

文章编号 1004-924X(2016)04-0873-09

加权空-谱与最近邻分类器相结合的高光谱图像分类

黄 鸿, 郑新磊*

(重庆大学 光电技术与系统教育部重点实验室, 重庆 400044)

摘要:提出了一种基于加权空-谱距离(WSSD)的相似性度量方法,并将其应用到最近邻分类器(KNN)中,导出了一种新的高光谱图像分类算法。该算法利用高光谱图像的物理特性,通过引入空间窗口和光谱因子这两个参数来挖掘出图像中的空间信息与光谱信息,利用空间近邻点对中心像元进行重构。在最大限度减少图像冗余信息的基础上,增大了同类像元间的相似性以及异类像元间的差异性,获得了更为有效的鉴别特征,从而更好地实现了数据间的相似性度量。基于 Indian Pines 和 PaviaU 高光谱数据集进行了实验,结果表明:将提出的 WSSD-KNN 算法应用于高光谱图像分类时,其分类精度高于其他算法,总体分类精度分别达到了 91.72% 和 96.56%。由于算法较好地融合了图像中的空间-光谱信息,提取出了更为有效的鉴别特征,故不仅有效地改善了高光谱数据的地物分类精度,而且可在训练样本较少时,保持较高的识别率。

关键词:高光谱图像;图像分类;空间近邻;加权空-谱距离;最近邻分类器

中图分类号:TP751.1 **文献标识码:**A **doi:**10.3788/OPE.20162404.0873

Hyperspectral image classification with combination of weighted spatial-spectral and KNN

HUANG Hong, ZHENG Xin-lei*

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

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

Abstract: A spatial consistency measurement method based on the Weighted Spatial-Spectral Distance (WSSD) is proposed and applied to the K Nearest Neighbor(KNN) classifier, and a new hyperspectral image classification algorithm is obtained. On the basis of the physical characters of hyperspectral images, the proposed algorithm combines both spatial window and spectral factor to obtain the spatial information and spectral information, and uses the spatial nearest points to reconstruct the center point and to reveal the local spatial structure. With effectively reducing the redundant information in the image, this algorithm increases the consistency of the same kinds pixels and the difference of the different kinds pixels and obtains extract discriminating features, so it implements the consistency measurement between the data points. The experiments were performed on the Indian Pines and PaviaU hyperspectral data sets. Experiment results show that the WSSD-KNN algorithm has better classification accu-

收稿日期:2015-12-15;**修订日期:**2016-01-14.

基金项目:国家自然科学基金资助项目(No. 41371338, No. 61101168);重庆市基础与前沿研究计划资助项目(No. cstc2013jcyjA4005);中央高校基本科研业务费专项资金资助项目(No. 106112013CDJZR125501, No. 1061120131204)

racy than other algorithms when it is applied to the classification of hyperspectral image, and the overall classification accuracies reach 91.72% and 96.56%, respectively. With the spectral information, spatial information and extract discriminating features, the proposed algorithm effectively improves ground object classification accuracy of hyperspectral data and has better recognition ability in less train samples.

Key words: hyperspectral image; image classification; spatial neighbor; weighted spatial-spectral distance; K Nearest Neighbor(KNN)

1 引言

高光谱遥感是现代遥感领域中最具前景的应用技术之一,被广泛用于资源探索、环境监测和精准农业等诸多领域^[1-3]。高光谱图像最主要的特点是图谱合一^[4],在获取地面图像空间信息的同时,得到每个地物的连续光谱信息,为地物的精细识别与分类带来了新的机遇^[5]。

由于高光谱数据集中含有十分丰富的地物光谱信息,而这些信息又能够较为充分地区别不同地物之间的差异。因此,在通常情况下,对于高光谱图像地物,仅使用光谱维信息进行分类。最近邻分类法(K Nearest Neighbor, KNN)^[6]是一种常用的地物分类方法,它通过寻找训练样本集中的 K 个已知近邻来判断未知像元的类别。光谱角制图(Spectral Angle Mapping, SAM)^[7]是对地物光谱波形相似性的一种度量,通过计算光谱曲线间的夹角对未知光谱曲线进行判定。支持向量机(Support Vector Machine, SVM)^[8-9]是一种基于核的分类方法,其较好地解决了分类过程中面临的小样本学习问题。这些算法都具有坚实的理论基础,易于执行和分析,广泛用于高光谱图像的地物分类中。然而,为了能更加准确地区分不同地物间的差异,一般需要大量的标记样本用于对比,而在实际应用中,有标记样本的获得通常十分困难和耗时。同时,这些算法也仅利用了图像中的光谱信息,忽略了不同像元在空间位置上的相互关系。

除光谱特征外,空间特征在高光谱图像分类中也具有十分重要的作用。从物理意义上讲,高光谱数据并不仅仅是由一些相互独立且无序排列的光谱特征向量组成,这些向量在空间位置上是

具有一定联系的,空间上距离很近的像元在很大概率上属于同一类地物,即地物分布的空间一致性特点^[10-11]。因此,高光谱图像分类可以采用空间信息与光谱信息相结合的空-谱联合分类方法。考虑到像元周围的局部空间结构,文献[12]将光谱分类器与图像中像元的近邻信息相结合,提出了一种基于投票式的多分类器联合算法。文献[13]提出了一种基于空间相干距离(Spatially Coherence Distance, SCD)的近邻选取方式,该方法首先在每个像元周围选取环块,通过计算环块间的距离来进行数据点间的相似性度量,但 SCD 仅比较了各环块中相同位置上的像元,忽略了环块本身局部结构的保持。文献[14]提出了一种基于图像块距离(Image Patch Distance, IPD)的邻域选择算法,该算法利用图像块替代单一像元参与度量,同时较好地保持了图像块自身的局部结构,但算法复杂度较高,耗时较长。

针对以上问题,本文提出一种新的基于加权空-谱距离(Weighted Spatial-Spectral Distance, WSSD)的相似性度量算法。该算法的核心思想为:利用像元的空间近邻对其进行重构,以有效去除像元中的冗余信息。将该度量方式与 KNN 分类器相结合对高光谱图像进行分类,并与已有的相关算法进行对比。

2 算法介绍

2.1 基于加权空-谱距离的相似性度量算法

空间一致性是图像去噪和纹理合成领域近年来提出的一种新思想^[15-16],在高光谱图像中,对于任意像元 $x_{ij} \in R^D$ (x_{ij} 表示在图像中位于第 i 行第 j 列的像元, D 为波段数), 与其空间位置上相邻的像元不仅是频谱相关的,而且是空间相关的,且距离越近,属于同类点的概率就越大。基于

此,本文提出一种新的融合空间信息与光谱信息的相似性度量算法。

假设以像元 x_{ij} 为中心的大小为 $\omega \times \omega$ 的方形空间区域为 $\Omega(x_{ij})$,其中 ω 为奇正整数,称为空间窗口。 $\Omega(x_{ij})$ 为像元 x_{ij} 的近邻空间,其定义为:

$$\Omega(x_{ij}) = \{x_{pq} | p \in [i-a, i+a], q \in [j-a, j+a]\}, \quad (1)$$

其中: x_{pq} 为近邻空间 $\Omega(x_{ij})$ 中的任一像元, $a = (\omega - 1)/2$ 。

对于大小为 $I \times J$ 且波段数为 D 的高光谱图像数据集 $\mathbf{X} \in R^{I \times J \times D}$,任意两像元 x_{ij} 和 x_{st} 间的加权空-谱距离为:

$$d_{WSSD}(x_{ij}, x_{st}) = \|\hat{x}_{ij} - \hat{x}_{st}\|, \quad (2)$$

其中: \hat{x}_{ij} 和 \hat{x}_{st} 分别表示 x_{ij} 和 x_{st} 重构后的像元, \hat{x}_{ij} 的定义为:


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

其中: $\tau_{pq} = e^{-t \|x_{ij} - x_{pq}\|}$, 为近邻空间 $\Omega(x_{ij})$ 中的任一像元 x_{pq} 到中心像元 x_{ij} 的权重, t 为光谱因子,表征了同一近邻空间中不同像元间的相互影响程度。该因子的物理意义为:光谱曲线越相近的像元间的影响就越大,反之影响就越小。此外,当近邻空间中存在与中心像元差别较大的点时(如奇异点),由于光谱因子的存在,该点将会以较小的权重融入到中心像元中。

由式(1)和式(3)可以看出,这种新的相似性度量方式通过空间窗口 ω 来调整近邻空间的大小,引入空间特征;同时,通过光谱因子 t 来调整各像元间的相互影响程度,引入光谱特征。因此, ω 和 t 是本文算法中两个重要的参数。一般来说,它们的选取仅与图像本身有关。对于地物分布较为集中或呈现块状分布的数据集,应选择较大的 ω 和较小的 t ,因为此时近邻空间中像元间的空间关系较为显著,且光谱差异性较小;而对于地物分布比较零散的数据集,则需要选择较小的 ω 来表征较弱的空间关系和较大的 t 值来削弱异类点的影响。

需要说明的是,位于图像边缘或角落的像元,同样可以作为近邻空间的中心来应用加权空-谱距离。当像元 x_{ij} 位于图像的边缘或角落位置时,利用 x_{ij} 自身来填补近邻空间 $\Omega(x_{ij})$ 中空缺的位置。图 1(彩图见期刊电子版)给出了窗口大小为

3×3 时不同情况下像元 x_{ij} 的近邻空间,其中,每一个正方形格子均代表高光谱图像中的一个像元,白色格子为中心像元,深黄色格子表示其边缘填补方式。



(a)正常位置 (b)边缘位置 (c)角落位置
(a) Normal position (b) On the edge (c) At the corner

图 1 不同情况下像元 x_{ij} 的近邻空间

Fig. 1 Neighbor space of pixel under different conditions

2.2 算法复杂度

算法复杂度主要由时间复杂度和空间复杂度两部分组成。对于本文算法,时间复杂度主要来自于图像加权空-谱距离矩阵的计算。由于乘除法运算的资源消耗远大于加减法运算,因此,本文在计算时间复杂度时只涉及乘除法浮点操作。当空间窗口为 $\omega \times \omega$ 时,由公式(2)和(3)可知,计算两个像元间的加权空-谱距离所需的浮点操作次数为 $2D\omega^2 + 2$, D 为光谱波段数。对于一个含有 N 个像元的高光谱图像来说,总的复杂度为 $O(DN^2)$ 。

空间复杂度则主要由算法执行时所需的存储空间来衡量,本文算法的空间复杂度主要取决于 $N \times N$ 的加权空-谱距离矩阵和空间窗口 ω 所带来的大量内存索引操作。因此,较大的数据集和较大的窗口 ω 将带来较高的时间复杂度和空间复杂度。

2.3 WSSD-KNN 算法步骤

基于加权空-谱距离的 KNN 分类算法(WSSD-based KNN Algorithm, WSSD-KNN)的具体步骤为:

输入:含有 $I \times J$ 个 D 维数据点的高光谱图像数据集 $\mathbf{X} \in R^{I \times J \times D}$,训练样本比例为 r ,空间窗口为 ω ,光谱因子为 t ,近邻个数为 k

输出:测试样本的类别

步骤 1:根据参数 r ,从数据集 \mathbf{X} 中随机选取训练样本和测试样本,其中训练样本类别为已知;

步骤 2: 根据式(1)构建所有样本的近邻空间;

步骤 3: 对于原始数据集上的任意两个像元 x_{ij} 和 x_{st} , 根据式(2)计算 $d_{WSSD}(x_{ij}, x_{st})$, 得到图像的加权空-谱距离矩阵, 并在全体测试样本中寻找每个样本的 k 个近邻点;


步骤 4: 与 KNN 算法类似, 根据得到的 k 个已知近邻点信息, 计算属于各类别的权值, 并将测试样本归为权值最大的一类。

3 实验结果及分析

3.1 实验数据集

本实验使用具有代表性的 Indian Pines 和 PaviaU 高光谱数据集来检验算法的分类性能。

(1) Indian Pines 数据集: 该数据集是在 1992 年由 AVIRIS 传感器获取的高光谱图像, 图像为美国 Indiana 州西北方向的一片农田。其大小为 $145 \text{ pixel} \times 145 \text{ pixel}$, 含有 16 类地物信息, 波长范围从 400 nm 到 2 450 nm, 共包含 220 个波段, 去除受大气吸收和噪声影响的波段, 余下的 200 个波段用于实验研究。其假彩色图像和真实地物信息如图 2 所示。




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

图 2 Indian Pines 高光谱图像

Fig. 2 Indian Pines hyperspectral image

(2) PaviaU 数据集: 该数据集是在 2002 年由 ROSIS 传感器获取的位于帕维亚大学区域的高光谱图像。图像的大小为 $610 \text{ pixel} \times 340 \text{ pixel}$, 空间分辨率为 1.3 m, 共包含 115 个光谱波段, 去除其中吸水严重的 12 个波段, 将剩余的 103 个波段用于实验研究。PaviaU 数据集中共包含 9 类地物信息, 其假彩色图像和真实地物信息如图 3 所示。



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

图 3 PaviaU 高光谱图像

Fig. 3 PaviaU hyperspectral image

3.2 实验设置


为评估本文算法的分类性能, 将本文算法与仅使用光谱信息的分类方法和结合了空间信息的分类方法进行对比。其中, 仅使用光谱信息的分类方法包括 KNN、SAM 和 SVM; 为验证 WSSD 算法的有效性, 与结合了空间信息的基于空间相干距离的 KNN 算法 (SCD-based KNN Algorithm, SCD-KNN) 和基于图像块距离的 KNN 算法 (IPD-based KNN Algorithm, IPD-KNN) 进行比较。为使各算法都有较好的效果, 将各算法的参数调整到最佳, 选取 KNN 和 SAM 的近邻数为 1; SVM 的最佳参数通过 10 次交叉验证确定; SCD-KNN 和 IPD-KNN 的窗口大小均设置为 13×13 。

本文使用总体精度 (Overall Accuracy, OA)、平均精度 (Average Accuracy, AA) 和 kappa 系数作为评价指标。为提高实验的精确度和可靠性, 将每种算法重复运行 10 次, 每次随机选取一定比例的训练样本, 其余为测试样本, 将 10 次实验的分类精度求平均值得到最终结果。

3.3 Indian Pines 实验结果及分析


对于本文提出的 WSSD-KNN 算法, 一个关键性的问题就是如何选取合适的空间窗口 ω 和光谱因子 t 。本实验通过分析 ω 和 t 取不同值时对分类精度的影响, 从中选出最优值。从 Indian Pines 数据集中每类地物随机选取 10% 作为训练样本, 剩余为测试样本, 其中, 为保证小样本类别的分类性能, 对于样本数目不足 100 的类别, 本文

统一选取 10 个训练样本。设置选取近邻数为 1, 空间窗口 ω 和光谱因子 t 对分类精度的影响如图 4 所示,当分析 ω 对分类精度的影响时, t 设置为 2, 同样地,当分析 t 时, ω 设置为 13。



(a) 空间窗口

(a) Spatial window



(b) 光谱因子

(b) Spectral factor

图 4 Indian Pines 数据集在不同参数 ω, t 下的分类精度
Fig. 4 Classification accuracy of Indian Pines data set with different parameters ω and t

由图 4 可知,空间窗口和光谱因子的大小会对算法的分类性能产生一定影响,它们的取值过大或过小都会使得算法分类精度降低。当 ω 和 t 过大时,近邻空间中异类地物的干扰加强,而同类地物的权重也因 t 值的增大而被削弱,使得算法分类精度下降。反之,当 ω 和 t 过小时,近邻空间中包含的空间信息不足,同时,过小的 t 值也使得异类地物的权重有所增大,导致分类效果不佳。对于 Indian Pines 数据集, $\omega=13$ 和 $t=2$ 为其最佳取值。

为验证本文算法的有效性,实验中每类地物

随机抽取一定比例的样本作为训练样本,剩余样本用于测试,然后使用各算法进行分类。图 5 给出了不同算法在不同训练样本比例下的总体分类精度(图中竖线表示标准差)。




图 5 不同算法在不同训练样本比例 r (%)下的总体精度
Fig. 5 Overall accuracy of different algorithms with different number of training samples

由图 5 可得,随着训练样本比例的不断增加,各算法的分类精度均不断提高,这是因为训练样本的数量越多,数据中所能提供的具有代表性的先验信息就越多,鉴别性能更为突出,分类精度也就更高。SCD-KNN 和 IPD-KNN 算法都比 KNN 算法分类效果好,这是因为空-谱联合分类方法较好地利用了图像中蕴含的丰富的空间信息,从而改善了算法的鉴别能力,提升了分类精度。但在各种比例下,WSSD-KNN 比其他算法的分类效果都好,由于 WSSD 不仅利用图像空间-光谱信息,同时还较好地保持了中心像元及其周围点的局部空间结构,增强了同类像元之间的相似性和异类像元之间的差异性,分类性能更好,且在样本比例较小时,仍能保持较高的分类精度。对于 Indian Pines 数据集,当训练样本比例仅为 5% 时,该算法的分类精度便可达到 85% 以上。

为比较各算法对每类地物的分类性能,实验中对于每类地物随机选取 10% 作为训练样本,其余作为测试样本,表 1 为各类地物的分类精度、总体精度(OA)、平均精度(AA)、kappa 系数以及运行时间。从表 1 可以看出,对于大多数类别的地物特征,本文算法的分类精度都有明显提升,且相关性较大的地物分类效果的改进尤为显著,如

Soybeans-notill、Soybeans-min 和 Soybeans-clean 这 3 类地物;同时,WSSD-KNN 算法的 OA,AA 和 kappa 系数均比其他算法好。这是由于 WSSD 较为有效地消除了图像中的冗余信息,增强了同

类数据间的相似性和不同类数据间的差异性,鉴别性能更突出,分类效果更好;此外,本文算法的运行时间较其他算法并没有显著增加,且远小于 SCD-KNN 和 IPD-KNN 的运行时间。

表 1 Indian Pines 数据集中各类地物在不同算法下的分类精度 (%)

Tab.1 Classification accuracy of different types of features in Indian Pines data set by different algorithms

#	类别	训练样本	测试样本	KNN	SAM	SVM	SCD-KNN	IPD-KNN	WSSD-KNN
1	Alfalfa	10	36	69.44	66.67	94.44	77.78	88.89	97.22
2	Corn-notill	143	1285	50.04	50.82	77.74	65.60	76.89	86.61
3	Corn-min	83	747	54.35	55.69	68.54	63.05	81.79	86.35
4	Corn	24	213	42.72	40.85	56.81	47.42	86.38	73.71
5	Grass/Psature	48	435	82.30	85.75	92.18	92.87	95.86	86.90
6	Grass/Tress	73	657	88.74	88.89	96.35	98.48	98.17	98.02
7	Grass/psature-mowed	10	18	88.89	94.44	77.78	94.44	100	100
8	Hay-windrowed	48	430	89.30	88.60	96.51	98.37	99.77	100
9	Oats	10	10	70.00	80.00	100	100	100	100
10	Soybeans-notill	97	875	66.51	67.20	74.29	80.57	89.14	93.49
11	Soybeans-min	246	2209	68.54	71.03	82.71	80.08	88.64	93.80
12	Soybeans-clean	59	534	38.95	40.82	72.28	51.12	73.97	77.90
13	Wheat	21	184	89.67	88.04	95.65	98.91	99.46	98.91
14	Woods	127	1138	91.83	92.53	95.52	89.10	97.72	99.38
15	Bldg-Grass-Tree-Drives	39	347	41.50	44.38	55.62	38.62	75.22	88.76
16	Stone-steel towers	10	83	87.95	90.36	91.57	87.95	100	98.80
	总体精度(OA)			67.86	69.14	81.88	77.10	88.10	91.72
	平均精度(AA)			70.05	71.63	83.00	79.02	90.74	92.49
	kappa 系数			0.6331	0.6476	0.7929	0.7379	0.8642	0.9055
	运行时间(s)			21.60	51.06	85.23	164.63	200.36	57.51




图 6 各算法在 Indian Pines 数据集上的分类结果图

Fig. 6 Classification accuracy of different algorithms in Indian Pines data set

图 6(彩图见期刊电子版)为各算法对 Indian Pines 数据集的分类结果,从图中可以看出,与其他算法相比,本文方法得到的分类图的大部分区域更加平滑,总体上看错分点更少,尤其是在 Soybeans-notill 地物区域的表现更为突出。这表明 WSSD-KNN 算法对各类地物的分类效果比其他大部分算法都好,同时提高了地物的总体分类

精度。

3.4 PaviaU 实验结果及分析

在 PaviaU 数据集中,每类随机选取 6% 样本作为训练样本,其余为测试样本,使用与 Indian Pine 数据集相同的参数检验方法,得到该数据集的合理取值为:空间窗口 $\omega=15$,光谱因子 $t=1$ 。

图 7 给出了不同算法在不同训练样本比例下




图 7 不同算法在不同训练样本比例 r (%)下的总体精度
Fig. 7 Overall accuracy of different algorithms with different number of training samples

的总体分类精度。由图 7 可知,随着训练样本比例的不断增加,各算法的分类精度也不断提高;但在各种比例下,WSSD-KNN 均比其他算法的分类效果好,且当训练样本比例较小时,本文算法仍能保持较高的分类精度。

表 2 给出了各算法的分类结果及相应的运行时间,其对应的分类图如图 8 所示。由表 2 可知,本文方法对大部分地物的分类精度、总体精度、平均精度和 kappa 系数都比其他算法好,且得到的分类图中错分点更少,地物分布更加平滑,而且算法运行时间并没有显著增加,再次证明了本文算法的实用性和可行性。

表 2 PaviaU 数据集中各类地物在不同算法下的分类精度 (%)

Tab. 2 Classification accuracy of different types of features in PaviaU data set by different algorithms

#	类别	训练样本	测试样本	KNN	SAD	SVM	SCD-KNN	IPD-KNN	WSSD-KNN
1	Asphalt	398	6233	85.62	75.76	94.64	92.73	96.33	92.40
2	Meadows	1119	17530	94.73	95.09	98.21	97.45	98.24	99.46
3	Gravel	126	1973	64.93	58.95	76.69	82.11	87.23	93.87
4	Trees	184	2880	78.33	81.91	92.33	82.22	90.69	91.18
5	Sheets	81	1264	99.13	99.76	99.45	99.92	100	99.53
6	Soil	302	4727	59.97	52.08	84.62	62.64	83.31	94.84
7	Bitumen	80	1250	76.96	76.72	77.92	91.36	94.16	96.16
8	Bricks	221	3461	78.68	78.76	88.21	90.78	93.30	96.16
9	Shadows	57	890	100	92.36	100	99.66	100	98.99
总体精度(OA)				84.92	82.43	93.17	90.15	94.65	96.56
平均精度(AA)				82.04	79.04	90.23	88.76	93.69	95.84
kappa 系数				0.796 8	0.763 0	0.908 8	0.866 9	0.928 5	0.954 2
运行时间(s)				128.84	290.61	141.04	1 228.84	1 767.35	338.78




图 8 各算法在 Pavia U 数据集上的分类结果图
Fig. 8 Classification results of different algorithms in PaviaU data set

4 结 论

本文提出了一种简单有效的基于加权空-谱距离的相似性度量算法并将其应用于最近邻分类器。该方法结合高光谱图像的物理特性,通过引入空间窗口和光谱因子更好地消除了图像中的冗余信息,提取出更为有效的鉴别特征。在 Indian Pines 和 PaviaU 高光谱数据集上的实验结果表明,相比已有的相关算法,本文方法取得的分类效果更好,对地物分类精度有较大改善,且当训练样

本数较少时,分类性能提升尤为明显。在总体分类精度上,本文算法比单一的光谱分类器提升了约 3.39%~23.86%,比 SCD-KNN 和 IPD-KNN 等算法提升了约 1.91%~14.62%。

但是本文算法在重构中心像元时存在引入异类地物的风险,虽然可以通过调节光谱因子来削弱该影响,但对于分布过于密集的区域,其近邻空间中存在较多的异类地物,此时空间信息的引入反倒易造成错误分类。对此,可以考虑通过结合单一像元分类或采用后处理方式等进行补偿,这些都是将来需要研究解决的工作。

参考文献:

- [1] 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)
- [2] 张达,郑玉权. 高光谱遥感的发展与应用[J]. 光学与光电技术, 2013, 11(3): 67-73.
ZHANG D, ZHENG Y Q. The development and application of hyperspectral remote sensing[J]. *Optical and Photoelectric Technology*, 2013, 11(3): 67-73. (in Chinese)
- [3] 唐中奇,付光远,陈进,等. 基于多尺度分割的高光谱图像稀疏表示与分类[J]. 光学 精密工程, 2015, 23(9): 2708-2714.
TANG ZH Q, FU G Y, CH J, *et al.*. Multiscale segmentation-based sparse coding for hyperspectral image classification [J]. *Opt. Precision Eng.*, 2015, 23(9): 2708-2714. (in Chinese)
- [4] FAUVEL M, TARABALKA Y, BENEDIKTS-SON J A, *et al.*. Advances in spectral-spatial classification of hyperspectral images[J]. *Proceedings of the IEEE*, 2013, 101(3): 652-675.
- [5] 黄鸿,曲焕鹏. 基于半监督稀疏鉴别嵌入的高光谱遥感影像分类[J]. 光学 精密工程, 2014, 22(2): 434-442.
HUANG H, QU H P. Hyperspectral remote sensing image classification based on SSDE[J]. *Opt. Precision Eng.*, 2014, 22(2): 434-442. (in Chinese)
- [6] MA L, CRAWFORD M M, TIAN J W. Local manifold learning-based k-Nearest-Neighbor for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2010, 48(11): 4099-4109.
- [7] SHAFRI H Z M, SUHAILI A, MANSOR S. The performance of maximum likelihood, spectral angle mapper, neural network and decision tree classifiers in hyperspectral image analysis[J]. *Journal of Computer Science*, 2007, 3(6): 419-423.
- [8] GUO B F, GUNN S R, DAMPER R I, *et al.*. Customizing kernel functions for SVM-based hyperspectral image classification[J]. *IEEE Transactions on Image Processing*, 2008, 17(4): 622-629.
- [9] 郭敬明,何昕,魏仲慧. 基于在线支持向量机的 Mean Shift 彩色图像跟踪[J]. 液晶与显示, 2014, 29(1): 120-128.
GUO J M, HE X, WEI ZH H. New mean shift tracking for color image based on online support vector machine [J]. *Chinese Journal of Liquid Crystals and Displays*, 2014, 29(1): 120-128. (in Chinese)
- [10] 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.
WEI F, HE M Y, MEI SH H. Hyperspectral data feature extraction using spatial coherence based neighborhood preserving embedding[J]. *Infrared and Laser Engineering*, 2012, 41(5): 1249-1254. (in Chinese)
- [11] VELASCO F S, MANIAN V. Improving hyperspectral image classification using spatial preprocessing[J]. *IEEE Geoscience and Remote Sensing Letters*, 2009, 6(2): 297-301.

- [12] 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.
- [13] MOHAN A, SAPIRO G, BOSCH E. Spatially coherent nonlinear dimensionality reduction and segmentation of hyperspectral images[J]. *IEEE Geoscience and 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] KANG X D, LI S T, BENEDIKTSSON J A. Spectral-Spatial hyperspectral image classification with Edge-Preserving Filtering[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(5): 2666-2677.
- [16] YUAN H L, TANG Y Y, LU Y, *et al.*. Spectral-Spatial classification of hyperspectral image based on discriminant analysis[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(6): 2035-2043.

作者简介:



黄 鸿(1980-),男,湖南新宁人,博士,副教授,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



郑新磊(1992-),男,山东滨州人,硕士研究生,2014年于重庆大学获得学士学位,主要从事图像处理、遥感影像分类、嵌入式系统等方面的研究。E-mail: zhengxl@cqu.edu.cn