的和, $\beta$  为权重参数.只要误差矩阵  $E$  足够稀疏,通过求解对应的凸优化问题即可从原始数据  $D$  中恢复出低秩矩阵  $A$ ,得到数据的低秩结构,增广拉格朗日乘子法可有效求解式(3).利用低秩表达在去除噪声的同时,得到了冗余数据的低秩近似,但无法利用数据的空间信息.在高光谱影像低秩表达基础上提取形态学剖面特征,可有效利用高光谱影像的光谱和空间双重信息.

## 2 融合低秩和多形态多尺度结构元素的形态学剖面特征提取

基于形态学的空间信息提取具有较低的时间和空间计算复杂度,适合处理数据量较大、复杂程度较高的高光谱影像.结构元素对形态学操作的结果有决定性作用,需结合实际应用背景和期望合理选择结构元素的大小与形状.多数形态学应用采用单结构元素,只能提取到和结构元素的形状、大小完全相同的模式,相近或相似的模式则无法提取.多结构元素形态学操作可采用多个结构元素,从多个不同尺度分别对影像进行形态学运算,再将运算后的影像进行融合,可以综合不同形状的特征,避免单一结构元素形态学操作提取空间信息单一的情况.多尺度形态学操作利用不同半径大小的结构元素依次对影像进行形态学变换,通过连续使用尺度递增的结构元素进行测地和重建操作,可用于提取影像中不同尺度和对比度的空间结构<sup>[27]</sup>.

基本的形态学操作有膨胀、腐蚀、开运算和闭运算,通过已知大小和形状的结构元素对图像进行运算.腐蚀是将当前操作的像元赋予其结构元素定义的邻域范围内所有像元的最小值;与其相反,膨胀是取邻域范围内所有像元的最大值.开运算用于将影像中比结构元素  $e$  更小的目标移除,消除散点和毛刺,对影像进行平滑;闭运算用于将两个邻近的目标连结起来,改变影像中比  $e$  大的结构.随着结构元半径的增

加(尺度变化),将移除越来越多的目标.

开运算和闭运算可消除比结构元素小的对象,但同时也会引起目标变形,即引入影像中原来不存在的“假对象”. 形态学重建和测地形态学可以避免此类问题<sup>[28]</sup>,即通过重建操作重复大小为 1 的测地膨胀和腐蚀直至影像达到稳定状态. 若根据大小递增的结构元素进行连续的开操作简化影像,再使用重建开进行连结操作<sup>[27]</sup>,既可提取影像的空间结构特征,又不会引入形状噪声.

给定大小和形状的结构元素  $e$ ,通过尺度递增的结构元素对像元进行形态学开、闭运算,提取的特征向量组合称为形态学剖面  $MP$ ,也即多尺度形态学信息.  $MP$  由开剖面( $OP$ )和闭剖面( $CP$ )构成,影像  $I$  中像元  $x$  的开剖面( $OP$ )定义为一个  $n$  维向量<sup>[27]</sup>:

$$OP_d(x) = \gamma_R^d(x), \forall d \in [0, n], \quad (4)$$

式中,  $\gamma_R^d$  是用大小为  $d$  的结构元素  $e$  依次进行  $n$  次重建开操作. 闭剖面( $CP$ )定义为:

$$CP_d(x) = \phi_R^d(x), \forall d \in [0, n], \quad (5)$$

式中,  $\phi_R^d$  是用大小为  $d$  的结构元素  $e$  依次进行  $n$  次重建闭操作. 由于  $CP_0(x) = OP_0(x) = I(x)$ ,影像  $I$  的多尺度形态学剖面  $MP$  表示为:

$$MP(x) = [CP_n(x), \dots, I(x), \dots, OP_n(x)]. \quad (6)$$

特征维数与变换次数  $n$  对应,每个像元经过一系列形态学变换,由一维扩展为  $2n+1$  维向量,包含了丰富的结构信息<sup>[27]</sup>.

多形态多尺度结构元素形态学剖面信息(MSEMP)提取过程为:对原始影像数据,运用低秩表达去除噪声和冗余信息,此时得到的结果仍为高维数据. 为了减轻空间信息提取的计算压力,在低秩表达基础上,利用主成分分析(PCA)提取低秩影像矩阵的前  $q$  个主分量,然后以每个主分量为基影像,分别用  $k$  种不同形状、尺度递增的结构元素  $e_j(j=1, 2, \dots, t)$  对基影像  $PC_i(i=1, 2, \dots, q)$  进行形态学开、闭重建,重建后的主分量影像与基影像一起构成  $q \times (2n+1)$  维的剖面信息;最后将  $k$  种不同形状结构元素提取的空间形态学剖面求取均值,即得到高光谱影像的空间形态学剖面信息 MSEMP,形式化表达如下:

$$MSEMP = \frac{1}{k} \sum_{j=1}^k [MP_{PC_1}(x)_{e_j}, \dots, MP_{PC_q}(x)_{e_j}] = \frac{1}{k} \sum_{i=1, j=1}^{q, k} \{ [CP_n(PC_i), \dots, I(PC_i), \dots, OP_n(PC_i)]_{e_j} \}. \quad (7)$$

### 3 高光谱数据特征提取实验分析

实验选取两个不同地表覆盖类型的遥感影像进行测试. Indian Pines 数据是机载可见光/红外成像光谱仪(AVIRIS)1992 年获取的美国印第安那州西北部地区影像,研究区以植被为主,同时包含林地、道路、房屋建筑等,总共 16 种地物类型. Pavia University 数据是 ROSIS 传感器获取的意大利帕维亚大学城区影像,研究区以人工地物为主,包含柏油路、草地、砂砾路、树木、喷漆金属片(人工屋顶)、裸地、沥青、砖块和阴影共 9 种地表覆盖类型. 两幅影像的土地覆被具有很好的代表性.

#### 3.1 实验区概况

Indian Pines 影像大小为 145 像素×145 像素,空间分辨率为 20 m,波长范围为 0.4~2.5  $\mu\text{m}$ ,去除坏波段和水体吸收的波段后有 200 个波段可用. 图 1(a)所示为 Indian Pines 研究区图像. 图 1(b)是其对应的

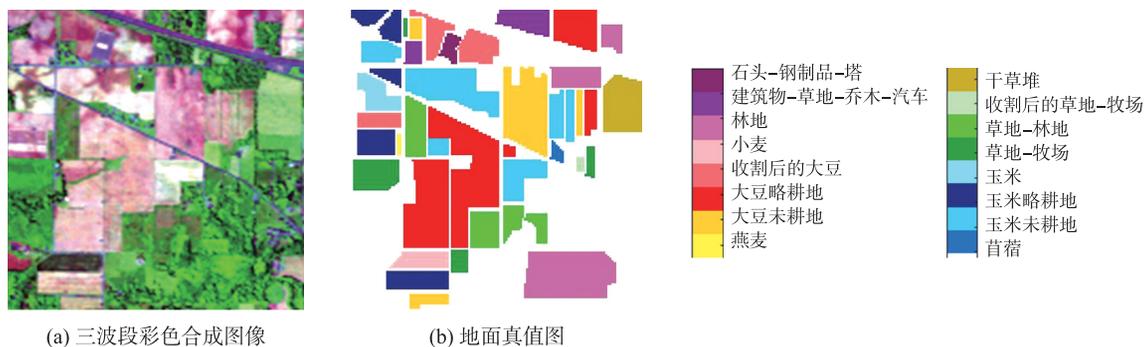


图 1 Indian Pines 数据与地面真值图  
Fig. 1 Indian Pines data and ground truth

地面真值图,共有 10 249 个样本. Pavia University 影像大小为 610 像素×340 像素,空间分辨率为 1.3 m,光谱范围为 0.43~0.86  $\mu\text{m}$ ,去除 12 个坏波段,共 103 个光谱波段可用,共 42 276 个样本. 图 2 所示为 Pavia University 研究区图像及其对应的地面真值图. 实验分别对两组数据按类别随机抽取 10% 和 1% 的训练样本,对其余样本进行测试.

### 3.2 高光谱影像特征低秩表达实验分析

针对原始高光谱数据,分别选取波段组合方法 BGU、波段相关性方法 BGCC、基于正交投影的 PCA 方法和基于聚类分析的 K-means 方法,与基于 RPCA 的光谱低秩表达方法进行对比分析. 为了评价提取的特征优劣和类别区分度,实验采用随机森林 (RF)<sup>[28]</sup> 分类器的分类结果作为特征提取算法的衡量标准,对不同方法提取到的特征类别可区分性进行验证. Indian Pines 数据和 Pavia University 数据的分类结果如图 3 和图 4 所示.

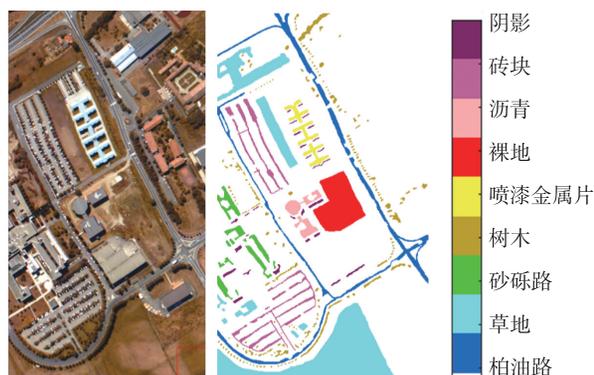


图 2 Pavia University 数据与地面真值图

Fig. 2 Pavia University data and ground truth

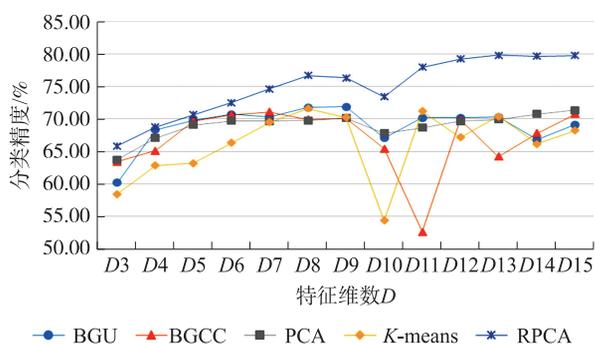


图 3 Indian Pines 数据不同特征提取方法  
分类精度与特征维数关系图

Fig. 3 The figure for the relationship between classification accuracy and the dimension of features based on different feature extraction methods for Indian Pines data

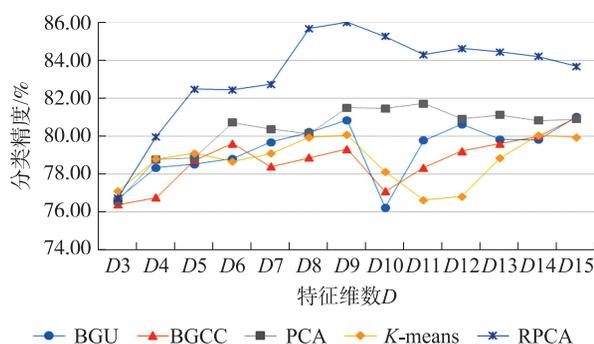


图 4 Pavia University 数据不同特征提取方法  
分类精度与特征维数关系图

Fig. 4 The figure for the relationship between classification accuracy and the dimension of features based on different feature extraction methods for Pavia University data

从图 3 可以看出,低秩表达 RPCA 的分类精度表现最好,且稳定性较好,随着特征维数的增加分类精度总体呈现上升趋势. PCA 在第 3~第 9 特征维数呈线性升高趋势,但在第 10~第 15 特征维数精度提高有限. BGU 和 BGCC 在第 3~第 9 特征维数分类精度呈线性升高趋势. 在第 10~第 15 特征维数, BGU 的分类精度呈现一定的波动;而 BGCC 和 K-means 极不稳定,分类结果波动较大. BGU 和 PCA 的总体分类精度持平, BGCC 和 K-means 较差. 由于 Indian Pines 影像中一些植被正处于生长初期,植被覆盖度较低,在分辨率有限的情况下,植被与裸地的区分度较小. 同时,处于初耕阶段的土地混有大量落叶、残茬等杂质,也对光谱区分产生不利影响. 因此,其他的光谱特征提取方法即便增加特征数也无法有效鉴别地物.

从图 4 可以看出,低秩表达 RPCA 的分类精度仍然最好,明显高于其他分类结果,总体呈现出分类精度随特征维数的增加而逐渐增长的趋势. PCA 表现依然平稳,随着特征维数的增加精度呈升高趋势,但精度远低于低秩表达分类. BGU 和 K-means 在第 3~第 9 特征维数分类精度呈线性升高趋势;在第 10~第 15 特征维数, BGU、BGCC 和 K-means 非常不稳定,分类结果波动较大;BGU、BGCC 和 K-means 的分类结果较差. 由于 Pavia University 数据空间分辨率更高,地物表现细节更丰富,总分类精度高于 Indian Pines. 但由于 Pavia University 以人工地物为主,光谱相似性较高,导致以波段计算策略为主的 BGU、BGCC 和 K-means 效果较差,人工地物的光谱特征可区分度并未随着特征数增加而变大.

实验结果表明,光谱低秩表达可以很好地利用高光谱数据低秩冗余特性,对于不同类型的高光谱数据,可在不同特征维度区间范围内获取类别区分度更高的低维表达.

### 3.3 融合低秩和形态学剖面的特征提取实验分析

在 RPCA 获取的低秩表示基础上,提取基于多尺度结构元素的形态学剖面特征. 本实验将低秩表达

结果的前  $q$  个低秩主分量作为基础影像提取形态学特征,分别用圆形、菱形、正方形 3 种形状、不同尺度的结构元素依次对基影像进行形态学操作,结构元半径  $r$  随着一定的步长依次递增进行  $n$  次形态学重建,得到特征维数为  $q \times (2n+1)$  的剖面信息,将不同结构元素提取的空间形态学剖面按不同形状和半径参数组合求取均值,并结合基影像共同构成空间形态学剖面 MSEMP. 为了测试本算法的分类结果,分 5 组实验对 Indian Pines 和 Pavia University 数据分类结果进行比对,分别为:对原始光谱数据进行分类;对原始光谱数据和灰度共生矩阵(GLCM)纹理信息相结合进行分类;对原始数据的前 15 个主成分光谱信息和 GLCM 纹理信息结合进行分类;对原始数据 200 个光谱波段和 MSEMP 相结合进行分类;对原始数据的前 15 个主成分光谱信息和 MSEMP 相结合进行分类(为了参数的一致性,本文对主成分分量统一取值为 15). 实验中 GLCM 参数取值为:灰度级量化范围为 0~15,滑动窗口大小为  $3 \times 3$ ,像元对距离  $d$  为 1,方向分别为  $0^\circ$ 、 $45^\circ$ 、 $90^\circ$ 、 $135^\circ$ ,12 个纹理统计指标分别为角二阶矩、对比度、相关性、纹理方差、逆差矩、熵、共生和均值、共生和方差、共生和熵、共生差均值、共生差方差、共生差熵. 表 1 和表 2 分别给出了两组数据不同特征组合方式下的随机森林<sup>[28]</sup>分类算法对应的分类精度.

表 1 Indian Pines 数据不同特征组合的分类结果

Table 1 Classification results based on different features combination of Indian Pines data

类别编号	原始 200 波段	GLCM+200 波段	GLCM+PCA15 波段	MSEMP(1,3)+200 波段	MSEMP(1,3)+PCA15 波段
1	29.27	39.02	21.95	46.34	90.24
2	66.07	64.75	69.95	72.05	80.98
3	55.14	55.14	49.80	78.91	88.12
4	17.37	27.70	22.54	35.21	66.67
5	85.29	84.83	80.23	87.82	92.41
6	97.26	98.02	97.57	97.87	99.39
7	12.00	28.00	36.00	52.00	68.00
8	98.61	97.45	99.54	99.07	99.77
9	5.56	11.11	0.00	5.56	22.22
10	66.48	73.09	66.7	77.42	84.26
11	85.43	84.66	79.98	88.66	92.53
12	45.23	47.29	41.12	51.21	77.94
13	92.39	94.02	91.85	95.11	98.91
14	96.14	97.20	95.88	98.16	98.60
15	38.22	43.97	45.40	76.72	86.49
16	90.36	92.77	96.39	98.80	95.18
OA	75.16	76.26	74.00	82.69	89.62

注:Indian Pines 数据类别编号 1~16 代表的地物覆盖类型分别为:苜蓿,玉米未耕地,玉米略耕地,玉米,草地-牧场,草地-林地,收割后的草地-牧场,干草堆,燕麦,大豆未耕地,大豆略耕地,收割后的大豆,小麦,林地,建筑物-草地-乔木-汽车,石头-钢制品-塔.

表 2 Pavia University 数据不同特征组合的分类结果

Table 2 Classification results based on different features combination of Pavia University

类别编号	原始 103 波段	GLCM+103 波段	GLCM+PCA15 波段	MSEMP(1,3)+103 波段	MSEMP(1,3)+PCA15 波段
1	85.41	89.13	94.05	94.58	96.40
2	94.55	95.06	95.89	98.82	99.52
3	43.88	43.49	35.82	63.11	74.93
4	86.69	86.53	79.36	93.06	94.45
5	96.99	97.07	99.55	97.74	99.02
6	42.01	47.30	49.84	92.82	97.73
7	77.02	70.47	26.48	94.37	98.78
8	80.59	83.70	85.21	89.72	95.79
9	100.00	100.00	98.40	100.00	99.57
OA	82.36	83.82	83.16	94.36	96.90

注:Pavia University 数据类别编号 1~9 代表的地物覆盖类型分别为:柏油路,草地,砂砾路,树木,喷漆金属片或人工屋顶,裸地,沥青,砖块,阴影.

每组实验使用相同的通过随机选取策略获得的训练样本,剩余样本全部作为测试样本. 对于 Indian Pines 数据,参数取值为  $q=3$ (前 3 个主分量涵盖了 90%以上的方差信息),假设取 3 次开闭运算( $n=3$ ),则 MSEMP 共有  $3 \times (2 \times 3 + 1) = 21$  个特征维度. 对于 Pavia University 数据,参数取值为  $q=2$ (前两个主分量

涵盖了98%以上的方差信息),进行3次开闭运算( $n=3$ ),MSEMP共有 $2 \times (2 \times 3 + 1) = 14$ 个特征维度.将多形态多尺度结构特征MSEMP和光谱波段前15个主成分相结合,在光谱数据基础上添加了空间信息,两组数据分别只需36个和29个特征即可取得非常好的分类效果.实验结果表明,本文提出的融合低秩和多形态多尺度结构特征提取方法MSEMP通过不同形态结构元的多尺度级联操作,能够刻画不同类型的空间模式,能有效提取高光谱遥感影像的空间信息,有助于提高分类精度.

为了说明提取MSEMP特征时结构元素参数对分类精度的影响,实验采用不同结构元素参数对两个数据集进行测试.结构元素半径取值范围为 $\{1, 2, 3, 4\}$ ,步长大小取值范围为 $\{1, 2, 3, 4\}$ ,共计16组不同参数组合.实验使用支持向量机SVM、梯度推进机GBM<sup>[29]</sup>和随机森林RF3个不同类型的分类器,所得分类结果如图5和6所示.可以看出,Indian Pines数据在参数组合为(1,4)、(2,4)、(3,4)和(4,4)时的分类精度出现峰值,分类精度最高.说明对于Indian Pines数据而言,结构元素步长取值为4时,提取的特征更好,半径和步长大小取值组合为(4,4)时的分类精度最高.对于Pavia University数据,在参数组合为(1,4)、(2,4)、(3,4)和(4,4)时,分类器呈现较高的分类精度.说明当结构元素步长取值为4时,提取的特征更好.对于SVM和RF分类器,半径和步长大小取值组合为(4,4)时的分类精度最高.对于GBM分类器,半径和步长大小取值组合为(3,4)时的分类精度最高.两组图像分类参数分析结果基本一致.

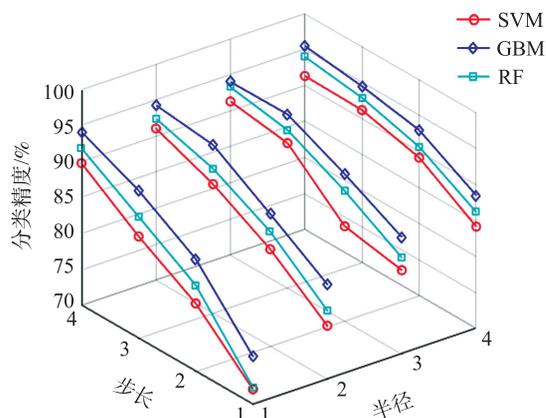


图5 Indian Pines数据多形态多尺度结构元素信息提取分类结果与结构元参数关系图

Fig. 5 The figure for the relationship between classification accuracy based on MSEMP and the coefficients of structure element for Indian Pines data

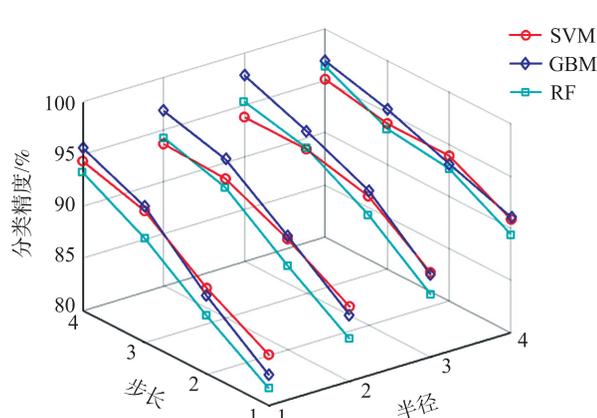


图6 Pavia University数据多形态多尺度结构元素信息提取分类结果与结构元参数关系图

Fig. 6 The figure for the relationship between classification accuracy based on MSEMP and the coefficients of structure element for Pavia University data

## 4 结论

本文提出了一种融合低秩和形态学的高光谱影像特征提取方法MSEMP,针对高光谱数据的高维特性和噪声问题,利用鲁棒主成分分析获取数据的低秩表示,在降低冗余的同时保留了原数据中的有用信息.在此基础上,构建基于多形态、多尺度结构元的形态学剖面,无需对每个像元邻域进行严格的界定,可根据像元所属结构进行自适应邻域定义,降低了时间和空间计算复杂度.与单一结构元提取的特征相比,能够提取到影像的不同空间模式,避免单一结构元形态学操作只能提取固定空间模式的情况,能够获取影像更丰富的空间结构特征,为基于高光谱影像的分析和应用提供了有效的特征提取思路.通过对两种不同类型传感器高光谱影像的实验分析,证明了本文算法的有效性.

### [参考文献] (References)

- [1] 石茜,杜博,张良培.一种基于局部判别正切空间排列的高光谱遥感影像降维方法[J].测绘学报,2012,41(3):417-420.
- [2] 孙伟伟.基于流形学习的高光谱影像降维理论与方法研究[J].测绘学报,2014,43(4):439.
- [3] SU J Y, YI D W, LIU C J, et al. Dimension reduction aided hyperspectral image classification with a small-sized training dataset: experimental comparisons[J]. Sensors, 2017, 17(12): 2726.
- [4] WRIGHT J, GANESH A, RAO S, et al. Robust principal component analysis: exact recovery of corrupted low-rank matrices via

- convex optimization[C]//Advances in Neural Information Processing Systems. Vancouver, Canada: NIPS200, 2009: 2080–2088.
- [5] LIN B, TAO G, KAI D. Using non-negative matrix factorization with projected gradient for hyperspectral images feature extraction[C]//2013 8th IEEE Conference on Industrial Electronics and Applications(ICIEA). Melbourne, Australia: IEEE, 2013: 516–519.
- [6] 施蓓琦, 刘春, 孙伟伟, 等. 应用稀疏非负矩阵分解聚类实现高光谱影像波段的优化选择[J]. 测绘学报, 2013, 42(3): 351–358, 366.
- [7] CAI J F, CANDÈS E J, SHEN Z. A singular value thresholding algorithm for matrix completion[J]. SIAM Journal on Optimization, 2010, 20(4): 1956–1982.
- [8] CANDÈS E, LI X, MA Y, et al. Robust principal component analysis? [J]. Journal of the ACM, 2011, 58(3): 1–37.
- [9] SINGHAL V, AGGARWAL H K, TARIYAL S, et al. Discriminative robust deep dictionary learning for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(9): 5274–5283.
- [10] TOSIC I, FROSSARD P. Dictionary learning[J]. IEEE Signal Processing Magazine, 2011, 28(2): 27–38.
- [11] SHEN H, HUANG J Z. Sparse principal component analysis via regularized low rank matrix approximation[J]. Journal of Multivariate Analysis, 2008, 99(6): 1015–1034.
- [12] SHEN Y, WEN Z, ZHANG Y. Augmented Lagrangian alternating direction method for matrix separation based on low-rank factorization[J]. Optimization Methods and Software, 2014, 29(2): 239–263.
- [13] CAI D, HE X, HAN J, et al. Graph regularized nonnegative matrix factorization for data representation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(8): 1548–1560.
- [14] KANG X, LI S, BENEDIKTSSON J. Spectral-spatial hyperspectral image classification with edge-preserving filtering[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(5): 2666–2677.
- [15] REN Y, ZHANG Y, WEI W, et al. A spectral-spatial hyperspectral data classification approach using random forest with label constraints[C]//2014 IEEE Workshop on Electronics, Computer and Applications. Ottawa, Canada: IEEE, 2014: 344–347.
- [16] SUN L, WU Z, LIU J, et al. Supervised spectral-spatial hyperspectral image classification with weighted Markov random fields[J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(3): 1490–1503.
- [17] LONG Z, DU Q, YOUNAN N. Hyperspectral feature extraction using contourlet transform[C]//2012 IAPR Workshop on Pattern Recognition in Remote Sensing(PRRS). Tsukuba Science City, Japan: IEEE, 2012: 1–4.
- [18] RASTI B, SVEINSSON J, ULFARSSON M. Total variation based hyperspectral feature extraction[C]//Geoscience & Remote Sensing Symposium. Quebec City, Canada: IEEE, 2014: 4644–4647.
- [19] 李亚标, 王宝光, 李温温. 基于小波变换的图像纹理特征提取方法及其应用[J]. 传感技术学报, 2009, 22(9): 1308–1311.
- [20] 赵莹, 高隽, 陈果, 等. 一种基于分形理论的多尺度多方向纹理特征提取方法[J]. 仪器仪表学报, 2008, 29(4): 787–791.
- [21] POGGI G, SCARPA G, ZERUBIA J B. Supervised segmentation of remote sensing images based on a tree-structured MRF model[J]. IEEE Transactions on Geoscience & Remote Sensing, 2005, 43(8): 1901–1911.
- [22] JACKSON Q, LANDGREBE D A. Adaptive bayesian contextual classification based on markov random field[J]. IEEE Transactions on Geoscience & Remote Sensing, 2002, 40(11): 2454–2463.
- [23] LI W, CHEN C, SU H, et al. Local binary patterns and extreme learning machine for hyperspectral imagery classification[J]. IEEE Transactions on Geoscience & Remote Sensing, 2015, 53(7): 3681–3693.
- [24] SU H, SHENG Y, DU P, et al. Hyperspectral image classification based on volumetric texture and dimensionality reduction[J]. Frontiers of Earth Science, 2015, 9(2): 225–236.
- [25] TSAI F, LAI J S. Feature extraction of hyperspectral image cubes using three-dimensional gray-level cooccurrence[J]. IEEE Transactions on Geoscience & Remote Sensing, 2013, 51(6): 3504–3513.
- [26] FAUVEL M, BENEDIKTSSON J, 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.
- [27] BENEDIKTSSON J, PALMASON J, SVEINSSON J. Classification of hyperspectral data from urban areas based on extended morphological profiles[J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43(3): 480–491.
- [28] BREIMAN L. Random forests[J]. Machine Learning, 2001, 45(1): 5–32.
- [29] FRIEDMAN J H. Greedy function approximation: a gradient boosting machine[J]. Annals of Statistics, 2001, 29(5): 1189–1232.

[责任编辑: 严海琳]