

文章编号 1004-924X(2018)07-1827-10

空-谱协同流形重构的高光谱影像分类

黄 鸿*, 陈美利, 段宇乐, 石光耀

(重庆大学 光电技术与系统教育部重点实验室, 重庆 400044)

摘要: 鉴于传统高光谱影像分类大都采用监督学习方法, 且仅利用了光谱信息, 未考虑影像空间特征和流形结构。提出一种基于空-谱协同流形重构误差的高光谱影像分类方法, 该算法基于高光谱影像中地物分布的空间一致性, 利用少量标记的样本和大量的无标记空间近邻样本来进行半监督学习, 并利用测试样本在每一子流形上的重构误差来表征相似性, 实现鉴别分类。在 Indian Pines 和 University of Pavia 数据集上的实验结果表明, 本文方法的分类精度在各种条件下要优于其他分类算法, 其最高总体精度分别达到了 95.67% 和 91.92%。该算法将高光谱遥感影像中的空间-光谱信息融入不同地物的子流形结构表征, 在训练样本数量较少时仍能得到好的分类效果, 有效提升了分类性能。

关键词: 高光谱遥感; 图像分类; 空-谱特征; 流形学习; 重构误差

中图分类号: TP394.1; TH691.9 **文献标识码:** A **doi:** 10.3788/OPE.20182607.1827

Hyper-spectral image classification using spatial-spectral manifold reconstruction

HUANG Hong*, CHEN Mei-li, DUAN Yu-le, SHI Guang-yao

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

* Corresponding author, E-mail: hhuang@cqu.edu.cn

Abstract: In recent years, several supervised learning methods have been introduced in hyperspectral image (HSI) classification. However, these methods use only spectral information without taking into account the spatial features and manifold structures of HSIs. To overcome this problem, a new classification method was proposed for HSI classification, combining spatial-spectral features and manifold reconstruction. Based on the spatial consistency of ground objects distribution in HSIs, the proposed algorithm used a small number of labeled samples and large number of unlabeled spatial neighbor samples to perform semisupervised learning, and utilized the reconstruction error of test samples in each submanifold to represent the similarities for discriminant classification. Experimental results obtained from the Indian Pines and University of Pavia data set reveal that the proposed method exhibits a higher classification accuracy compared to other classification algorithms under various training conditions, the highest overall accuracy achieved in the two cases being 95.67% and 91.92%, respectively. The proposed method integrates spatial-spectral information to represent the submanifold structure of different land objects, exhibits superior discrimination performance,

收稿日期: 2017-11-03; 修订日期: 2018-01-19.

基金项目: 国家自然科学基金资助项目 (No. 41371338)

especially for a small number of training samples, and effectively improves the performance of HSI classification.

Key words: hyperspectral remote sensing; image classification; spatial-spectral feature; manifold learning; reconstruction error

1 引言

高光谱遥感影像具有数据量大、波段多及光谱分辨率高等特点^[1-2],不仅能辨识不同地物光谱间差异较大的地物类别,而且能辨识不同地物光谱间只存在细微差异的地物类别,可实现地物的精细分类。但如何有效提取像元鉴别特征与提升影像分类精度,是当前高光谱遥感影像分类研究热点^[3-4]。

高光谱遥感影像分类常用的非监督分类方法有 K 均值法(K-means)、自组织映射法(Self-Organizing Map, SOM)和高斯混合模型(Gaussian Mixture Model, GMM)^[5-7]等。尽管不需要样本的类别信息,但是大都需要人工解译来确定地物类别,例如光谱角制图(Spectral Angle Mapping, SAM)^[8]、K 近邻(K-Nearest Neighbor, KNN)^[9]及支持向量机(Support Vector Machines, SVM)^[10]等。这些方法是典型的监督分类方法,通过训练样本的类别标签信息,构建相关的判断函数或准则,获得未知样本的类别,但是需要一定数量的标记样本来保证分类性能。然而在实际应用中,标记样本数量有限,且对数据进行标记的代价很高。同时,以上分类算法在提取鉴别特征是仅利用了光谱特性,忽略了影像中丰富的空间信息。

高光谱遥感影像具有空间一致性的特点^[11-12],即各像素之间的空间位置也具有一定程度的相关性,因而学者们近年来探索融合其空间信息来提升分类性能。Mohan 等提出了一种基于空间相干距离(Spatially Coherence Distance, SCD)^[13]的近邻分类算法,但该算法只比较了环块中相同位置像元,忽视了环块自身局部空间相关性。Pu 等表述了一种以采用图像块替代单一像元作相似度量的近邻选择方法(Image Patch Distance, IPD)^[14],能较好保持该图像块局部结构,但计算复杂度大。上述分类方法在进行分类时都忽略了如何有效发现和利用高光谱数据中子流形来实现地物分类。Fu 等提出了一种利用同类别

的近邻区域内多个样本点重构进行分类鉴别的算法(K-Nearest-Neighbor Simplex, KNNS)^[15],在人脸识别上取得了较好效果,但是该算法不能直接应用于高光谱遥感影像空-谱分类。

针对上述问题,本文提出了一种新的空-谱协同流形重构分类方法(Spatial-spectral combined Manifold Reconstruction classifier, S²MREC)算法。该方法根据高光谱影像空间一致性特点,利用少量标记样本获取其空间近邻样本信息,将未知像元在每类样本空间进行近邻流形重构,并根据最小重构误差来衡量像元与对应类别的契合程度,从而实现有效地物分类。在 Indian Pines 和 University of Pavia 高光谱数据集上的实验结果表明,本文方法相较其他分类方法具有更好的地物分类性能。

2 本文算法

文中高光谱遥感数据集表示为 $Z = \{(z_1, l_1), (z_2, l_2), \dots, (z_{n_l}, l_{n_l}), z_{n_l+1}, \dots, z_n\}$, 类别标签集为 $L = \{1, 2, \dots, c\}$ 。其中 $z_i \in R^{B \times 1}$, l_i 为 z_i 对应的标签,且 $l_i \in L$, n_l 为有标签的样本数, c 为类别数, B 为高光谱空间维度, n 为样本总数, $n - n_l$ 为无标记样本数。

2.1 KNNS 算法

传统 NN 通过度量新样本与其周围像素点之间的距离判定样本所属的类别,在模式分类问题中得到了广泛的应用,但面对数据分布不规则的多分类问题时,仅依赖单个近邻点进行分类不能保证其分类精度。由此,Roweis 和 Saul 在《科学》杂志中提出每个数据点与其近邻点可以构成或近似构成一个局部子流形,因而用近邻点线性重构系数来表征数据点邻域内空间结构。以此为基础, Fu 等提出了 KNNS 算法,其利用样本与每类邻域内近邻点的线性重构误差衡量样本与对应类别的相似程度来判别样本类别,可避免 KNN 中因单个非同类近邻点导致的分类错误,因此具有更好的分类性能。

对于高光谱数据集 Z ,KNNS 算法利用数据点 z_i 的 k 个局部近邻点的线性重构表示 z_i ,具体如下:

$$S(z_1, z_2, \dots, z_k) = \sum_{j=1}^k m_j z_j$$

$$\text{st. } \sum_{j=1}^k m_j = 1, m_j \geq 0, \quad (1)$$

式中: $S(z_1, z_2, \dots, z_k)$ 表示 z_i 的局部 k 最近邻重构函数, z_j 为 z_i 局部子流形内的近邻点, m_j 表示近邻点 z_j 的权重系数,反映了 z_i 近邻点与其相关程度。

在此基础上,待分类样本 z_t 在第 i 流形上的重构误差 d_{knn}^i 可通过如下目标函数获取:

$$d_{knn}^i = \operatorname{argmin} \left\| z_t - \sum_{j=1}^k m_j^i z_j^i \right\|. \quad (2)$$

重构误差 d_{knn}^i 体现了待分类样本与不同流形(类别)样本在分布上的距离关系。 d_{knn}^i 越小,表明样本与该类数据的相似度越高,属于该类别的概率也越大。因此,样本点 z_i 所属类别可根据以下目标函数判定:

$$l_t^* = \operatorname{argmin}_i d_{knn}^i. \quad (3)$$

2.2 S²MREC 算法

KNNS 算法采用样本点邻域的线性重构系数来描述几何结构,但在高光谱遥感影像分类若仅利用光谱特性寻找近邻,易因高光谱遥感影像中“异物同谱”现象导致将非同类点选为近邻,降低分类精度。针对此问题,本文依据高光谱遥感数据的空间一致性特点,提出了一种基于空-谱协同流形重构分类方法,该方法融合样本的空-谱联合信息来选择近邻点,然后利用测试样本在每一

类训练样本及其近邻空间上的流形重构误差来表征相似度,并得到测试样本的类别标签,提升高光谱数据地物分类性能。S²MREC 算法过程如图 1 所示。

在高光谱遥感影像分类中,由于地物具有空间自相关性,令以像素 $z_i(x, y)$ 为中心的环块 $\Omega(z_i)$ 称为近邻空间域,其窗口大小为 $r \times r$, r 是正奇整数, x, y 分别是 z_i 在影像中的行与列。则以像素 $z_i(x, y)$ 为中心的近邻空间域 $\Omega(z_i)$ 可记作:

$$\Omega(z_i) = \{z_{im}(x_m, y_m) \mid x_m \in (x-c, x+c), y_m \in (y-c, y+c)\}, \quad (4)$$

其中: $z_{im}(x_m, y_m)$ 为 $\Omega(z_i)$ 中任意像素, x_m 和 y_m 为其在当前近邻空间中的行和列, $1 \leq m \leq r^2$, $c = (r-1)/2$ 。在得到训练样本的近邻空间的基础上,待分类的样本通过与每类空间训练样本流形重构,根据其对应的流形重构结果之间的最小重构误差来判别其类别属性。即对于未知像素点 z_{new} 在第 i 类样本空间 $\Omega(Z^{(i)}, i \in L)$ 内的 k 个局部邻域点线性重构函数如下:

$$S^*(z_1^{(i)}, z_2^{(i)}, \dots, z_k^{(i)}) = \sum_{m=1}^k \omega_m * z_m^{(i)}$$

$$\text{s. t. } \sum_{m=1}^k \omega_m = 1, \omega_m \geq 0, \quad (5)$$

式中: $S^*(z_1^{(i)}, z_2^{(i)}, \dots, z_k^{(i)})$ 表示 z_{new} 在第 i 类样本空间上 k 近邻重构函数, $z_m^{(i)}$ 表示 z_{new} 在第 i 类样本空间中的近邻点, ω_m 表示第 i 类邻域点 $z_m^{(i)}$ 的权重系数。则数据点 z_{new} 与其每类子流形近邻重构结果 $e_{S^2MREC}^{(i)}$ 可通过如下目标函数求解:

$$e_{S^2MREC}^{(i)} = \operatorname{argmin} \left\| z_{new} - \sum_{m=1}^k \omega_m * z_m^{(i)} \right\|. \quad (6)$$

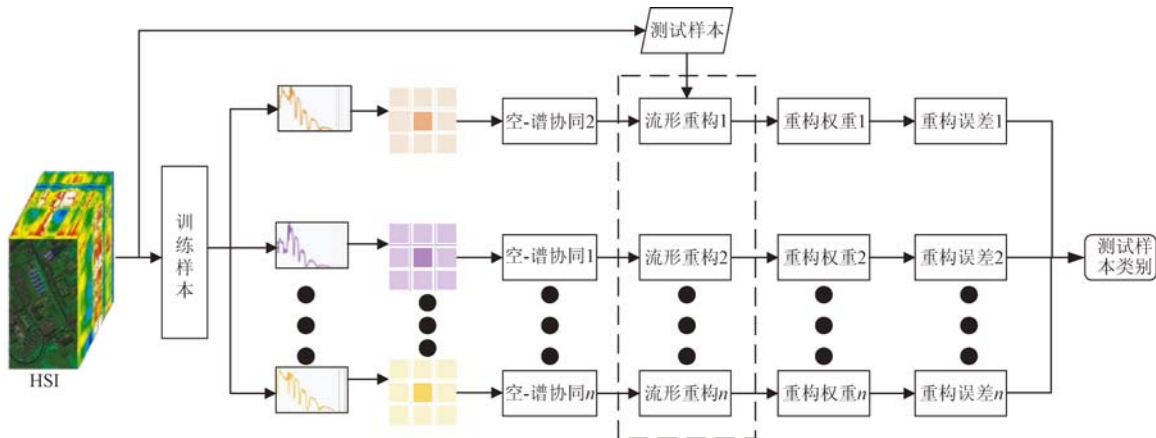


图 1 S²MREC 算法流程图
Fig. 1 Flow chart of S²MREC algorithm

局部空间子流形重构误差 $e_{S^2MREC}^{(i)}$ 反映了待分类的数据点与同类或异类数据点在空间分布上的距离关系。样本与某类像元间重构误差越小,说明该样本与此类数据的契合程度越高,归属于该类别的概率就越大。由此小样本且多分类的问题得到解决。

最后根据下述目标函数即可判定未标记样本 z_{new} 所属的地物类别 l_{new}^* :

$$l_{new}^* = \arg \min_i \{ e_{S^2MREC}^{(i)} ; i \in L \}. \quad (7)$$

与 KNN 及 KNNS 算法相比, S^2MREC 算法具有更好的分类性能,具体可以通过一个二分类例子进行说明。如图 2 所示,处于两个三角形中

间点 R 是属于圆形类, S^2MREC 分别利用两类别样本空间内与 R 点空间近邻的像元点线性重构点 R , 点 R 与圆形类的距离(重构误差)为 b , 与方形类距离是 a , 由于 $b < a$ 所以把 R 点判定为距离近的圆形类。KNNS 分别利用两类中同 R 点近邻的样本点线性重构点 R , R 点与方形类重构误差是 a , 与圆形类的重构误差是 c , 然而 $a = c$, 点 R 既可以认为是圆形类也可以是方形类, 易造成点 R 类别误判。而在简单凭借欧式距离度量分类的 KNN 算法中, R 点与圆形类近邻点最近距离是 d , 与方形类近邻点最短距离为 a 因为 $a < d$, 以致 R 被错分为方形类。




图 2 S^2MREC 与 KNNS、KNN 方法的对比

Fig. 2 Comparison of S^2MREC with KNNS and KNN

2.3 S^2MREC 算法步骤

本文提出的 S^2MREC 分类算法的具体实现步骤如表 1 所示。

表 1 S^2MREC 算法具体步骤

Tab. 1 Specific steps of S^2MREC algorithm

输入: 高光谱数据 Z , 类别标签 L , 训练样本率 ω , 空间窗口 r , 近邻数 k	输出: 测试数据点的类别
1. 在数据集 Z 中按训练样本率 ω 随机选取训练样本, 余下的为测试样本, 其中训练样本已标记;	
2. 利用式(4)获取属于空间训练样本: $\{ \Omega(z_i); \Omega(z_i) \in R^{B \times r \times r} \}_{i=1}^n$;	
3. 根据式(5)、(6)测试样本在每类空间训练样本中寻找 k 近邻点局部流形重构, 并计算其与每类流形重构结果之间的重构误差 $\{ e_{S^2MREC}^{(i)} ; i \in L \}$;	
4. 最后通过公式(7)优化问题最小化, 判定未知样本类别 l_{new}^* 属于重构误差最小的那类。	

美国 Indian 州西北的一片农田区域高光谱图像。影像尺寸为 $145 \text{ pixel} \times 145 \text{ pixel}$, 其波长区间为 $400 \sim 2450 \text{ nm}$, 共有 220 个波段, 去除受噪声影响或是水气吸收影响的波段, 分别是第 104 到 108 与第 150 到 163、第 220 波段, 剩余的波段用于实验, 主要包括 16 类地物。图 3 为其假彩色图像和实际地物。

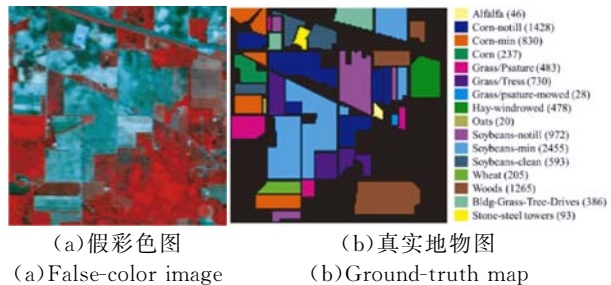


图 3 Indian Pines 高光谱影像

Fig. 3 Indian Pines hyperspectral image

3 实验结果及分析

3.1 实验数据集

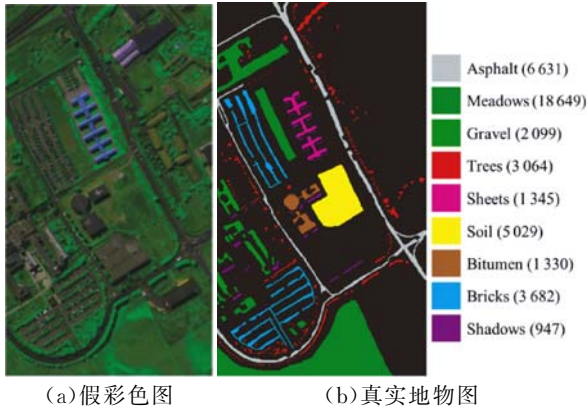
3.1.1 Indian Pines 数据集

此数据集是运用 AVIRIS 传感器采集的位于

3.1.2 University of Pavia 数据集

此数据集是运用由 ROSIS 传感器获得的位于意大利北部帕维亚大学区域的高光谱影像。该

数据集尺寸为 $610 \text{ pixel} \times 340 \text{ pixel}$, 空间分辨率为 1.3 m , 涵盖了 115 个波段, 剔除水气吸收严重的波段, 将余下的 103 个波段用于实验。University of Pavia 数据集含有 9 类地物, 其假彩色图像与实际地物信息如图 4 所示。



(a)假彩色图 (b)真实地物图
(a)False-color image (b)Ground-truth map

图 4 University of Pavia 高光谱影像

Fig. 4 University of Pavia hyperspectral image

3.2 实验设置

在实验中, 将总体分类精度 (Overall Accuracy, OA), 平均分类精度 (Average Accuracy, AA) 和 $Kappa$ 系数作为分类性能评估指标。每次实验均按一定比例随机选取训练样本数, 剩下部分均为测试样本, 并每种实验条件下进行 10 次实验。

为评估本文方法的有效性, 将 S^2MREC 与 KNN, SAM, SVM 等谱分类方法, KNNS 子流形分类方法, 以及 IPD, SCD 等空-谱联合分类方法作比较。为使得各方法均能获得较佳效果, 采用交叉验证方法使各算法参数调节到最优, KNN 和 SAM 的最近邻数为 1, SVM 的最优参数通过 10 次交叉验证获得, IPD 和 SCD 的空间窗口设置为 9。

3.3 参量对 S^2MREC 算法的影响

为探究近邻空间域窗口 r 和近邻数参量 k 对 S^2MREC 的影响, 分别从 Indian Pines、University of Pavia 数据集的每类地物随机选取 1% 和 0.1% 的像元用于训练, 余下样本用来测试。图 5 为 Indian Pines 数据集中 S^2MREC 在不同近邻空间域窗口 r 和近邻数参量 k 下的总体分类精度。

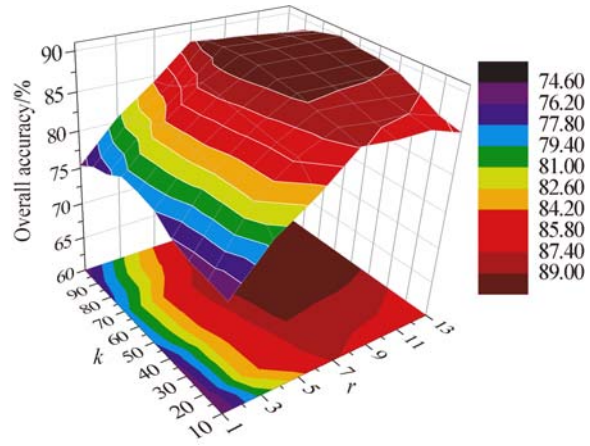


图 5 Indian Pines 数据集中, S^2MREC 在不同 r 和 k 下的总体分类精度

Fig. 5 Overall accuracy of S^2MREC with different r and k in Indian Pines data set

由图 5 可知, 对于 Indian Pines 数据集, 随着近邻空间域窗口 r 的增大, 算法的分类精度逐渐增大, 但当窗口大于 7×7 时, 增幅逐渐变小。这是由于随着空间窗口越大, S^2MREC 能利用的空间信息愈发丰富, 奇异性较大的像元愈易平滑, 然而当获取的空间信息足够多时, 分类精度逐渐趋于平稳。在保证良好的实验结果前提下, 兼顾算法的运行效率, 选取 $r=7$ 。同时, 总体分类精度随着 k 的变化具有一定波动, 在 k 为 70 时分类效果较佳。

对于 University of Pavia 数据集, 本文采用与 Indian Pines 数据集相同的实验处理方式, 如图 6 所示, University of Pavia 数据集中 S^2MREC 在不同空间邻域窗口 r 和近邻数参量 k 下的总体分类精度, 选取 $r=7, k=80$ 分类效果较好。




图 6 University of Pavia 数据集中, S^2MREC 在不同 r 和 k 下的总体分类精度

Fig. 6 Overall accuracy of S^2MREC with different r and k in University of Pavia data set

3.4 Indian Pines 实验结果与分析

实验中,从 Indian Pines 数据集的每一类地物中分别按照 2%、4%、6%、8% 比例随机选取数据作训练样本,余下数据均用于测试。若某一类中选取训练样本数目小于 10,统一选取 10 个训练样本。表 2 为在不同的训练样本比例下各种分类方法的总体分类精度及方差。

表 2 不同分类算法在 Indian Pines 数据集上的分类效果 (总体分类精确度±标准差)

Tab. 2 Classification results with different methods in Indian Pines data set (Overall Accuracy±Std) (%)

Algorithm	2	4	6	8
KNN	57.87±1.39	63.23±0.9	65.17±0.81	66.37±0.62
KNNS	66.82±1.64	71.29±0.79	73.74±1.03	74.95±0.68
SAM	59.19±1.25	64.24±0.96	66.22±0.68	67.64±0.63
SVM	65.33±2.18	72.26±1.25	76.50±1.32	78.96±0.65
IPD	84.64±1.33	87.07±1.22	91.51±0.65	92.35±0.66
SCD	76.96±2.11	83.79±0.75	88.52±0.73	90.31±0.79
S ² MREC	87.52±1.30	90.45±0.74	94.06±0.50	95.67±0.23

由表 2 可知,各种方法的分类精度均随着训练样本率的增加而不断提升,这是因为随着训练样本数量增加,可在分类中融入更多先验信息,进

而提升分类精度。KNNS 算法的分类精度要高于 KNN、SVM、SAM 方法,是因为这 3 个分类方法仅利用了样本的光谱信息,而 KNNS 算法在分类时有效融入了训练数样本点局部近邻流形结构信息,因此具有更好的鉴别性。IPD、SCD 及 S²MREC 等空-谱联合方法的分类效果则优于 KNNS 方法,其原因是有效利用了训练样本中丰富的空间近邻信息,有效改善了分类效果。在不同训练条件下,S²MREC 算法的分类效果是最好的,尤其在训练样本较少时仍具有较好的识别率,因为其通过利用训练样本的空间近邻信息来发现样本数据的局部流形结构,进而增强地物分类性能。

为分析各算法在每类地物上分类性能,从 Indian Pines 数据集里随机选取 10% 的数据做训练样本,剩余样本用于测试。表 3 为不同算法每种地物分类精度、总体分类精度、平均分类精度以及 Kappa 系数,各种分类方法地物分类结果如图 7 所示。

由表 3 可知,S²MREC 算法在大部分地物类别中具有较高的分类精确度,在“Corn”、“Soybeans-clean”、“Grass”等这几类中尤为明显。与此同时,在图 7 中 S²MREC 算法的分类结果图相比其他算法,在大多区域错分点均较少,地物分类结果更为光滑。

表 3 Indian Pines 数据集中每类地物在不同方法下的分类结果

Tab. 3 Classification results of each class samples via different methods in Indian Pines data set (%)

Classes	Train	Test	KNN	SAM	SVM	KNNS	SCD	IPD	S ² MREC
Alfalfa	10	36	81.94	82.50	85.83	68.05	97.22	100	97.22
Corn-notill	28	1400	42.13	43.57	60.69	54.02	52.18	75.98	83.49
Corn-min	16	814	37.82	40.75	42.92	46.83	54.24	76.95	83.15
Corn	10	227	39.42	41.85	48.19	13.56	44.05	82.81	97.80
Grass/Psature	10	473	63.12	64.97	74.19	75.15	71.24	84.35	86.68
Grass/Tress	15	745	78.79	80.33	88.28	95.42	85.73	91.93	88.95
Grass/psature-mowed	10	18	93.88	92.22	91.27	89.44	100	100	100
Hay-windrowed	10	468	74.18	74.93	81.60	95.92	99.78	99.21	100
Oats	10	10	86.00	89.00	93.00	79.00	100	81.11	100
Soybeans-notill	19	953	53.24	54.45	53.84	66.00	77.23	85.72	84.05
Soybeans-min	49	2 406	60.64	61.67	70.12	83.52	81.25	91.60	88.82
Soybeans-clean	12	581	29.02	28.89	39.85	30.73	35.28	61.96	82.27
Wheat	10	195	88.92	89.38	92.62	91.94	99.48	89.23	96.92
Woods	25	1 240	85.59	86.51	87.17	98.74	90.88	95.26	97.90
Bldg-Grass-Tree-Drives	10	367	24.52	26.14	30.05	35.09	36.17	80.31	80.32
Stone-steel towers	10	83	89.63	91.32	89.28	85.66	85.54	97.59	98.80
总体精度(OA)			67.66	68.96	80.66	75.58	91.85	91.85	97.12
平均精度(AA)			64.29	65.52	69.83	69.02	73.62	88.21	91.60
Kappa 系数			0.52	0.54	0.60	0.62	0.65	0.81	0.87




图 7 各算法在 Indian Pines 数据集上的每类地物分类结果

Fig. 7 Classification results with different algorithms in each class samples of Indian Pines data set

3.5 University of Pavia 实验结果与分析

依据实验设置,从 University of Pavia 数据集分别按照 0.2%、0.4%、0.6%、0.8% 比例随机取数构成训练样本集,余下部分均为测试样本。若某一类中选取训练样本数目不足 10,统一选取 10 个训练样本。表 4 为在相同的影像处理背景下,在不同训练样本率下各算法的总体分类精度和方差。

表 4 不同分类器算法在 University of Pavia 高光谱数据集上的分类效果(总体分类精确度±标准差)

Tab. 4 Classification results with different methods in University of Pavia data set (Overall Accuracy±Std) (%)

Algorithm	0.2	0.4	0.6	0.8
KNN	72.56±1.04	75.41±1.20	77.95±0.93	79.17±1.02
KNNS	77.86±3.05	80.32±1.71	82.95±1.52	82.29±1.44
SAM	70.12±1.51	74.19±1.19	75.23±1.38	77.42±1.16
SVM	79.12±1.01	84.50±1.30	86.37±2.13	88.06±0.94
IPD	86.23±0.81	88.14±0.77	90.47±0.91	90.80±0.95
SCD	74.56±1.51	80.59±1.18	83.18±1.05	83.89±0.56
S²MREC	87.57±1.00	90.71±0.21	91.34±0.26	91.92±0.53

根据表 4 可得,在各种实验条件下,S²MREC 算法的分类结果最优,这是由于其不仅利用了遥感影像的空间一致性原则,还有效利用了每一类

训练样本的空间近邻数据来发现高光谱数据的鉴别子流形结构,使地物分类效果得到有效地提升。

从 University of Pavia 数据集里随机选取 1% 的数据做训练样本,余下的用于测试,来分析各算法在每类地物上分类性能。不同算法对每种地物分类效果如表 5 所示,图 8 为各算法在每类地物上的分类结果图。

由表 5 可知,S²MREC 算法对大部分类别都具有更好的分类性能,其每类地物的分类精度、总体分类精度、平均分类精度以及 Kappa 系数均优于其他方法。同时,从图 8 可以看到 S²MREC 算法的分类结果图中错分点更少,在“Soil”、“Asphalt”、“Tetal sheets”等区域尤其明显。

需要说明的是,相对于 Indian Pines 数据集而言,University of Pavia 数据集内包含的每类地物样本更丰富,其地物分布更为密集,空间特征利用性极高,同时为缩短算法运行时耗。故在验证各算法分类性能时,选取训练样本比例为 Indian Pines 数据集选取训练样本率的十分之一,从最后的实验结果来看,相比已有的算法,S²MREC 算法分类结果是最佳,最高平均总体精度到达了 91.92%,在一定程度上反映了小样本情况下本算法的有效性,同时也验证训练样本率分别取 0.2%、0.4%、0.6%、0.8% 是合理的。

表 5 University of Pavia 数据集中每类地物在不同方法下的分类结果

Tab. 5 Classification results of each class samples via different methods in University of Pavia data set (%)

Classes	Train	Test	KNN	SAM	SVM	KNNS	SCD	IPD	S ² MREC
Asphalt	133	6 498	79.24	71.53	88.87	86.25	82.00	95.63	98.04
Meadows	373	18 276	90.65	91.87	95.69	80.39	99.00	97.58	98.16
Gravel	42	2 057	54.04	59.77	77.67	74.88	60.00	81.67	71.27
Trees	61	3 003	76.59	78.37	90.70	89.22	74.00	93.93	96.31
Tetal sheets	27	1 318	99.25	98.42	99.47	99.47	98.00	96.10	99.70
Soil	101	4 928	49.27	40.11	73.49	79.51	57.00	76.06	84.31
Bitumen	27	1 303	72.82	71.91	73.80	52.24	88.00	93.39	62.57
Bricks	74	3 608	71.17	74.32	80.33	73.55	90.00	85.24	81.43
Shadows	19	928	99.68	90.39	99.48	98.09	97.00	99.57	99.79
总体精度(OA)			79.45	78.13	88.98	81.12	86.37	92.51	93.60
平均精度(AA)			76.99	75.19	86.63	81.71	82.74	91.01	92.95
Kappa 系数			0.72	0.71	0.85	0.76	0.82	0.90	0.95




图 8 各算法在 University of Pavia 数据集上的每类地物分类结果图

Fig. 8 Classification results with different algorithms in each class samples of University of Pavia data set

4 结 论

本文基于流形学习方法和空间一致性原理,提出了一种基于空-谱协同流形重构的分类算法。该方法能较充分利用影像中丰富的光谱信息和其空间近邻信息来发现高光谱遥感数据中的鉴别子流形,来提升分类器的地物鉴别能力,进行改善分类效果。在 Indian Pines 和 University of Pavia 高光谱数据集上的实验结果表明,本文算法相比

其他分类方法分类精度有不同程度的提升,在训练样本较少时尤为明显,因而具有更好的实际应用价值。在最小训练样本率下的总体平均精度,本文算法相比光谱类分类算法提高了约 22%~25%,相比结合空间信息和光谱信息的分类算法提升了约 3%~10%。

本文提出的分类算法直接对高光谱遥感数据进行分类,由于高光谱数据中存在波段相关性强,存在冗余等特点,因此,在下一步工作将对其进行降维处理,提取鉴别特征,进一步提升算法分类性能。

参考文献:

- [1] 黄鸿,郑新磊. 加权空-谱与 KNN 相结合的高光谱图像分类[J]. 光学精密工程, 2016, 24(4): 873-880.
HUANG H, ZHENG X L. Hyperspectral image classification with combination of weighted spatial-spectral and KNN [J]. *Opt. Precision Eng.*, 2016, 24(4): 873-880. (in Chinese)
- [2] TIEN H N, KOIKE K. Hyperspectral transformation from EO-1 ALI imagery using pseudo-hyperspectral image synthesis algorithm [J]. *ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2016, XLI-B7:661-665.
- [3] 王晗,王阿川,苍圣. 基于压缩感知的高光谱遥感影像重构方法研究[J]. 液晶与显示, 2017, 32(3): 219-226.
WANG H, WANG A CH, CANG SH. Research on reconstruction of hyperspectral remote sensing image based on compressed sensing [J]. *Chinese Journal of Liquid Crystals and Displays*, 2017, 32(3): 219-226. (in Chinese)
- [4] WANG L, ZHANG J, LIU P, *et al.*. Spectral-spatial multi-feature-based deep learning for hyperspectral remote sensing image classification [J]. *Soft Computing*, 2017, 21(1):213-221.
- [5] LIU X, WANG L, ZHANG J, *et al.*. Global and local structure preservation for feature selection [J]. *IEEE Transactions on Neural Networks & Learning Systems*, 2017, 25(6):1083-1095.
- [6] 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.
DU P J, XIA J SH, XUE ZH H, *et al.*. Progress of hyperspectral remote sensing image classification [J]. *Journal of remote sensing*, 2016, 20(2):236-256. (in Chinese)
- [7] 罗甫林. 面向高光谱图像的空谱核半监督图聚类算法研究[D]. 重庆:重庆大学, 2016.
LUO F L. *Study spectral kernel semi supervised graph clustering algorithm of hyperspectral images*[D]. Chongqing: Chongqing University, 2016.
- [8] ZHANG S, WU C, LIU L, *et al.*. Optical coherence tomography angiography of the peripapillary retina in primary angle-closure glaucoma [J]. *American Journal of Ophthalmology*, 2017, 182:194.
- [9] TIAN J, MORILLO C, AZARIAN M H, *et al.*. Motor bearing fault detection using spectral kurtosis-based feature extraction coupled with k-nearest neighbor distance analysis [J]. *IEEE Transactions on Industrial Electronics*, 2016, 63(3): 1793-1803.
- [10] CAVALLARO G, RIEDE M, RICHERZHAGEN M, *et al.*. On understanding big data impacts in remotely sensed image classification using support vector machine methods [J]. *IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing*, 2016, 8(10):4634-4646.
- [11] XIA J, CHANUSSOT J, DU P, *et al.*. Spectral-spatial classification for hyperspectral data using rotation forests with local feature extraction and markov random fields [J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2015, 53(5): 2532-2546.
- [12] SOUZAF D M D, SARKAR S, SRIVASTAVA A, *et al.*. Spatially coherent interpretations of videos using pattern theory [J]. *International Journal of Computer Vision*, 2017, 121(1):1-21.
- [13] MOHANA, SAPIRO G, BOSCH E. Spatially coherent nonlinear dimensionality reduction and segmenta-

- tion of hyperspectral images [J]. *IEEE Geoscience & Remote Sensing Letters*, 2007, 4(2):206-210.
- [14] 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.
- [15] FU Y, Y SC, HUANG T S. Classification and feature extraction by simplexization [J]. *IEEE Trans. on Information Forensics and Security*, 2008, 3(1):91-100.
- [16] CUIM, PRASAD S. Spectral-angle-based discriminant analysis of hyperspectral data for robustness to varying illumination [J]. *IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing*, 2017, 9(9):4203-4214.
- [17] 李志敏,张杰,黄鸿,等. 面向高光谱图像分类的半监督丛流形学习[J]. *光学精密工程*, 2015, 23(5):1434-1442.
- LI ZH M, ZHANG J, HUANG H, *et al.*. Semi-supervised bundle manifold learning for hyperspectral image classification [J]. *Opt. Precision Eng.*, 2015, 23(5): 1434-1442. (in Chinese)
- [18] 何芳,王榕,于强,等. 加权空谱局部保持投影的高光谱图像特征提取[J]. *光学精密工程*, 2017, 25(1):263-273.
- HE F, WANG R, YU Q, *et al.*. Feature extraction of hyperspectral images with weighted spatial-spectral locally maintained projection [J]. *Opt. Precision Eng.*, 2017,25(1):263-273. (in Chinese)

作者简介:



黄 鸿(1980—),男,湖南新宁人,教授,博士生导师,2003、2005、2008 年于重庆大学分别获得学士、硕士和博士学位,主要从事流形学习、模式识别、遥感影像智能化处理等方面的研究。E-mail: hhuang@cqu.edu.cn



陈美利(1992—),女,重庆铜梁人,硕士研究生,2016 年于南京师范大学获得学士学位,主要从事图像处理、遥感影像分类等方面的研究。E-mail: chenmeili@cqu.edu.cn

(本栏目编辑:秦 思)