

基于空谱加权近邻的高光谱图像分类算法

纪磊¹, 张欣^{1*}, 张丽梅², 文章¹

¹贵州大学大数据与信息工程学院, 贵州 贵阳 550025;

²重庆大学光电工程学院, 重庆 400044

摘要 现有的高光谱图像分类方法多注意到空间信息的利用,并未考虑地物在空间分布上具有连续性的特点。基于此,提出了一种空谱加权近邻(SSWNN)高光谱图像分类算法。通过构造测试样本点的近邻空间,过滤近邻空间中与测试样本标签不一致的空间近邻点,有效解决了近邻空间内异类点对中心像元分类的干扰,改善了图像的椒盐效应。根据空间近邻点和测试像元之间的光谱相似性为空间近邻点赋予不同的权重,增大了同类像元间的相似性和异类像元间的差异性,并通过引入正则化系数,得到训练样本和测试样本近邻空间的距离,选择距离最小的训练样本标签作为测试样本的标签。该方法在 Indian Pines 和 PaviaU 高光谱数据集上的总体分类精度分别达到了 96.75% 和 98.54%,高于文中所列的其他算法。

关键词 高光谱图像; 图像分类; 近邻空间; 背景点; 椒盐效应; 正则化系数

中图分类号 TP751

文献标志码 A

doi: 10.3788/LOP57.061013

Hyperspectral Image Classification Algorithm Based on Space-Spectral Weighted Nearest Neighbor

Ji Lei¹, Zhang Xin^{1*}, Zhang Limei², Wen Zhang¹

¹ College of Big Data and Information Engineering, Guizhou University, Guiyang Guizhou 550025, China;

² College of Optoelectronic Engineering, Chongqing University, Chongqing 400044, China

Abstract Existing hyperspectral image classification methods focus on using spatial information without considering the continuity of ground object in spatial distribution. Based on this, this paper proposes a space-spectrum weighted nearest neighbor hyperspectral image classification algorithm. By constructing the neighboring space of the test sample points, the spatial neighboring points in the neighboring space that are inconsistent with the test sample labels are filtered to further remove the interference of heterogeneous points in the neighboring space towards the classification of central pixels and improve salt and pepper effect. According to the spectral similarity between the spatial neighbors and the test pixels, different weights are assigned to the spatial neighboring points, which increases the similarity between similar pixels and the difference between the heterogeneous pixels. The distance between the training sample and the test sample neighboring space is obtained by introducing the regularization coefficient, and the training sample label with minimum distance is selected as the label of the test sample. The overall classification accuracies by this method on the Indian Pines and PaviaU hyperspectral datasets reach 96.75% and 98.54%, respectively, which are higher than those by other algorithms listed in the paper.

Key words hyperspectral image; image classification; spatial neighbor; background point; salt and pepper effect; regularization coefficient

OCIS codes 100.3008; 100.4145; 110.4234

收稿日期: 2019-08-23; 修回日期: 2019-09-07; 录用日期: 2019-09-15

基金项目: 中国国家国际科技合作专项(2014DFA00670)、国家自然科学基金(61741505,61865002)、贵州省研究生教育教学改革重点课题(黔教研合 JG 字[2016]15)

* E-mail: xzhang1@gzu.edu.cn

1 引言

高光谱遥感技术是一种多融合的综合技术^[1-3],包含探测器技术、精密光学机械、微弱信号检测、计算机和信息处理等多种技术,广泛应用于多个领域中^[4-5]。因高光谱图像相比传统光谱图像搭载的光波信息更多,所以利用高光谱图像进行地物的精细辨识与归类更具研究前景。高光谱图像不仅包含丰富的地物光谱信息,还具备大量的空间信息,高光谱图像分类算法^[6-7]根据其利用的信息特征大致可分为两类。

第一类为仅利用高光谱图像光谱信息的图像分类方法。文献[8]以待测样本与 k 个光谱距离最近的测试样本点中数量最多的那类测试样本作为待测样本点的类别,提出了最近邻(KNN)分类法。文献[9]为对实现高光谱小样本目标的精细分类,提出了一种基于多特征和改进稀疏表示(SRC)模型的分类方法。但该算法只发挥了光谱信息的作用,并未充分挖掘像元空间之间的关系,因而分类精度有待提高。支持向量机(SVM)算法^[10-11]是一种主要通过核进行分类,以统计学习理论为基础的模式识别方法。通过增加特殊样本的学习环节,极大缩小了计算量。但该算法依托于对大量样本的标记,样本量越大,地物差异特征越明显,而标记样本的需求在实际工程中往往难以实现。当输入为光谱和纹理特征时,SVM算法也为空谱联合特征分类,因本算法的输入仅为光谱信息,故将 SVM 算法加入对比讨论。

第二类为融合高光谱图像光谱信息与空间信息的空谱联合图像分类方法。不仅利用了像元的光谱信息,还利用了地物分布的空间连续性特征^[12],将空间上距离近的像元点划分为同类。文献[13]提出了一种基于投票式的多分类器联合方法。为充分考虑像元局部空间结构,文献[14]提出一种基于加权空谱距离(WSSD)的相似性度量算法,利用像元的空间近邻对其进行重构,进一步描述中心像元与近邻空间的信息,提高了分类精度,但对中心像元进行重构的同时存在引入异类地物的风险。

针对上述问题,本文提出了一种基于空谱加权近邻(SSWNN)的高光谱图像分类方法。其核心思想是利用地物在空间分布上具有连续性的特点,构造待测样本点的近邻空间,过滤近邻空间中与测试样本点标签不一致的空间近邻点。可有效滤除近邻空间中的异类点以及图像中随机出现的黑色、白色

像素点,即椒盐噪声^[15-16],进而达到抑制椒盐效应^[17]的效果。根据空间近邻点和测试像元的光谱相似性给空间近邻点赋予不同的权值(未引入加权地物空谱最近邻(SSNN)),增大了同类像元间的相似性和异类像元间的差异性。最后通过引入正则化系数^[18-19],计算训练样本点和测试样本点邻域块的距离,选择距离最小的训练样本点标签作为测试样本点的标签。

2 算法介绍

近年来,图像去噪和纹理合成领域,多使用图像空间信息与光谱信息相结合的方式。假定高光谱图像中高光谱数据集为 $X \in R^D$ (D 为高光谱图像的维度),图像中的训练样本点为 $x_{ij} \in R^D$,图像中的测试样本点为 $y_{ij} \in R^D$ (i 为图像的横坐标, j 为图像的纵坐标)。对于某一个测试样本点,在空间上与其近邻像元的光谱和空间都是相关的,距离越近,越有可能是同类点。根据光谱相似性给近邻点赋予不同的权重突出特征,提出了一种基于空间信息与光谱信息相结合的加权近邻高光谱图像分类方法。

2.1 椒盐效应的抑制

以 y_{ij} 为中心像元点,构造方块尺寸为 $\omega \times \omega$ 的近邻空间, ω 为空间窗口,且为正奇数。将 y_{ij} 的近邻空间表示为

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

式中, y_{pq} 为近邻空间 $\Omega(y_{ij})$ 中除中心像元点外的空间近邻点, $a = (\omega - 1)/2$ 为邻域块的半径。

在高光谱图像中,由于同类地物空间分布具有连续性,所以同一近邻空间中的一部分近邻点和中心像元点的性质接近。但是处于图像边缘上的像元,其近邻点以及图像中随机出现的椒盐噪声在很大概率上和中心像元点不属于同一类别。为解决该问题,提高地物的分类精度,需要去掉和中心像元性质差异较大的点(背景点)。在近邻空间 $\Omega(y_{ij})$ 中,过滤掉背景点之后的近邻空间可表示为

$$N(y_{ij}) = \{y_{pq} \mid X_{\text{label}}(y_{pq}) = X_{\text{label}}(y_{ij}), y_{ij} \in \Omega, y_{pq} \in \Omega\}, \quad (2)$$

式中, $X_{\text{label}}(y_{pq}) = X_{\text{label}}(y_{ij})$ 表示和中心像元点标签相同的空间近邻点,如果 y_{pq} 的标签与 y_{ij} 的标签相同,说明它们性质相近,属于同一类地物,则保留该近邻像素点;反之去除该近邻像素点。

图 1 为近邻空间过滤背景点的过程。如图 1(a) 所示,从一幅高光谱图像中随机选取一个样本

点;找到其近邻空间,如图 1(b)所示;以 3×3 的邻域块为例,判断周围近邻点的标签与中心点的标签是否相同,图中灰色方块代表和中心像素点标签不相同的近邻点,如图 1(c)、(d)所示;最终得到




图 1 过滤背景点过程。(a)原始图像;(b)随机样本点;(c)非近邻样本点;(d)处理非近邻样本点;(e)过滤后的样本点

Fig. 1 Process of removing background point. (a) Original image; (b) random sample points; (c) non-nearest neighbor sample points; (d) processing non-nearest neighbor sample points; (e) filtered sample points

2.2 SSWNN 算法

将近邻(NN)算法应用到高光谱图像分类中,利用图像数据点之间的光谱信息计算测试样本点和训练样本点之间的光谱距离,可表示为

$$d(y_{ij}; x_{ij}) = \| y_{ij} - x_{ij} \|_2^2. \quad (3)$$

式中, $\| \cdot \|_2^2$ 代表取向量的 2 范数的平方, d 的值越小,测试样本点和训练样本点的光谱相似性越高,属于同类点的概率越大;反之,光谱相似性越低,属于同类点的概率越小。

传统的 NN 算法分类精度不高,原因是只利用了图像的光谱信息,没有利用图像的空间信息。因此提出了一种基于空谱加权近邻的图像分类算法,通过引入过滤背景点后的近邻空间进行分类,可表示为

$$d(y_{ij}) = \| \mathbf{N}(y_{ij})\boldsymbol{\alpha} - x_i \|_2^2, \quad (4)$$

式中, x_i 为中心像素点, $\mathbf{N}(y_{ij})$ 为去除背景点之后的近邻空间,通过引入正则化系数 $\boldsymbol{\alpha} = [\mathbf{N}(y_{ij})^T \mathbf{N}(y_{ij})]^{-1} \mathbf{N}(y_{ij})^T x_i$, T 为转置运算符号,实现点到近邻空间距离的求解。

为进一步提高地物分类精度,引入加权矩阵优化上述函数,可表示为

$$d(y_{ij}) = \| \mathbf{W}\mathbf{N}(y_{ij})\boldsymbol{\alpha} - x_i \|_2^2, \quad (5)$$

式中, $\mathbf{W} = \{\omega_{pq}\}$ 为近邻空间 $\mathbf{N}(y_{ij})$ 中的所有像元 y_{pq} 到中心像素点 y_{ij} 的权重集合, $\omega_{pq} = \exp(-\| y_{ij} - y_{pq} \|_2^2)$, $y_{pq} \in \mathbf{N}(y_{ij})$, $y_{ij} \in \mathbf{N}(y_{ij})$, ω_{pq} 为 $\mathbf{N}(y_{ij})$ 中任意一像元 y_{pq} 到中心像素点 y_{ij} 的权重。

ω 越大,说明空间近邻点与中心像素点性质越接近; ω 越小,说明空间近邻点与中心像素点的性质差异越大。因此,根据与中心像素点性质相似性的大小给邻域块中的近邻点赋予不同的权重。最终得到测试样本点的标签,可表示为

过滤背景点之后的近邻空间,如图 1(e)所示。通过过滤除和中心像元性质差距过大的点,在后续的分类过程中引入该近邻空间,可有效提高地物的分类精度。

$$X_{\text{label}}(y) = \operatorname{argmin}[d_i(y_{ij})], i = 1, \dots, m, \quad (6)$$

式中, m 为总的地物类数,选择与测试样本近邻空间距离最近的训练样本标签作为测试样本的标签。

2.3 SSWNN 算法步骤

基于空谱加权近邻算法的步骤:

- 1) 输入数据集 $X \in R^D$, 训练样本集 $x_{ij} \in R^D$, 测试样本集 $y_{ij} \in R^D$, 空间窗口为 ω 。从数据集中选取不同比例的训练样本和测试样本,且训练样本类别已知;
- 2) 根据(1)式构建所有样本的近邻空间;
- 3) 根据(2)式过滤近邻空间中的背景点,改善椒盐效应;
- 4) 根据权重公式计算近邻点到中心像元点的权重;
- 5) 根据(5)式求得近邻空间到训练样本的距离;
- 6) 计算测试样本点的标签,选择与测试样本近邻空间距离最近的训练样本的标签作为测试样本的标签,输出测试样本的类别。

3 实验结果及分析

3.1 实验数据集

使用经典的 Indian Pines 和 PaviaU 高光谱图像数据集进行实验。

- 1) Indian Pines 数据集是 1992 年通过 AVIRIS 拍摄的高光谱图像,其内容为美国西北部 Indiana 地区部分区域。数据集集中的图像尺寸为 $145 \text{ pixel} \times 145 \text{ pixel}$,共覆盖 $0.4 \sim 0.25 \mu\text{m}$ 的波段范围,包含 220 个波段,空间分辨率为 20 m/pixel ,剔除掉因水汽吸收和噪声等影响的 20 个波段,用剩下的 200 个波段进行实验,包括森林、道路、植被和房屋等 16 类

不同的地物。图 2 分别为该数据集的假彩色图、地物类型调查图及各类地物的光谱曲线图。

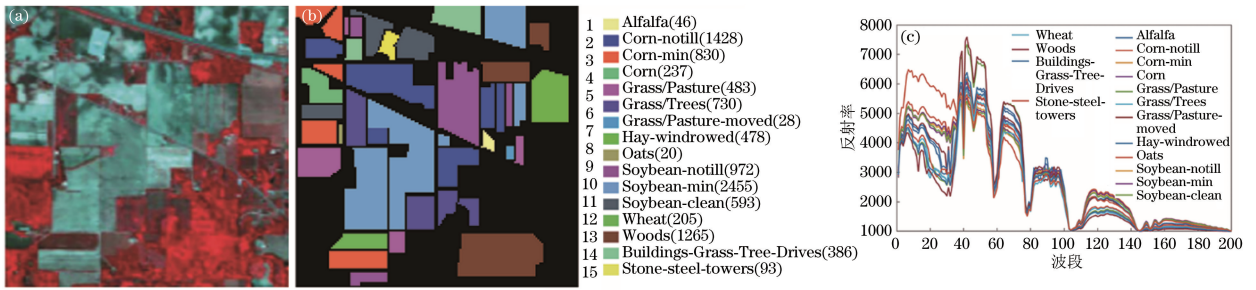


图 2 Indian Pines 数据集。(a)假彩色图;(b)地物类型调查图;(c)光谱曲线图^[14]

Fig. 2 Indian Pines dataset. (a) False-color image; (b) ground-type survey map; (c) spectral curves^[14]

2) PaviaU 数据集是 1992 年利用 ROSIS 获取的高光谱图像,其内容为意大利北部的 Pavia 大学区域,图像尺寸为 610 pixel×340 pixel,总计有 115 个不同的波段,覆盖了 0.43~0.86 μm 的光谱范围,空间分辨率达

1.3 m,包括房屋、道路和树木等 9 类不同的地物。剔除掉受光照和噪声影响的 12 个波段,用剩下的 103 个波段的数据集进行实验。图 3 分别为 PaviaU 数据集的假彩色图、地物类型调查图和光谱曲线图。

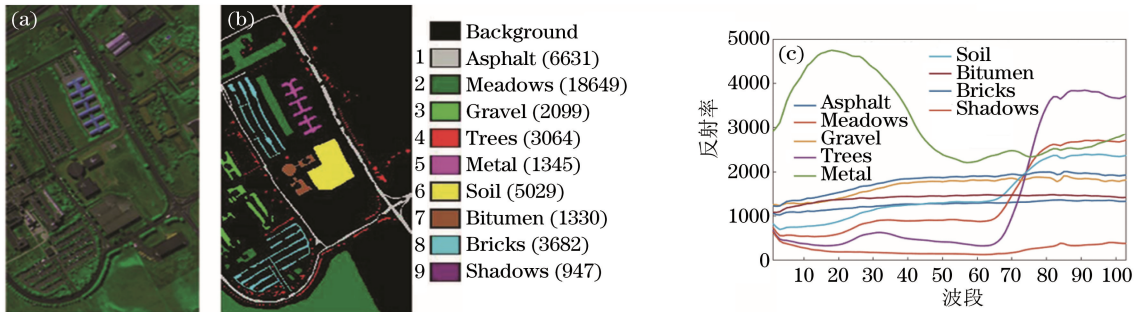


图 3 PaviaU 数据集。(a)假彩色图;(b)地物类型调查图;(c)光谱曲线^[14]

Fig. 3 PaviaU dataset. (a) False-color image; (b) ground-type survey map; (c) spectral curves^[14]

3.2 实验设置

为测试本算法的性能,将其与四种现有算法进行对比。其中 NN、SRC 和 SVM 是仅利用图像光谱信息的算法,WSSD-KNN 是融合了空间信息的算法。为使算法的性能达到最佳,SVM 采用高斯内核;设置 SRC 的残差为 0.9;根据文献[14],WSSD-KNN 的窗口大小设置为 13×13,光谱因子设置为 1。

使用总体精度(OA),平均精度(AA)以及 Kappa 系数作为高光谱图像分类精度的评价指标。其中 OA 表示正确分类的像元数与总像元数之比;AA 为所有地物的平均分类精度;Kappa 系数表示随机分类产生错误的减少比例。OA、AA 和 Kappa 系数值越大,代表分类精度越高。为减少实验误差,随机选取一定比例的训练样本,重复进行 10 次实验,计算所有实验结果的平均值作为最终结果。

3.3 Indians Pines 数据集实验结果分析

ω 是 SSNN 和 SSWNN 算法中至关重要的一个参数,选择一个合适的空间窗口 ω 能使算法效果

达到最好。为选择最佳的空间窗口,测试了在不同窗口下的 OA 值,结果如图 4 所示。其中,在 Indians Pines 数据集中设置训练样本的比例为 10%,其余为测试样本。




图 4 不同窗口下 Indian Pines 数据集的 OA
Fig. 4 OA of Indian Pines dataset with different spatial windows

由图 4 可知,算法选取不同的 ω 产生的 OA 值也有很大的差异,且对本算法的精度具有较大的影响。图中两种算法的 OA 值均呈现先上升后下降的趋势,当 $\omega = 5$ 时,两种算法的 OA 值均达到最大

值,所以后续两种算法均选取 $\omega=5$ 进行实验。

不同的样本比例也会对实验精度产生较大的影响,为寻找合适的样本比例使实验效果达到最佳,图 5 给出了各算法在不同样本比例下的 OA 值。




图 5 不同训练样本比例下各算法的 OA

Fig. 5 OA of different algorithms with different percentages of training samples

由图 5 可知,在相同的样本比例下,不同算法对于 OA 值有不同的影响。随着样本比例的增加,六种算法的 OA 值均呈现上升趋势,原因是随着样本数量的增加,数据中可用信息越来越多,鉴别性能更加突出,所以分类精度会随着样本比例的增加而提高。当选取样本比例大于 8% 时,各算法的上升趋势都趋于平缓,若继续增大样本比例,则会严重增加算法时间,综合考虑,选取样本比例为 10% 进行后续实验。

由图 5 可知, WSSD-KNN、SSNN 和 SSWNN

算法均比传统的 NN 算法分类精度高,这是由于几种算法均引入了空间信息,较好地利用了图像中的空间信息提高算法鉴别能力。同时, SSNN 和 SSWNN 算法在不同样本比例下的分类精度均比其他算法高,因为 SSNN 和 SSWNN 算法过滤了图像中的背景点,并改变了传统算法利用距离求解的方式,突出了有效的鉴别特征。SSWNN 根据近邻空间中空间近邻点与中心像元的光谱相似性,引入了权重,进一步提高了 SSNN 的分类精度。如在 Indians Pines 数据集中,当 $\omega=5$, 样本比例为 10% 时, SSNN 和 SSWNN 算法的分类精度分别能达到 96.04% 和 97.47%。

为比较各算法对 Indians Pines 数据集中每类地物的分类精度,每类地物选取 10% 的训练样本。表 1 为各算法对每类地物的 OA、AA 以及 Kappa 系数值。从表 1 可以看出,所提出的 SSNN 和 SSWNN 算法对大部分地物的分类精度均有明显提高,且 SSWNN 算法的分类精度更高,对特征相关性较大的地物,分类精度提升尤为明显,如 Corn-notill、Corn-min 以及 Corn 这三类地物。同时,两种算法的 OA、AA 和 Kappa 系数均高于文中其他算法,且 SSWNN 算法各指标最高。由于 WSSD-KNN 算法的实验结果是基于自身条件的,所以与原文献实验结果有细微差别。

表 1 Indian Pines 数据集中各种算法在不同类别中的分类精度

Table 1 Classification accuracy of different classes in Indian Pines dataset for different algorithms

Grade	Category	Training sample set	Test sample set	Classification accuracy / %					
				NN	SRC	SVM	WSSD-KNN	SSNN	SSWNN
1	Alfalfa	10	36	48.28	55.56	69.44	92.11	97.22	100.00
2	Corn-notill	143	1285	58.86	55.98	72.13	89.13	94.17	98.24
3	Corn-min	83	747	51.47	54.03	69.23	84.14	93.84	94.55
4	Corn	24	213	44.15	41.40	57.61	82.76	88.00	99.00
5	Grass/Pasture	48	435	85.30	82.37	86.71	97.03	100.00	98.82
6	Grass/Tress	73	657	84.30	79.92	90.61	98.31	93.94	96.98
7	Grass Pasture mowed	10	18	50.00	60.61	69.23	69.23	76.67	80.77
8	Hay-windrowed	48	430	91.29	93.10	96.52	100.00	98.62	100.00
9	Oats	10	10	16.67	14.29	38.46	62.50	65.22	63.16
10	Soybean-notill	97	875	59.55	58.39	73.99	87.76	95.27	95.74
11	Soybean-min	246	2209	69.40	69.54	81.82	92.36	95.29	96.02
12	Soybean-clean	59	534	48.35	46.72	79.22	82.99	91.62	96.17
13	Wheat	21	184	85.43	86.44	94.27	98.92	94.59	94.38
14	Woods	127	1138	90.54	89.05	93.80	97.82	99.12	97.09
15	Buildings-Grass-Tree-Drives	39	347	40.94	51.44	63.95	91.88	98.18	99.37
16	Stone-steel-towers	10	83	96.34	98.68	98.65	98.80	93.24	94.74
	OA			68.70	68.71	80.66	91.74	95.31	96.75
	AA			63.80	64.84	77.23	89.11	92.19	94.06
	Kappa			0.643	0.642	0.780	0.906	0.947	0.963




图 6 各算法在 Indian Pines 数据集的分类结果。(a) NN;(b) SRC;(c) SVM;(d) WSSD-KNN;(e) SSNN;(f) SSWNN
 Fig. 6 Classification results of different algorithms in Indian Pines dataset. (a) NN; (b) SRC; (c) SVM; (d) WSSD-KNN; (e)SSNN; (f) SSWNN

图 6 为在 Indian Pines 数据集上的分类结果, 可以发现, 引入空间信息的算法比仅利用图像光谱信息的算法分类精度更高。所提出的两种算法与同样引入空间信息的 WSSD-KNN 算法相比, 分类结果图更加平滑, 且错分点更少, 对高光谱图像的分类效果更好, 特别是在地物 Corn 区域更为明显。

3.4 PaviaU 数据集实验结果分析

为选择最佳的空间窗口, 测试了在不同窗口下的 OA 值, 结果如图 7 所示。其中, 选取 10% 为训练样本, 剩余的为测试样本。

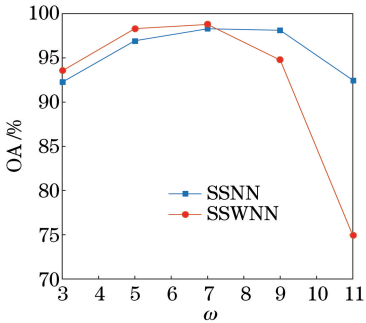


图 7 不同窗口下 PaviaU 数据集的 OA

Fig. 7 OA of PaviaU dataset with different spatial windows

由图 7 可知, 两种算法的 OA 值均呈现先上升后下降的趋势, 当 $\omega=7$ 时, 两种算法的 OA 值均达到最大值, 所以实验中选取 $\omega=7$ 。

各算法在不同样本比例下的 OA 值如图 8 所示, 其中, 当选取样本比例大于 8% 时, 各算法的上升趋势均趋于平缓, 类似于 Indian Pines 数据集, 所以实验在 PaviaU 数据集中同样选取 10% 的样本比例。可以发现 SSNN 和 SSWNN 算法在各样本比例下均比其他算法分类精度高, 尤其当 $\omega=7$, 样本比例为 10% 时, 分类精度分别达到了 98.39% 和 99.13%。




图 8 不同算法在不同训练样本比例下的 OA

Fig. 8 OA of different algorithms with different percentages of training samples

表 2 PaviaU 数据集中各类地物在不同算法下的分类精度

Table 2 Classification accuracy of different classes in PaviaU dataset for different algorithms

Grade	Category	Training sample set	Test sample set	Classification accuracy / %					
				NN	SRC	SVM	WSSD-KNN	SSNN	SSWNN
1	Asphalt	398	6233	91.61	93.13	93.09	97.91	100.00	99.64
2	Meadows	1119	17530	87.79	87.09	93.23	97.73	99.90	99.49
3	Gravel	126	1973	65.98	65.74	84.46	96.51	61.76	97.11
4	Trees	184	2880	94.34	94.97	95.35	99.57	98.77	97.82
5	Sheets	81	1264	99.42	99.75	99.26	99.59	99.91	96.52
6	Soil	302	4727	71.82	71.93	87.65	96.47	99.78	99.49
7	Bitumen	80	1250	69.08	68.04	87.57	91.46	77.68	98.18
8	Bricks	221	3461	65.22	66.95	79.19	93.68	96.08	93.59
9	Shadows	57	890	99.75	99.88	99.40	99.65	96.13	96.34
	OA			83.83	83.91	91.24	97.21	95.57	98.54
	AA			82.78	83.05	91.02	96.95	92.22	97.57
	Kappa			0.783	0.784	0.883	0.963	0.941	0.981




图9 各算法在 PaviaU 数据及上的分类结果图。(a) NN;(b) SRC;(c) SVM;(d) WSSD-KNN;(e) SSNN;(f) SSWNN

Fig. 9 Classification results of different algorithms in PaviaU dataset. (a) NN; (b) SRC; (c) SVM; (d) WSSD-KNN;

(e) SSNN; (f) SSWNN

从表2和图9可知,与 Indian Pines 数据集结论一致:所提出的 SSNN 和 SSWNN 算法在 PaviaU 数据集中各项指标都是最高的,且分类精度更高,效果更明显,验证了所提算法的准确性。

4 结 论

提出了一种简单可行的基于空谱加权近邻的高光谱图像分类方法。结合高光谱图像的物理特性,通过选取合适的空间窗口和样本比例,滤除图像中的冗余信息,有效避免了近邻空间内异类点对中心像元点分类的干扰。通过给空间近邻点赋予不同的权值,使有效的鉴别特征更加明显。同时引入正则化系数,对训练样本和测试样本近邻空间距离进行求解,极大提高了算法的精度。在 Indian Pines 和 PaviaU 高光谱数据集上的实验结果表明,相较于已有算法,本算法的分类精度更高,对地物的分类效果更好。其中 SSWNN 算法比仅利用光谱信息的算法,总体精度提高了 16.09%~28.05%;比引入空间信息的 WSSD-KNN 算法,精度提高了约 5.01%。因为图像中的噪声会影响对像元的分类,所以对含有噪声较多的图像进行分类还需要进一步研究。

参 考 文 献

- [1] Khodadadzadeh M, Li J, Prasad S, et al. Fusion of hyperspectral and LiDAR remote sensing data using multiple feature learning [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, 8(6): 2971-2983.
- [2] Wang L Z, Zhang J B, 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.
- [3] Tang Z Q, Fu G Y, Chen J, et al. Multiscale segmentation-based sparse coding for hyperspectral image classification [J]. *Optics and Precision*

Engineering, 2015, 23(9): 2708-2714.

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.

- [4] Paoletti M E, Haut J M, Fernandez-Beltran R, et al. Deep pyramidal residual networks for spectral-spatial hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(2): 740-754.
- [5] van Cleemput E, Vanierschot L, Fernández-Castilla B, et al. The functional characterization of grass- and shrubland ecosystems using hyperspectral remote sensing: trends, accuracy and moderating variables [J]. *Remote Sensing of Environment*, 2018, 209: 747-763.
- [6] Cao X Y, Zhou F, Xu L, et al. Hyperspectral image classification with Markov random fields and a convolutional neural network[J]. *IEEE Transactions on Image Processing*, 2018, 27(5): 2354-2367.
- [7] Zhao C H, Liu W, Xu Y, et al. A spectral-spatial SVM-based multi-layer learning algorithm for hyperspectral image classification [J]. *Remote Sensing Letters*, 2018, 9(3): 218-227.
- [8] 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.
- [9] Li F Y, Huo H T, Li J, et al. Hyperspectral image classification via multiple-feature-based improved sparse representation[J]. *Acta Optica Sinica*, 2019, 39(5): 0528004.
李非燕,霍宏涛,李静,等.基于多特征和改进稀疏表示的高光谱图像分类[J].*光学学报*, 2019, 39(5): 0528004.
- [10] Du E Y, Zhang N, Li Y D. Multi classification method of lane arrow markings based on support

- vector machines with adaptive partitioning coding[J]. Acta Optica Sinica, 2018, 38(10): 1015003.
- 杜恩宇, 张宁, 李艳获. 基于自适应分块编码 SVM 的车道导向箭头多分类方法[J]. 光学学报, 2018, 38(10): 1015003.
- [11] Liu F, Lu L X, Huang G W, et al. Landform image classification based on discrete cosine transformation and deep network[J]. Acta Optica Sinica, 2018, 38(6): 0620001.
- 刘芳, 路丽霞, 黄光伟, 等. 基于离散余弦变换和深度网络的地貌图像分类[J]. 光学学报, 2018, 38(6): 0620001.
- [12] Zhi L, Yu X C, Fu Q Y. Hyperspectral imagery spatial-spectral classification combining local binary patterns [J]. Journal of Geomatics Science and Technology, 2018, 35(1): 65-69, 76.
- 职露, 余旭初, 付琼莹. 联合局部二值模式的高光谱影像空-谱分类方法[J]. 测绘科学技术学报, 2018, 35(1): 65-69, 76.
- [13] 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.
- [14] 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.
- [15] Wang Z J, Yu Z J, Ma K, et al. An image filtering algorithm based on adaptive median and gradient inverse weight [J]. Laser & Optoelectronics Progress, 2017, 54(12): 121001.
- 王志军, 于之靖, 马凯, 等. 一种自适应中值梯度倒数加权的图像滤波算法[J]. 激光与光电子学进展, 2017, 54(12): 121001.
- [16] Chen J Y, Zhan Y W, Cao H Y, et al. Adaptive probability filter for removing salt and pepper noises [J]. IET Image Processing, 2018, 12(6): 863-871.
- [17] Singh V, Dev R, Dhar N K, et al. Adaptive type-2 fuzzy approach for filtering salt and pepper noise in grayscale images [J]. IEEE Transactions on Fuzzy Systems, 2018, 26(5): 3170-3176.
- [18] Zhu H L, Liu C, Zhang B, et al. Research on laser ultrasonic visual image processing [J]. Chinese Journal of Lasers, 2018, 45(1): 0104004.
- 朱洪玲, 刘畅, 张博, 等. 激光超声可视化图像处理研究[J]. 中国激光, 2018, 45(1): 0104004.
- [19] Yu J J, Liu J L. Simulation of bioluminescence tomography based on nonconvex L_{1-2} regularization [J]. Chinese Journal of Lasers, 2018, 45(4): 0407006.
- 余景景, 刘佳乐. 基于非凸 L_{1-2} 正则化的生物发光断层成像仿真研究[J]. 中国激光, 2018, 45(4): 0407006.