

doi: 10.3788/gzxb20164510.1030001

融合加权均值滤波与流形重构保持嵌入的高光谱影像分类

黄鸿, 郑新磊, 罗甫林

(重庆大学 光电技术与系统教育部重点实验室, 重庆 400044)

摘要: 高光谱影像中波段数过多易导致“维数灾难”, 而传统高光谱影像维数约简算法仅利用光谱特征而忽略了空间信息. 针对上述问题, 提出一种融合加权均值滤波与流形重构保持嵌入的维数约简算法. 该方法利用影像中地物分布的空间一致性特点, 对所有像素进行加权均值滤波, 消除同类光谱差异性较大的像素影响, 并在流形重构过程中增大空间近邻点的权重, 提取出更为有效的鉴别特征, 实现维数约简. 在 PaviaU 和 Urban 高光谱数据集上的实验结果表明: 相比于其它相关方法, 该方法能获得更高的分类准确度, 在分别随机选取 5% 和 1% 的训练样本情况下, 其总体分类准确度分别提高到 98.76% 和 80.21%. 该方法在发现内在低维流形结构的同时, 有效融入了影像中的空间信息, 改善了分类性能.

关键词: 高光谱影像分类; 加权均值滤波; 流形学习; 维数约简; 空间近邻

中图分类号: TP751.1

文献标识码: A

文章编号: 1004-4213(2016)10-1030001-9

Hyperspectral Image Classification with Combination of Weighted Mean Filter and Manifold Reconstruction Preserving Embedding

HUANG Hong, ZHENG Xin-lei, LUO Fu-lin

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

Abstract: Hyperspectral Image (HSI) contains a large number of spectral bands that easily results in the curse of dimensionality. The traditional classification methods just apply the spectral information while they ignore the spatial information. To address this problem, a dimensionality reduction algorithm combining Weighted Mean Filter (WMF) and Manifold Reconstruction Preserving Embedding (MRPE) was proposed in this paper. According to the spatial consistency property of HSI, firstly, the method applies WMF to all pixels which can reduce the spectral difference of data points from the same class. Then, the weights of the spatial neighbor points are enhanced in manifold reconstruction. This method effectively extracts the discriminant features and achieves the dimensionality reduction. Experimental results on PaviaU and Urban data sets show that the proposed method has better classification accuracy than other algorithms. When 5% and 1% of training samples were randomly selected from the two data sets, the overall accuracies based on MRPE can reach 98.76% and 80.21%. The proposed method enhances the low-dimensional manifold representation with the spatial information and improves the performance of HSI classification.

Key words: Hyperspectral image classification; Weighted mean filter; Manifold learning; Dimensionality reduction; Spatial neighbors

OCIS Codes: 300.6310; 280.0280; 110.4234; 100.4145; 100.5010; 100.2960

基金项目: 国家自然科学基金(No. 41371338)、重庆市基础与前沿研究计划(No. cstc2013jcyjA4005)和重庆市研究生科研创新项目(No. CYB15052)资助

第一作者: 黄鸿(1980—), 男, 副教授, 博士, 主要研究方向为高光谱遥感影像智能化处理. Email: hhuang@cqu.edu.cn

通讯作者: 郑新磊(1992—), 男, 硕士研究生, 主要研究方向为高光谱遥感影像分类. Email: zhengxl@cqu.edu.cn

收稿日期: 2016-04-20; 录用日期: 2016-07-21

<http://www.photon.ac.cn>

0 引言

作为遥感技术的前沿,高光谱影像中含有十分丰富的光谱特征信息,能鉴别出不同地物间的细微差别,为地物的精细识别与分类带来了新的机遇^[1-3].但高光谱影像数据量大、波段数多、冗余性强,若直接对其进行识别分类,容易导致“维数灾难”^[4].因此,如何实现有效的维数约简以及消除冗余信息,是目前高光谱影像分类研究的前沿与热点.

近年来,国内外学者已经提出了一系列高光谱数据的维数约简方法.主成分分析(Principal Component Analysis, PCA)^[5]和线性判别分析(Linear Discriminant Analysis, LDA)^[6]是两种常用的子空间学习方法,它们是在满足全局线性假设的条件下,通过不同的判别准则来获取最优线性模型,但无法揭示出高光谱数据的内在非线性结构.为此,学者们提出了流形学习方法,如局部线性嵌入(Local Linear Embedding, LLE)^[7]、等距离映射(Isometric Feature Mapping, ISOMAP)^[8]和拉普拉斯特征映射(Laplacian Eigenmaps, LE)^[9]等,较好的揭示了蕴含在高光谱数据中的低维流形结构,但存在“样本外学习”问题,不能直接处理新样本.针对此问题,He等提出了基于线性降维的邻域保持嵌入(Neighborhood Preserving Embedding, NPE)^[10]和局部保持投影(Locality Preserving Projection, LPP)^[11]算法,有效地解决了新样本的学习问题,但仅利用了影像中的光谱信息,并未考虑空间信息对分类的贡献.

在高光谱影像中,所有像素共同组成一幅图像,这些像素不仅是一些相互独立的无序向量,它们在空间位置上具有一定关联,空间上距离很近的像素之间具有较强的光谱相关性,且距离越近,相关性越强^[12].若一像素属于某一特定类别,那么在空间位置上与其隶属近邻关系的像素属于该类别的概率就越高.此外,从地物分布来看,相同类别的地物在影像中也往往呈现集中性或呈块状分布^[13].基于此,在高光谱影像分类过程中,可以采用空间信息与光谱信息相结合的分类方法.Tan^[14]等通过引入空间近邻的标记信息参与投票表决,提出了一种基于空间近邻信息与分类器集成的半监督分类算法,但算法需要进行多次迭代来选取样本,且受参量影响较大.魏峰^[15]提出了一种基于空间一致性的邻域保留嵌入(Spatial Coherence-Neighborhood Preserving Embedding, SC-NPE)降维算法,该算法首先在每一像素周围选取环块,通过对比环块间的差异来选取近邻,有效克服了同一类别中像素值差异较大的孤点或噪点的影响,在高光谱影像分类中具有较好的识别效果.

结合高光谱影像的空间一致性特点,本文提出了

一种加权均值滤波(Weighted Mean Filter, WMF)与流形重构保持嵌入(Manifold Reconstruction Preserving Embedding, MRPE)相结合的维数约简算法.该算法首先对高光谱影像进行空间滤波,消除影像中噪点的影响,增强同类地物间光谱特征的稳定性;同时,在流形重构过程中嵌入空间近邻点的光谱信息,提取出更为有效的鉴别特征,实现数据降维.在PaviaU和Urban高光谱数据集上进行验证,结果表明本文方法能有效改善高光谱影像的地物分类效果.

1 本文算法

1.1 加权均值滤波

在高光谱影像成像过程中,由于噪声等因素的影响,同种地物的光谱曲线往往呈现出差异,且当维数较高时,这种差异将严重影响地物间的相似性度量,进而给少数训练样本情况下的地物分类带来困难.为削弱同类地物间的光谱差异,本文采用滤波的方式对高光谱影像进行预处理.加权均值滤波(WMF)是一种常用的图像处理方法,通过运用模板对图像进行卷积运算,消除噪声,使得处理后的图像更加平滑;同时,该滤波方式还具有处理速度快、计算简单等优点.因此,本文使用加权均值滤波器对高光谱影像进行空间滤波,在消除影像中噪点的同时提高地物光谱特征分析的准确度和可靠性.

加权均值滤波的基本原理为

构建以像素 $x_i(p, q)$ 为中心的窗口大小为 $w \times w$ 的方形区域 $\Omega(x_i)$,其中 p 和 q 分别为 x_i 在影像中的行和列, $\Omega(x_i)$ 定义为近邻空间,即

$$\Omega(x_i) = \{x_{is}(p_s, q_s)\} \quad (1)$$

$$p_s \in [p-r, p+r], \quad q_s \in [q-r, q+r]$$

式中, $r = (w-1)/2$, w 为正奇数, $x_{is}(p_s, q_s)$ 为近邻空间 $\Omega(x_i)$ 中的第 s 个像素, $1 \leq s \leq w^2$.此外,由于影像边缘位置上像素的近邻空间并不完整,本文在处理过程中,使用该像素自身对缺失部分进行填补.

对像素 x_i 进行加权均值滤波,得到像素 \bar{x}_i 为

$$\bar{x}_i = \frac{\sum_{s=1}^{w^2} v_s x_{is}}{\sum_{s=1}^{w^2} v_s}, \quad x_{is} \in \Omega(x_i) \quad (2)$$

式中, v_s 为像素 x_{is} 到中心像素 x_i 的权重,即

$$v_s = \exp\{-t \|x_i - x_{is}\|^2\}, \quad t \geq 0 \quad (3)$$

从式(2)可以看出,加权均值滤波在对像素进行处理过程中,不仅考虑了其空间位置上的近邻信息,同时也考虑了不同像素间的光谱差异性.通过窗口 w 和权重参量 t 来调节滤波程度,消除差异性较大的噪点的影响,增强同类像素间的光谱相似度.

1.2 流形重构保持嵌入

假设含有 N 个数据点的高维空间数据集为 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$, 其中 $\mathbf{x}_i (i=1, 2, \dots, N) \in R^D$, D 为高维空间的维数, 低维嵌入后得到数据 $\mathbf{Y} = \{\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N\}$, $\mathbf{y}_i \in R^d$, 且 $d \ll D$.

在高光谱影像中, 由于地物的空间自相关性, 相邻位置上的像素往往具有光谱相关性, 它们在较大程度上是由同类地物所构成, 即地物分布的空间一致性特点. 基于此, 提出了一种融合空间近邻信息的流形重构保持嵌入(MRPE)算法. 该算法的主要思想为: 在高维空间中将每个像素由它的 k 个光谱近邻点及空间近邻点进行重构, 并适当增大空间近邻点的权重以增强同类地物间的聚集性, 最后, 在低维嵌入过程中保持这种光谱和空间近邻关系不变, 实现维数约简.

MRPE 算法的主要步骤为:

1) 构建像素 \mathbf{x}_i 的光谱近邻 $k(\mathbf{x}_i)$

在高维空间中计算每个像素 \mathbf{x}_i 与其它所有像素在光谱维上的欧式距离, 选出距离最近的 k 个点, 得到光谱近邻 $k(\mathbf{x}_i)$.

2) 设置重构权值矩阵 \mathbf{W}

在高维空间中, 将像素 \mathbf{x}_i 由它的光谱近邻 $k(\mathbf{x}_i)$ 进行重构, 通过最小化重构误差的方式来获取局部重构权值矩阵 $\mathbf{W} = [\tau_{ij}]_{N \times k}$, 其目标函数为

$$\min J(\mathbf{w}_i) = \min \sum_{i=1}^N \left\| \mathbf{x}_i - \sum_{\mathbf{x}_j \in k(\mathbf{x}_i)} \tau_{ij} \mathbf{x}_j \right\|^2$$

$$\text{s. t. } \tau_{ij} = 0 \quad \forall \mathbf{x}_j \notin k(\mathbf{x}_i) \quad (4)$$

式中, τ_{ij} 为 \mathbf{x}_i 与 \mathbf{x}_j 之间的权值, 且 $\sum_{\mathbf{x}_j \in k(\mathbf{x}_i)} \tau_{ij} = 1$.

为进一步增强同类地物间的聚集性, 在重构过程中融入空间近邻点的光谱信息以提高算法的分类鉴别能力. 当像素 \mathbf{x}_j 为 \mathbf{x}_i 的光谱近邻且位于 \mathbf{x}_i 的近邻空间内时, 适当增大该两者之间的权值, 即

$$s_{ij} = \begin{cases} \beta \times \tau_{ij}, & \mathbf{x}_j \in k(\mathbf{x}_i) \text{ 且 } \mathbf{x}_j \in \Omega(\mathbf{x}_i) \\ \tau_{ij}, & \mathbf{x}_j \in k(\mathbf{x}_i) \text{ 且 } \mathbf{x}_j \notin \Omega(\mathbf{x}_i) \end{cases} \quad (5)$$

式中, 加权参量 $\beta > 1$, 用于调整空间近邻点在分类过程中的贡献. 图 1 为窗口大小为 3×3 时权值变化的示意




图 1 重构权值变化示意图

Fig. 1 Schematic diagram of reconstruction weight change

图, 其中, 每一个圆圈均代表一个像素, 深色圆圈为像素 \mathbf{x}_i 的光谱近邻 $k(\mathbf{x}_i)$, 方框为其近邻空间 $\Omega(\mathbf{x}_i)$. 对于 $\Omega(\mathbf{x}_i)$ 中的两个像素, 由于其满足条件 $\mathbf{x}_j \in k(\mathbf{x}_i)$ 且 $\mathbf{x}_j \in \Omega(\mathbf{x}_i)$, 故在重构过程中增大其权值.

3) 计算低维嵌入空间 \mathbf{Y}

将高光谱影像数据集从高维空间投影到低维空间, 并保持数据间的近邻关系及重构权值矩阵 $\mathbf{S} = [s_{ij}]_{N \times k}$ 不变, 构建目标函数

$$\min \sum_{i=1}^N \left\| \mathbf{y}_i - \sum_{\mathbf{y}_j \in k(\mathbf{y}_i)} s_{ij} \mathbf{y}_j \right\|^2 = \text{tr}(\mathbf{Y}(\mathbf{I} - \mathbf{S})(\mathbf{I} - \mathbf{S})^T \mathbf{Y}^T) = \text{tr}(\mathbf{A}^T \mathbf{X} \mathbf{M} \mathbf{X}^T \mathbf{A}) \quad \text{s. t. } \mathbf{A}^T \mathbf{X} \mathbf{X}^T \mathbf{A} = \mathbf{I} \quad (6)$$

式中, $\mathbf{M} = (\mathbf{I} - \mathbf{S})(\mathbf{I} - \mathbf{S})^T$.

根据约束条件, 利用 Lagrange 乘子法, 将式(6)中的最优化问题转化为特征方程的求解问题

$$\mathbf{X} \mathbf{M} \mathbf{X}^T \mathbf{A} = \lambda \mathbf{X} \mathbf{X}^T \mathbf{A} \quad (7)$$

求解式(7)得到广义特征值及其特征向量, 从中选出最小的 d 个特征值所对应的特征向量 $\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_d$, 构建投影矩阵 $\mathbf{A} = [\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_d]$, 得到低维嵌入结果 $\mathbf{Y} = \mathbf{A}^T \mathbf{X}$.

本文提出的 MRPE 算法的详细步骤为:

输入: 含有 N 个像素的高光谱影像数据集 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$, $\mathbf{x}_i \in R^D$, 嵌入特征维数 d , 窗口 ω , 权重参量 t , 加权参量 β .

输出: 投影矩阵 \mathbf{A} , 低维嵌入结果 \mathbf{Y} .

Step1: 利用式(2)对影像进行加权均值滤波;

Step2: 从滤波后的影像中选取训练样本及测试样本;

Step3: 计算不同像素在光谱维上的欧式距离, 得到光谱近邻 $k(\mathbf{x}_i)$;

Step4: 设置重构权值矩阵 \mathbf{W} , 并根据式(5)增大空间近邻点的权值;

Step5: 保持像素间的重构权值不变, 利用式(7)计算投影矩阵 \mathbf{A} 及低维嵌入结果 \mathbf{Y} .

2 实验结果及分析

2.1 实验数据集

为验证本文算法的分类性能, 实验中选取了 PaviaU 和 Urban 两组高光谱遥感数据集进行实验.

1) PaviaU 数据集^[16]是由 ROSIS 传感器采集的位于帕维亚大学区域的高光谱影像. 已知该影像大小为 610×340 pixels, 空间分辨率为 1.3 m/pixel , 光谱波段数为 115, 去除受噪声影响严重的波段, 共选取 103 个波段进行实验研究. PaviaU 数据集中含有 9 类不同的地物, 共 42776 个已标注真实类别的像素, 不同类别的地物具有不同的光谱特征, 图 2 为其假彩色图像、真实地物图以及不同地物的光谱曲线图.

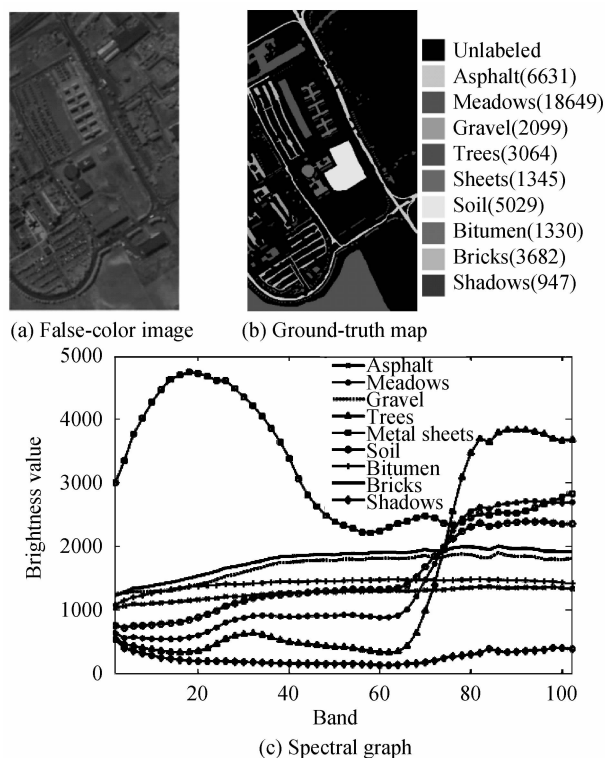


图2 PaviaU 高光谱影像

Fig. 2 PaviaU hyperspectral image

2) Urban 数据集^[17]是由 HYDICE 传感器采集的位于美国德克萨斯州某城郊住宿区的高光谱影像,其大小为 307×307 pixels,共包含 5 类不同的地物,去除影像中吸水严重以及受噪声影响较大的 48 个波段,将剩余的 162 个波段用于实验研究.图 3 为其假彩色图像、真实地物图及不同地物的光谱曲线图.

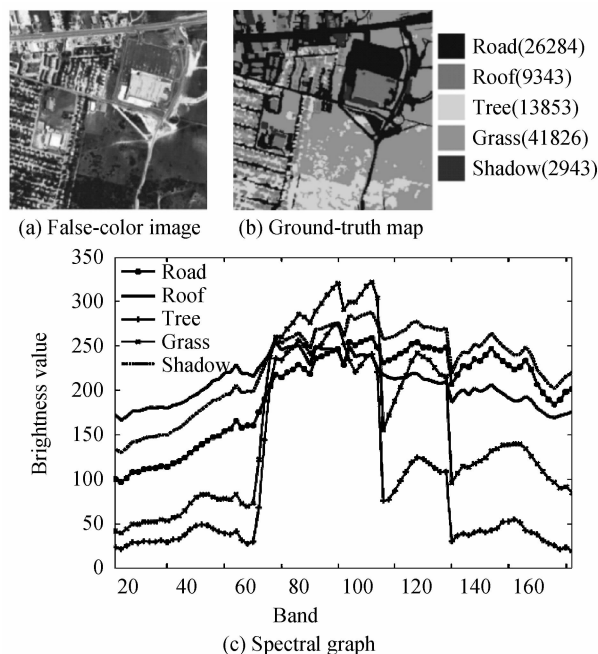


图3 Urban 高光谱影像

Fig. 3 Urban hyperspectral image

2.2 实验设置

在实验中,每次实验都采用随机方式从高光谱数据集中选取训练样本及测试样本,并将总体分类准确度、平均分类准确度和 kappa 系数作为实验结果的评价指标.为提高实验的精确性及可信度,每种条件下都重复进行 10 次实验,并对 10 次实验结果求平均得到最终结果.

为评估本文提出的 MRPE 算法的有效性,实验中选取了 PCA、LDA、LPP、NPE 和 SC-NPE 算法作为对比.首先利用各维数约简算法对随机选取的同一训练样本进行学习,得到各自相对应的投影矩阵,提取鉴别特征,最后使用最近邻分类器(1-Nearest Neighbor, 1-NN)进行分类.为保证各算法都具有较好的分类效果,调整各算法参量为最优,通过实验设置 LPP、NPE、SC-NPE 和 MRPE 的近邻数为 $k=5$,这是由于此时已获得的足够的像素进行流形重构,同时也可以减少异类点的引入,各算法统一提取 30 维特征,LDA 提取 $c-1$ 维, c 为高光谱数据集中的类别数.

为分析不同类别地物在降维前后的光谱特征变化,对 PaviaU 数据集的所有地物同时进行降维处理,得到各类地物的低维特征.因数据集中地物类别较多,为更好地说明降维对地物光谱的特征提取效果,在图 4 中给出了“Gravel”和“Bricks”两类具有相似光谱特征的地物在降维前后的特征曲线图.

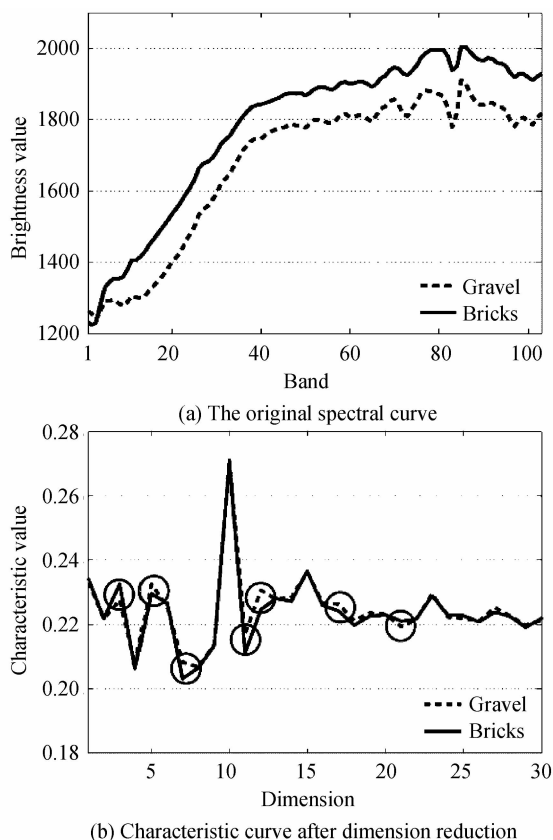


图4 PaviaU 影像中部分地物的特征曲线

Fig. 4 Characteristic curve of land cover in PaviaU image

从图4可以看出,这两类地物的原始光谱曲线较为接近,若直接进行分类,易产生较多的错分点.利用MRPE算法对其进行降维处理,可以提取出易于区分两类地物的鉴别特征(见图中圆圈标记),增强可分性.但当维数增大到一定程度时,特征曲线的差异性逐渐减小,这是由MRPE算法本身的特性导致,按特征值从小到大选取特征向量来构建投影矩阵,特征值越大,特征向量表征不同地物差异性的能力越弱,进而特征曲线越接近.当提取30维鉴别特征时,既保留了足够的特征来表征不同地物间的差异,同时,也不会因维数过多而导致数据量的增加.

2.3 参量对MRPE的影响

为研究窗口 w 和权重参量 t 对滤波的影响以及加权参量 β 对MRPE算法的影响,分别从PaviaU和Urban数据集的所有地物中随机选取5%和1%的样本用于训练,剩余样本用于测试.图5为PaviaU数据集中MRPE在不同窗口 w 和权重参量 t 下的总体分类准确度,图6为算法总体分类准确度与加权参量 β 的关系.

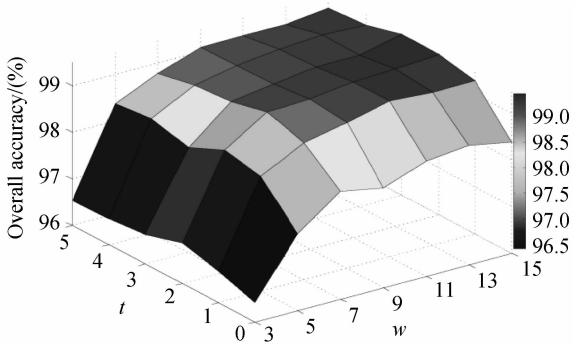


图5 MRPE在不同 w 和 t 下的总体分类准确度

Fig.5 Overall accuracy of MRPE with different w and t

由图5可知,对于PaviaU数据集,随着窗口 w 的

增大,算法分类准确度也随之提高,但当窗口大于 7×7 时,增幅逐渐减小.这是因为窗口越大,MRPE可以利用的空间信息越丰富,差异性较大的像素的平滑效果越好,能更好地区分不同地物间的差异,但当采集到的空间信息足够多时,分类准确度逐渐趋于平衡.在保证较好实验结果的情况下,综合考虑算法的运行效率,选取 $w=7$.同时,随着 t 值的变化,分类准确度出现波动,当 t 取值为2时分类效果较好.对于Urban数据集,本文采用相同的实验处理方式,选取 $w=5, t=2$.




图6 总体分类准确度与参量 β 之间的关系

Fig.6 Overall accuracy with respect to parameter β

由图6可知,随着加权参量 β 的增大,算法的总体分类准确度先增大后减小.这是由于 β 的增大突出了影像中空间近邻点的作用,增强了来自同类地物的数据间的聚集性,但当 β 取值过大时,空间近邻信息过于突出,反而忽略了其它光谱近邻的贡献,算法分类准确度降低.根据实验结果,本文将 β 的值设置为2.

2.4 PaviaU实验结果及分析

根据实验设置,分别从PaviaU数据集的每类地物中随机选取100、150、200和300个样本构成训练样本集,剩余样本用于测试,表1为不同维数约简算法在不

表1 不同算法在PaviaU数据集上的分类结果(总体分类准确度±标准差(%)(kappa系数))

Table 1 The classification results with different methods on PaviaU data set (overall accuracy ± std (%) (kappa))

Filter	Algorithms	100	150	200	300
No WMF	Original	76.07±1.24(0.6936)	77.88±0.75(0.7143)	79.84±0.86(0.7372)	80.75±0.42(0.7471)
	PCA	76.05±1.25(0.6934)	77.83±0.75(0.7137)	79.79±0.83(0.7366)	80.71±0.41(0.7467)
	LDA	79.53±1.14(0.7354)	81.28±1.20(0.7563)	82.39±1.00(0.7720)	83.78±0.30(0.7883)
	LPP	77.60±1.54(0.7153)	80.08±1.28(0.7415)	81.17±1.58(0.7573)	83.50±0.85(0.7825)
	NPE	76.17±1.60(0.6956)	78.37±1.59(0.7208)	79.67±1.61(0.7357)	81.45±0.75(0.7565)
	SC-NPE	76.69±1.42(0.7009)	80.12±0.85(0.7422)	82.56±1.34(0.7715)	84.19±1.11(0.7910)
	MRPE	79.81±1.45(0.7385)	81.80±1.23(0.7632)	83.50±0.55(0.7833)	84.95±1.11(0.8004)
WMF	Original	87.39±0.70(0.8357)	89.50±0.94(0.8624)	91.73±0.28(0.8899)	92.76±0.27(0.9032)
	PCA	87.38±0.71(0.8356)	89.48±0.94(0.8621)	91.72±0.28(0.8898)	92.75±0.27(0.9030)
	LDA	94.32±0.59(0.9280)	96.25±0.60(0.9501)	96.72±0.32(0.9560)	97.56±0.32(0.9669)
	LPP	93.45±1.28(0.9138)	94.80±1.13(0.9312)	95.06±0.62(0.9340)	97.06±0.78(0.9604)
	NPE	86.08±1.65(0.8197)	88.32±1.07(0.8477)	89.69±1.50(0.8638)	92.19±1.00(0.8959)
	SC-NPE	86.75±0.88(0.8278)	87.85±1.15(0.8419)	88.67±0.93(0.8511)	90.15±0.73(0.8691)
	MRPE	95.61±1.04(0.9358)	97.33±0.67(0.9643)	98.33±0.24(0.9775)	98.71±0.11(0.9826)

同训练样本数下的总体分类准确度和 kappa 系数. 此外, 为验证 WMF 对分类准确度的影响, 文中增加了是否采用滤波处理的对比实验.

由表 1 可知, 各算法的分类准确度随着训练样本数的增加而不断提高, 由于训练样本数越多, 其包含的类别信息就越丰富, 提取的鉴别特征能更好地表征不同地物间的差异, 改善分类效果. 在不同训练样本数下, 各算法采用 WMF 处理后的分类准确度均有明显提升, 这是由于加权均值滤波较好地消除了影像中噪点的影响, 提高了同类地物间光谱的相似程度. 此外, 本文提出的 MRPE 算法的分类效果最好, 且当训练样本较少时, 仍能保持较高的分类准确度. 这是因为 MRPE 充分利用了影像中的空间-光谱信息, 在降维过程中融入空间近邻信息以提高同类地物的聚集性, 获取更好的鉴别特征.

为研究各算法对每类地物的分类性能, 实验中随机选取了 5% 的样本作为训练样本, 剩余为测试样本, 并在降维之前对高光谱影像进行滤波处理. 图 7 为其相对应的分类结果图.

表 2 为每类地物的分类准确度、总体分类准确度、平均分类准确度以及 kappa 系数. 由表 2 可知, MRPE 算法在大多数地物类别中具有较高的分类准确度, 其中, “Asphalt”、“Trees”和“Soil”这几类地物的分类准确度相比于其它算法都有较大幅度的提升, 这是由于空间近邻信息的融入更好地表征了数据的内在属性, 提取的鉴别特征更加有利于区分不同类别地物间的差异. 同时, MRPE 算法的各项评价指标均为最优, 且由图 7 可以看出, 其分类结果图中错分点更少, 大部分区域的地物分布更加平滑.




图 7 各算法在 PaviaU 数据集上的分类结果

Fig. 7 Classification results on PaviaU data set for different methods

表 2 PaviaU 数据集中每类地物在不同算法下的分类准确度(%)

Table 2 Classification accuracy of different class data with different methods on PaviaU data set (%)

Classes	Train	Test	Original	PCA	LDA	LPP	NPE	SC-NPE	MRPE
Asphalt	332	6299	94.52	94.54	95.94	96.65	94.36	95.21	98.08
Meadows	932	17717	98.56	98.56	99.75	99.32	98.36	98.60	99.96
Gravel	105	1994	88.42	88.37	91.32	94.73	89.62	91.17	94.28
Trees	153	2911	87.26	87.26	96.87	91.31	88.25	88.49	98.01
Metal sheets	67	1278	99.61	99.61	99.84	99.77	99.53	99.53	99.92
Soil	251	4778	86.06	86.04	96.69	92.32	85.83	91.38	99.20
Bitumen	67	1263	88.04	87.81	98.26	96.83	89.31	90.18	98.18
Bricks	184	3498	92.82	92.85	93.60	96.57	92.88	95.74	95.97
Shadows	47	900	100	100	100	99.89	100	100	99.89
Overall accuracy			94.40	94.39	97.61	97.00	94.43	95.69	98.76
Average accuracy			92.81	92.78	96.92	96.38	93.13	94.48	98.17
Kappa coefficient			0.925 2	0.925 1	0.968 3	0.960 0	0.925 7	0.942 6	0.983 6

2.5 Urban 实验结果及分析

实验中,从 Urban 数据集的每类地物中随机选取 100、150、200 和 300 个样本构成训练样本集,其余为测试样本,表 3 为不同算法在不同训练样本数、不同影像处理方式下的总体分类准确度和 kappa 系数。

由表 3 可知,随着每类地物训练样本数的增加,各算法的总体分类准确度和 kappa 系数均不断提高;且

滤波过后的分类效果要比未采用滤波处理的分类效果好,这是由于加权均值滤波削弱了影像中噪点的干扰,增强了光谱特征的稳定性.在各种实验条件下,MRPE 算法的分类效果最好,由于 MRPE 在降维过程中既具有流形学习的优点,又结合了影像中的空间近邻信息,有效改善了地物分类效果。

表 3 不同算法在 Urban 数据集上的分类结果(总体分类准确度±标准差(%)(kappa 系数))

Table 3 The classification results with different methods on Urban data set (overall accuracy ± std (%) (kappa))

Filter	Algorithms	100	150	200	300
NO WMF	Original	67.57±1.04(0.5610)	68.49±1.62(0.5720)	68.98±0.74(0.5777)	70.35±0.36(0.5949)
	PCA	67.49±1.06(0.5601)	68.46±1.66(0.5716)	68.92±0.77(0.5770)	70.27±0.36(0.5939)
	LDA	65.79±0.81(0.5390)	67.13±1.16(0.5562)	68.10±1.30(0.5669)	68.13±0.70(0.5673)
	LPP	65.89±0.71(0.5395)	67.38±1.37(0.5587)	68.70±0.91(0.5751)	70.22±0.42(0.5937)
	NPE	66.17±0.46(0.5436)	66.83±1.72(0.5516)	67.69±1.06(0.5616)	69.12±0.63(0.5795)
	SC-NPE	66.33±1.20(0.5442)	67.83±1.90(0.5630)	68.37±1.33(0.5690)	70.12±0.71(0.5911)
	MRPE	68.08±0.51(0.5665)	69.25±0.74(0.5796)	70.68±0.56(0.6003)	72.46±0.39(0.6220)
WMF	Original	68.89±0.65(0.5789)	70.46±0.74(0.5971)	72.40±0.93(0.6221)	73.12±0.18(0.6311)
	PCA	68.89±0.64(0.5789)	70.43±0.74(0.5968)	72.36±0.94(0.6216)	73.05±0.17(0.6303)
	LDA	71.56±1.03(0.6111)	71.86±0.81(0.6161)	72.96±0.92(0.6300)	72.98±0.41(0.6301)
	LPP	68.53±0.51(0.5752)	70.47±0.14(0.5985)	73.96±0.56(0.6424)	75.17±0.81(0.6579)
	NPE	68.11±0.12(0.5689)	69.61±0.69(0.5865)	71.49±0.38(0.6102)	71.92±0.89(0.6160)
	SC-NPE	67.13±1.05(0.5571)	69.47±0.85(0.5808)	72.59±0.47(0.6240)	73.00±0.73(0.6283)
	MRPE	71.92±1.26(0.6151)	72.85±1.15(0.6289)	75.14±0.22(0.6580)	76.62±0.35(0.6771)

为揭示 MRPE 算法对每类地物的分类性能,从 Urban 数据集中随机选取 1% 的样本为训练样本,剩余

为测试样本.表 4 为不同地物的分类准确度及其评价指标,图 8 为相对应的分类结果图。

表 4 Urban 数据集中每类地物在不同算法下的分类准确度(%)

Table 4 Classification accuracy of different class data with different methods on Urban data set (%)

Classes	Train	Test	Original	PCA	LDA	LPP	NPE	SC-NPE	MRPE
Road	263	26 021	79.42	79.41	77.25	77.97	77.80	75.47	79.09
Roof	93	9 250	63.35	63.28	75.22	64.42	62.16	60.36	74.67
Tree	139	13 714	71.07	70.92	71.02	72.44	71.86	68.72	74.71
Grass	418	41 408	84.74	84.72	84.64	86.96	84.01	84.73	86.38
Shadow	29	2 914	34.04	34.04	34.69	40.46	29.99	22.20	46.05
Overall accuracy			77.55	77.50	78.09	78.63	76.64	75.43	80.21
Average accuracy			66.53	66.47	68.57	68.45	65.16	62.30	72.18
Kappa coefficient			0.672 5	0.671 8	0.681 3	0.687 2	0.659 7	0.640 5	0.712 2




图 8 各算法在 Urban 数据集上的分类结果

Fig. 8 Classification results on Urban data set for different methods

由表 4 可知, MRPE 算法对大多数类别都能保持较高的识别率, 且其各项评价指标均优于其它算法. 另外, 由图 8 可以看出, MRPE 算法的分类结果图中错分点更少, 在“Shadow”区域表现尤为突出.

需要说明的是, 相对于 PaviaU 数据集而言, 其分类性能并不十分突出, 这是由于 Urban 数据集中地物分布较为分散, 相比于 PaviaU 数据集的集中性分布, 其空间特征的可利用性不高, 同时, 更少的地物类别及较小的光谱差异性, 也为地物分类带来了困难. 但在各数据集上, MRPE 算法的分类性能均为最优, 从而在一定程度上反映出本文算法的有效性.

3 结论

结合高光谱影像的空间一致性特点及流形学习思想, 本文提出了一种加权均值滤波(WMF)与流形重构保持嵌入(MRPE)相结合的降维算法. 该方法充分利用影像中的空间位置信息, 通过加权均值滤波来消除噪点的影响, 增强光谱稳定性, 使得同类地物间的光谱曲线更为接近. 同时, 在流形重构过程中增大空间近邻点的权重, 突出空间信息的作用, 使得同类地物在投影后更加聚集. 在 PaviaU 和 Urban 高光谱数据集上的实验结果表明, 本文算法在应用于高光谱影像分类时, 与其它算法相比具有更高的分类准确度.

由于 MRPE 算法是基于像素点均匀分布于单一流形的假设, 在实际应用中不同类别的地物可能位于多个不同的流形上, 同时, 采用加权均值滤波的处理方式也会在一定程度上造成光谱特征的损失, 即不利于具有相似光谱的不同地物的区分, 如何针对不同类别

地物提取不同的鉴别特征, 以及最大程度的保留其精细特征, 这将是下一步工作的研究重点.

参考文献

- [1] WANG Zeng-mao, DU Bo, ZHANG Liang-pei, *et al.* Based on texture feature and extend morphological profile fusion for hyperspectral image classification[J]. *Acta Photonica Sinica*, 2014, **43**(8): 0810002.
王曾茂, 杜博, 张良培, 等. 基于纹理特征和形态学特征融合的高光谱影像分类法[J]. *光子学报*, 2014, **43**(8): 0810002.
- [2] CHEN J W, JIAO L C. Hyperspectral imagery classification using local collaborative representation [J]. *International Journal of Remote Sensing*, 2015, **36**(3): 734-738.
- [3] LIU Yan-de, DENG Qing. Measurement of chlorophyll distribution in navel orange leaves based on hyper-spectral imaging technique [J]. *Chinese Journal of Luminescence*, 2015, **36**(8): 957-961.
刘燕德, 邓青. 基于高光谱成像技术的脐橙叶片的叶绿素含量及其分布测量[J]. *发光学报*, 2015, **36**(8): 957-961.
- [4] HUANG H, LUO F L, LIU J M, *et al.* Dimensionality reduction of hyperspectral images based on sparse discriminant manifold embedding[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2015, **106**: 42-54.
- [5] PRASAD S, BRUCE L M. Limitations of principal components analysis for hyperspectral target recognition[J]. *IEEE Geoscience and Remote Sensing Letters*, 2008, **5**(4): 625-629.
- [6] BANDOS T V, BRUZZONE L, CAMPS-VALLS G. Classification of hyperspectral images with regularized linear discriminant analysis[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, **47**(3): 862-873.
- [7] ROWEIS S T, SAUL L K. Nonlinear dimensionality reduction by locally linear embedding [J]. *Science*, 2000, **290**(5500): 2323-2326.
- [8] TENENBAUM J B, SILVA V, LANGFORD J C. A global geometric framework for nonlinear dimensionality reduction [J]. *Science*, 2000, **290**(5500): 2319-2323.

- [9] BELKIN M, NIYOGI P. Laplacian eigenmaps for dimensionality reduction and data representation[J]. *Neural Computation*, 2003, **15**(6): 1373-1396.
- [10] HE X F, CAI D, YAN S C, *et al.* Neighborhood preserving embedding[C]. Proceedings of the 10th IEEE International Conference on Computer Vision. Beijing, China, 2005: 1208-1213.
- [11] HE X F, NIYOGI P. Locality preserving projections[C]. Proceedings of the Advances in Neural Information Processing Systems. Vancouver, Canada, 2004: 153-160.
- [12] PU H Y, CHEN Z, WANG B, *et al.* A novel spatial-spectral similarity measure for dimensionality reduction and classification of hyperspectral imagery [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, **52** (11): 7008-7022.
- [13] FAUVEL M, TARABALKA Y, BENEDIKTSSON J A, *et al.* Advances in spectral-spatial classification of hyperspectral images[J]. *Proceedings of the IEEE*, 2013, **101**(3): 652-675.
- [14] TAN K, HU J, LI J, *et al.* A novel semi-supervised hyperspectral image classification approach based on spatial neighborhood information and classifier combination [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2015, **105**: 19-29.
- [15] WEI Feng, HE Ming-yi, MEI Shao-hui. Hyperspectral data feature extraction using spatial coherence based neighborhood preserving embedding[J]. *Infrared and Laser Engineering*, 2012, **41**(5): 1249-1254.
魏峰, 何明一, 梅少辉. 空间一致性邻域保留嵌入的高光谱数据特征提取[J]. *红外与激光工程*, 2012, **41**(5): 1249-1254.
- [16] KANG X D, LI S T, BENEDIKTSSON J A. Feature extraction of hyperspectral images with image fusion and recursive filtering[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, **52**(6): 3742-3752.
- [17] LUO Fu-lin, HUANG Hong, LIU Jia-min, *et al.* Hyperspectral image land cover classification based on discriminant sparse preserving embedding [J]. *Chinese Journal of Scientific Instrument*, 2016, **37**(1): 177-183.
罗甫林, 黄鸿, 刘嘉敏, 等. 基于鉴别稀疏保持嵌入的高光谱影像地物分类[J]. *仪器仪表学报*, 2016, **37**(1): 177-183.