

散度核协同表示与空谱融合特征的高光谱图像分类算法

闫汇聪 刘德山 陈浪 马斯宇

(辽宁师范大学计算机与信息技术学院 辽宁 大连 116081)

摘要 协同表示的相关算法在高光谱图像分类的学习过程中没有很好地刻画高光谱图像的特性,如像素的局域性和标签信息等,因此其性能受到限制。对此,提出一种散度核协同表示技术并利用空谱融合获取特征的分类方法(IKCRC)。为有效刻画像素的局域性和标签信息,该方法构造新的散度核协同表示模型和相应的计算模型。在公式中引入核映射以提高分类能力,在计算过程上使用空谱融合的初步特征提取使得算法简洁高效。在标准高光谱图像数据集上进行的对比实验表明,IKCRC 更能有效地提高分类精度。

关键词 高光谱图像 散度核协同表示 空谱融合特征

中图分类号 TP39

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2023.02.045

A HYPERSPECTRAL IMAGE CLASSIFICATION ALGORITHM BASED ON DIVERGENCE KERNEL COLLABORATIVE REPRESENTATION AND SPATIAL-SPECTRAL FUSION FEATURE

Yan Huicong Liu Deshan Chen Lang Ma Siyu

(School of Computer and Information Technology, Liaoning Normal University, Dalian 116081, Liaoning, China)

Abstract In the learning process of hyperspectral image classification, the related algorithms of collaborative representation do not describe the characteristics of hyperspectral image well, such as pixel localization and label information, so its performance is limited. Therefore, we propose a divergence kernel collaborative representation technique and a classification method (IKCRC) that utilizes spatial-spectral fusion to obtain feature. In order to describe the localization and label information of pixels effectively, a new divergence kernel collaborative representation model and a corresponding computational model were constructed. In the proposed algorithm formula, we introduced kernel mapping to improve the ability of classification, and used the initial feature extraction of spatial-spectral fusion to make the algorithm simple and efficient. Comparison experiments on standard hyperspectral image data sets show that the proposed method (IKCRC) can improve classification accuracy more effectively.

Keywords Hyperspectral image Divergence kernel collaborative representation Spatial-spectral fusion feature

0 引言

高光谱图像(HSI)分类的研究具有重要应用意义。高光谱图像具有丰富的地理信息量,能够实现对地表的清晰表达^[1],其图像属性也使得人们能够对不同物质进行分类^[2-3]。目前,研究人员利用丰富的光谱信息和光谱数据开发了多种分类算法,这些算法被广泛应用于军事^[4]、农业^[5]、矿业^[6]、渔业^[7]、林业^[8]

等领域。同时,这些算法在环境污染监测、农业精耕细作、土地利用分析、矿产勘查等领域都有着广泛的应用^[9]。对高光谱图像而言,由于其成像的方式是多光谱,其像素的空间关系和光谱关系相互影响。此外,如果直接用高光谱数据对地物进行分类应用,一方面会导致训练样本的数量有限、维度高、容易产生 Hughes 现象;另一方面计算量大、耗时长,限制了 HSI 分类的表现^[10]。高光谱图像具有如下特点:(1)相同的物体可能具有不同的光谱表现,相反,不同的物体也会反映

出相同的光谱特点。这样就对分类技术是一个考验。(2) 类别边缘以及像素之间存在信号的影响。(3) 高光谱图像的成像过程中存在外界多种因素的影响(如大气、雾等),从而带来噪声数据。(4) 由于各种原因,高光谱图像的学习样本相对不足,增加学习算法的困难。

近年来有一些基于机器学习的常规分类方法提出,如基于(KNN)^[11]、支持向量机(SVM)^[12]、极端学习机(ELM)^[13]以及稀疏表示(SR)^[14]等技术的算法。在信息刻画和提取策略上,空间和光谱的结合是一个重要的研究方面^[15]。在稀疏表示分类的理论与算法框架^[16]基础上,Zhang等^[17]提出了一种在高光谱图像分类中的应用方法。与上述方法相比,一些方法侧重于有效的特征提取。Kalluri等^[18]从HSI中提取光谱导数信息。Jolliffe等^[19]利用了HSI的主成分分析特征。Li等^[20]提取了线性和非线性特征,并开发了一种用于HSI分类的多特征学习机制。

以字典学习为基础的SR理论凭借其良好的分类性能在信号处理、计算机视觉和模式识别等方面有很多成功应用的模型,近年来对高光谱图像处理领域产生了重要的影响^[42-47]。基于SR理论方法,Zhang等^[21,41]提出了协同表示(CR)方法。文献[22]提出一种局部协同表示方法。文献[23]根据不同约束项的作用给出加权正则的协同表示框架。基于协同表示和正则化技术,文献[24-25]分别提出最近邻子空间与核映射正则化的方法。文献[26]结合多任务学习,同时利用邻域信息给出联合协同表示(JCR)的方法。Xiong等^[27]研究了邻域信息提取的作用,提出加权联合协同表示(WJCR)方法。以构建局部自适应字典为基础,Li等^[28]提出一种非局部联合协同表示(NJCR)方法。文献[29]提出基于核方法投影数据的稀疏表示分类算法(KSRC),通过使用核技术优化算法获得的稀疏表示向量,以此确定待测像素的类标签。高光谱图像中数据的关联具有非线性特性,为此,文献[30]利用核映射技术提出了一种核协同表示(KCRC)分类算法。为加强空间信息的提取,Jiang等^[31]在改进协同表示算法的目标函数提出一种具有空间感知的协同表示方法(JSACR)。

现有的算法从不同的角度研究的信息刻画与提取的途径和技术,为我们的研究提供了重要启发。在研究中我们发现,协同表示的相关算法在高光谱图像分类的学习过程中没有很好地刻画高光谱图像的特性,如像素的局域性和标签信息等,因此其性能受到限制。

为此,我们提出一种散度核协同表示技术并利用空谱融合获取特征的分类方法(IKCRC)。所提出新方法以最大获取像素的类信息与关联信息为出发点,强调分类的有效性,建立一种新的协同表示模型与计算框架。

本文提出算法的主要贡献:(1) 不仅考虑到空间和谱信息的刻画,同时考虑到数据间的关联信息,引入信息散度矩阵到优化目标函数的正则约束中,有利于特征的有效提取。(2) 引入核学习,在CRC的基础上提出了IKCRC算法模型。增强算法的分类能力。(3) 在学习样本相对较少的情况下能够展示出较好的信息提取能力并具有更高的分类精度。

1 研究基础

1.1 空谱特征学习

空间与谱特征学习网络(SSN)^[33]可同时获得空间和光谱的信息,其特点是以分层的形式学习图像特征。SSN在学习阶段的结构由多个学习的单元(SSFLU)连接,构成一个多层的深度学习网络。每一层是一个SSFLU,一个SSFLU由两部分组成:一部分是光谱特征的学习模块;另一部分是空间特征的学习模块。由线性判别分析(LDA)^[32]实现光谱特征部分的学习。LDA同时具有分类和降维功能,利于信息的刻画提取。空间特征的学习由多个具有不同尺度的空间滤波器(AWF)^[33]实现。图1是文献[34]中所描述的SSFLU结构。图2为SSN空谱特征学习的原理结构。

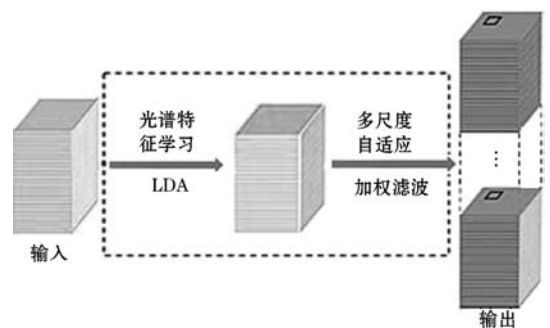


图1 SSFLU结构




图2 SSN空谱特征学习的原理

1.2 LDA 算法

LDA 算法^[32]能够实现最小化类内散度和最大化类间散度。在 SSN 的空谱特征学习中使用 LDA 将高光谱图像在光谱维度上进行降维,同时保证类间的最大区分性。

设数据集为 $\mathbf{X} = [\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_N] \in \mathbf{R}^{N \times D}$, $\mathbf{X}_j \in \mathbf{R}^D$ ($j=1, 2, \dots, N$)。数据一共分 C 类,假设过滤器数量为 K_{spe} ,则 $\mathbf{W}_{\text{spe}} \in \mathbf{R}^{D \times K_{\text{spe}}}$ 。第 c 类样本均值为:

$$\mathbf{m}_c = \frac{1}{N_c} \sum_{n=1}^{N_c} \mathbf{W}_{\text{spe}}^T \mathbf{X}_{n,c} \quad (1)$$

式中: N_c 是第 c 类像素的个数, $\mathbf{X}_{n,c}$ 是第 c 类中的像素。所以类内散度 \mathbf{S}_w 为:

$$\mathbf{S}_w = \sum_{c=1}^C p_c \frac{1}{N_c} \sum_{i=1}^{N_c} (\mathbf{W}_{\text{spe}}^T \mathbf{X}_i^c - \mathbf{m}_c) (\mathbf{W}_{\text{spe}}^T \mathbf{X}_i^c - \mathbf{m}_c)^T \quad (2)$$

式中: $p_c = N_c/N$ 。然后求高光谱总的像素平均:

$$\mathbf{m} = \frac{1}{N} \sum_{n=1}^N \mathbf{W}_{\text{spe}}^T \mathbf{X}_n \quad (3)$$

类间散度 \mathbf{S}_b 计算为:

$$\mathbf{S}_b = \sum_{c=1}^C p_c (\mathbf{m}_c - \mathbf{m}) (\mathbf{m}_c - \mathbf{m})^T \quad (4)$$

LDA 使用一系列过滤器使类间散度和类内散度的比例最大化:

$$\max_{\mathbf{W}_{\text{spe}} \in \mathbf{R}^{D \times K_{\text{spe}}}} = \frac{\mathbf{W}_{\text{spe}}^T \mathbf{S}_b \mathbf{W}_{\text{spe}}}{\mathbf{W}_{\text{spe}}^T \mathbf{S}_w \mathbf{W}_{\text{spe}}} \quad (5)$$

选择 K_{spe} 个最大的特征向量:

$$\mathbf{S}_b \mathbf{w}_{\text{spe}} = \lambda \mathbf{S}_w \mathbf{w}_{\text{spe}} \quad (6)$$

通过上述方法对 HSI 图像像素进行过滤,获得过滤后的 HSI 像素为 K_{spe} 层。

1.3 字典学习^[21,30]

传统的字典学习方法基于下面的基本原理:对于给定训练样本 \mathbf{y} ,寻找对应的权重向量 \mathbf{X} ,满足误差: $\|\mathbf{y} - \mathbf{D}\mathbf{X}\|_2^2$ 最小。其中, \mathbf{D} 是学习字典矩阵,其列向量代表各类特征。当通过不同训练样本获取对应的不同权重向量 \mathbf{X} (一般是稀疏的向量)后即完成学习阶段。对于待测的样本 \mathbf{y} ,仍然利用 $\|\mathbf{y} - \mathbf{D}\mathbf{X}\|_2^2$ 的结构,寻找与之最佳匹配的权重向量,从而确定待测的样本 \mathbf{y} 的最佳所属类别。

协同表示 (CRC)^[21] 和核协同表示算法 (KCRC)^[30] 改进了传统字典的构造:把字典中代表某类的一个原子(列向量)扩展到该类的多个原子,以使得样本信息具有协同作用。

2 IKCRC 算法

2.1 协同表示分类 (CRC)

Zhang 等^[21,41] 认为在分类过程中起决定因素的是协同表示 (CR) 而非稀疏表示 (SR)。因此提出基于范数 L2 进行约束的协同表示方法 (CRC)。协同表示模型可利用全部的训练字典原子重建给定的测试像元。对于测试像元 \mathbf{y} ,寻找对应的权重向量 \mathbf{X} ,需要同时满足重建误差 $\|\mathbf{y} - \mathbf{D}\mathbf{X}\|_2^2$ 最小和约束条件 $\|\mathbf{X}\|_2^2$ 最小,可以表达为:

$$\hat{\mathbf{X}} = \operatorname{argmin} \|\mathbf{y} - \mathbf{D}\mathbf{X}\|_2^2 + \lambda \|\mathbf{X}\|_2^2 \quad (7)$$

式中: λ 惩罚参数,其功能是平衡重建误差和范数项 $\|\mathbf{X}\|_2^2$ 。通过二范数正则化项对表示系数进行约束,可以促使全部的字典原子均参与测试像元 \mathbf{y} 的重建。求取式(7)关于表示系数向量 \mathbf{X} 的导数,可以得到式(8)的解析解。

$$\hat{\mathbf{X}} = (\mathbf{D}^T \mathbf{D} + \lambda \mathbf{I})^{-1} \mathbf{D}^T \mathbf{y} \quad (8)$$

式中: \mathbf{I} 表示单位矩阵。

当解析地获取得到表示系数向量 \mathbf{X}^{CR} ,可以计算像元 \mathbf{y} 和其类依赖近似 $D_c \delta_c(d)$ 的最小逼近残差:

$$\gamma_c(Y) = \|\mathbf{y} - D_c \delta_c(x)\|_2^2 \quad (9)$$

式中:只为类依赖字典。像元 Y 的地物类别可由类向最小残差准则 $\operatorname{class}(Y) = \operatorname{argmin}_{c=1,2,\dots,C} \gamma_c$ 计算得到。

2.2 核协同表示分类 (KCRC)^[30]

高光谱图像的不同特征通道通常是线性不可分离的,而典型的线性稀疏表示模型无法充分表示高光谱数据样本的非线性结构特征。为解决非线性问题,文献[30]中给出了一种核协同表示算法 (KCRC)。其中稀疏表示的计算为:

$$\hat{\mathbf{X}} = \operatorname{argmin} \|\phi(\mathbf{y}) - \phi(\mathbf{D})\mathbf{X}\|_2^2 + \lambda \|\mathbf{X}\|_2^2 = \operatorname{argmin} \|\mathbf{K}(\mathbf{D}, \mathbf{y}) - \mathbf{G}\mathbf{X}\|_2^2 + \lambda \|\mathbf{X}\|_2^2 \quad (10)$$

式中: $\mathbf{k}(\mathbf{D}, \mathbf{y}) = [k(d_1, \mathbf{y}), k(d_2, \mathbf{y}), \dots, k(d_N, \mathbf{y})]^T \in \mathbf{R}^{N \times 1}$ 和 $\mathbf{G} = \boldsymbol{\varphi}\boldsymbol{\varphi}^T \in \mathbf{R}^{N \times N}$ 表示核 Gram 矩阵,其中每个元素 $G(i, j) = k(d_i, d_j)$ 。

2.3 散度核映射协同表示与空谱特征融合的算法 (IKCRC)

在本节中我们提出空谱融合特征信息与散度核协同表示的分类方法 (IKCRC)。利用 LDA 算法提取数据的散度矩阵作为判别信息的流行正则项引入到

KCRC 算法中,以提高 KCRC 在高光谱图像分类中的准确性。IKCRC 算法基于优化目标函数的计算形式如下:

$$\hat{X} = \operatorname{argmin} \|y - DX\|_F^2 + \lambda \operatorname{tr}[X^T(\mu S_b - (1 - \mu)S_w)X] + \beta \|X\|_F^2 \quad (11)$$

式(11)为流形正则项, μ 为修正参数, β 为正则化参数, λ 为惩罚参数。

本文算法采用高斯径向基核函数(Gaussian Radial Basis Function Kernel),简称 Gaussian 核,其定义为:

$$k(d_i, d_j) = \exp\left\{-\frac{\|d_i - d_j\|^2}{2\sigma^2}\right\} \sigma \in \mathbf{R}^+ \quad (12)$$

式中: σ 为高斯核函数的频带宽度。

IKCRC 的核协同表示优化目标函数计算式为:

$$\hat{X} = \operatorname{argmin} \|\varphi(y) - \varphi(D)X\|_F^2 + \lambda \operatorname{tr}[X^T(\mu S_b - (1 - \mu)S_w)X] + \beta \|X\|_F^2 \quad (13)$$

式中: $\varphi(y)$ 和 $\varphi(D)$ 与式(10)中的意义相同,表示变换为高维空间下的数据。求取式(13)于表示系数向量 X 的导数,可以解析得到核特征空间 H 中表示系数向量的解:

$$\hat{X} = [\varphi^T(D)\varphi(D) + \lambda(\mu S_b - (1 - \mu)S_w) + \beta I]^{-1} \varphi^T(D)\varphi(y) \quad (14)$$

式中向量的内积由核函数计算。通过下式的计算可确定类别:

$$\operatorname{class}(Y) = \operatorname{argmin} \|K(D, y) - G_c X_c\|_2^2 \quad (15)$$

式中: G_c 可视作诱导特征空间中与第 c 类相关联的字典, X_c 为与第 c 类相关联的类依赖的表示系数。

关于 IKCRC 的算法的理论思想:目标函数中引入散度矩阵体现出像素数据之间的关联与区分信息。目标函数中包含着字典信息、稀疏表示信息以及协同表示信息。这样的信息构成能更全面刻画出数据的分类本质。从机器学习角度来说,核映射的引入源于其具有对非线性分类的能力。对复杂背景下的数据更有意义,而高光谱图像即是这样类型的数据。由于高光谱图像具有维度高,像素构成影响因素多等特点,挖掘其空谱融合特征对于高效分类具有重要作用。因此,这样的算法结构即形成一种分类模型。

IKCRC 的算法步骤如下:

输入:高光谱数据集。

步骤 1 使用 SSN^[33]的 SSFLU 特征提取得到新的数据集(特征信息数据)。

步骤 2 依据式(1)–式(6)局部嵌入类信息散度矩阵。

步骤 3 通过式(11)–式(14)稀疏表示向量 X (训练学习阶段)。

步骤 4 对待测的 y ,通过 X 寻找到 y 的最优逼近,从而得到预测的标签(预测阶段)。

输出:测试数据集的预测标签。

3 实验结果与分析

我们把所提出的算法与相关算法做对比实验。实验所用的高光谱数据集分别为 Indian Pines 和 Salinas。本文所有实验使用 MATLAB R2016b,硬件环境为 CPU 3.2 GHz;内存 8 GB。

3.1 高光谱图像数据集

Indian Pines 数据集:该数据集是印第安纳州西北部一个区域的高光谱遥感图像。图像大小 145×145 像素,每个像素的空间分辨率为 2 000 万像素。AVIRIS 传感器在 $0.4 \sim 2.5 \mu\text{m}$ 的光谱范围内产生 220 个波段,为降低实验误差通常去除 20 个吸水带将光谱带的数量降至 200^[36]。如表 1 所示,该数据集包含 16 个真实类别,其中大多数为农作物如玉米、大豆、小麦、燕麦等。本实验采用去除后保留的其余 200 个波段的数据作为实验对象。图 3 给出了波段 50、27 和 17 组成的三波段伪彩色图和真实地面图。

表 1 Indiana Pines 数据集描述

| 名称 | 训练样本 | 测试样本 | 样本总数 |
|-----------------|-------|-------|--------|
| Alfalfa | 6 | 48 | 54 |
| Corn-notill | 144 | 1 290 | 1 434 |
| Corn-mintill | 84 | 750 | 834 |
| Corn | 24 | 210 | 234 |
| Grass-pasture | 50 | 447 | 497 |
| Grass-trees | 75 | 672 | 747 |
| Grass-pasture-m | 3 | 23 | 26 |
| Hay-windrowed | 49 | 440 | 489 |
| Oats | 2 | 18 | 20 |
| Soybean-notill | 97 | 871 | 968 |
| Soybean-mintill | 247 | 2 221 | 2 468 |
| Soybean-clean | 62 | 552 | 614 |
| Wheat | 22 | 190 | 212 |
| Woods | 130 | 1 164 | 1 294 |
| Buildings-G-T-R | 38 | 342 | 380 |
| Stone-Steel-T | 10 | 85 | 95 |
| 总计 | 1 043 | 9 323 | 10 366 |



(a) 实际地面图 (b) 波段 50、27 和 17 组成的伪彩色图

图 3 Indian Pines

Salinass 数据集:该数据集是美国加利福尼亚南部的 Salinas 山谷区域的高光谱图像,图像由 AVIRIS 传感器获取。该图像大小为 512×217 像素。如表 2 所示,在该数据集中有 16 种地物的类别。该数据集在空间上具有 224 个波段^[37]。按照常规做法,本实验中使用数据去除 20 个大气水分吸收和低信噪比的波段,采用处理后保留的 204 个波段的数据。图 4 给出的是由波段 50、30 和 20 组成的实际地面图和伪彩色图。

表 2 Salinas 数据集描述

| 名称 | 训练样本 | 测试样本 | 样本总数 |
|--------------------------|-------|--------|--------|
| Brocoli_g_weeds_1 | 101 | 1 908 | 2 009 |
| Brocoli_green_weeds_2 | 187 | 3 539 | 3 726 |
| Fallow | 99 | 1 877 | 1 976 |
| Fallow_rough_plow | 70 | 1 324 | 1 394 |
| Fallow_smooth | 1 347 | 2 544 | 2 678 |
| Stubble | 198 | 3 761 | 3 959 |
| Celery | 179 | 3 400 | 3 579 |
| Grapes_untrained | 563 | 10 708 | 11 271 |
| Soil_vinyard_develop | 311 | 5 892 | 6 203 |
| Corn_s_g_weeds | 164 | 3 114 | 3 278 |
| Lettuce_romaine_4wk | 54 | 1 014 | 1 068 |
| Lettuce_romaine_5wk | 97 | 1 830 | 1 927 |
| Lettuce_romaine_6wk | 46 | 870 | 916 |
| Lettuce_romaine_7wk | 54 | 1 016 | 1 070 |
| Vinyard_untrained | 364 | 6 904 | 7 268 |
| Vinyard_vertical_trellis | 91 | 1 716 | 1 807 |
| 总计 | 2 712 | 51 417 | 54 129 |



(a) 实际地面图

(b) 由波段 50、30 和 20 组成的伪彩色图

图 4 Salinas

3.2 实验和参数设置

我们使用 IKCRC 与相关经典算法做对比实验。这些算法分别是 KCRC^[30]、SRC^[38]、KSRC^[29]、SVM^[12]、SVM-CK^[39]、JSaCR^[31]。在 Indiana Pines 数据集上随机选择每个类别的 10% 的样本用作训练;由于 Salinas 数据集相对量大,我们在该数据集上随机选择每个类别的 5% 用作训练;剩余样本用于测试。

IKCRC 采用“Gaussian”核函数。IKCRC 中有三个计算参数,它们分别是:修正参数 μ 、惩罚参数 λ 、正则化参数 β 。为得到最佳的参数选取,实验采用交叉验证方法以及网格搜索方式。

3.3 评价指标

我们采用通常的 3 个指标来评估实验结果。这 3 个指标分别是总体分类精度、平均分类精度和 Kappa 系数^[40]。总体分类精度(OA)的计算方法由式(16)给出。其中, C 为图像中待分类样本的类别数目, N_i 代表第 i 类样本中待分类样本的数量, \bar{N}_i 代表第 i 类样本中被准确划分的样本个数, $1 \leq i \leq C$ 。

$$OA = \frac{\sum_{i=1}^C \bar{N}_i}{C} \quad (16)$$

平均分类精度(AA)的计算由式(17)给出,该数值体现出算法对各种类别样本的总体分类效果。

$$AA = \frac{\sum_{i=1}^C \bar{N}_i}{C} \quad (17)$$

Kappa 系数(kappa coefficient),计算过程如式(18)–式(19)所示,它可以用于一致性检验,也可以用于衡量分类精度。式中:OA 指总体分类精度。

$$Kappa = \frac{OA - p_e}{1 - p_e} \quad (18)$$

$$p_e = \frac{\sum_{i=1}^C N_i \cdot \bar{N}_i}{\left(\sum_{i=1}^C N_i\right)^2} \quad (19)$$

3.4 在 Indian Pines 数据集上的实验结果

在 Indian Pines 数据集上将本文所提算法与 KCRC、SRC、KSRC、SVM、SVM-CK、JSaRC 进行对比。几种分类算法在 Indian Pines 数据上的分类结果如表 3 所示,不同分类算法的效果由图 5 给出。

表 3 Indian Pines 数据分类中不同分类算法的比较 (%)

| 数据集 | KCRC | SRC | KSRC | SVM | SVM-CK | JSaCR | IKCRC |
|-----------------|-------|-------|-------|-------|---------------|---------------|---------------|
| Alfalfa | 29.17 | 10.42 | 29.17 | 52.08 | 97.92 | 95.83 | 97.92 |
| Corn-notill | 54.73 | 53.33 | 55.74 | 77.52 | 93.88 | 97.13 | 98.22 |
| Corn-mintil | 53.60 | 49.73 | 53.20 | 69.87 | 92.80 | 96.93 | 99.20 |
| Corn | 34.76 | 27.62 | 36.19 | 56.19 | 94.76 | 91.90 | 98.57 |
| Grass-pasture | 75.84 | 74.05 | 76.51 | 87.25 | 96.87 | 99.78 | 98.66 |
| Grass-trees | 89.43 | 89.14 | 89.43 | 94.49 | 99.40 | 99.85 | 99.70 |
| Grass-pasture-m | 73.91 | 52.17 | 78.26 | 73.91 | 100.00 | 100.00 | 100.00 |
| Hay-windrowed | 97.50 | 97.50 | 97.73 | 97.27 | 96.82 | 100.00 | 100.00 |
| Oats | 38.39 | 33.33 | 33.33 | 27.78 | 94.44 | 88.89 | 100.00 |
| Soybean-notill | 61.19 | 56.72 | 62.57 | 62.00 | 87.14 | 90.70 | 98.62 |
| Soybean-mintill | 73.93 | 69.65 | 73.35 | 78.39 | 96.08 | 95.81 | 98.96 |
| Soybean-clean | 42.57 | 40.04 | 43.84 | 69.57 | 94.57 | 95.47 | 99.09 |
| Wheat | 95.26 | 96.84 | 95.26 | 97.89 | 100.00 | 100.00 | 100.00 |
| Woods | 91.32 | 88.92 | 91.41 | 90.21 | 99.23 | 99.40 | 99.23 |
| Buildings-G-T-R | 35.67 | 41.52 | 34.50 | 57.89 | 97.08 | 97.66 | 100.00 |
| Stone-Steel-T | 84.71 | 81.18 | 84.71 | 85.88 | 84.71 | 97.65 | 98.82 |
| OA | 69.03 | 66.43 | 69.25 | 78.45 | 95.29 | 96.79 | 99.02 |
| AA | 64.53 | 60.13 | 64.70 | 73.64 | 95.36 | 96.69 | 99.19 |
| Kappa | 64.59 | 61.63 | 64.85 | 75.43 | 94.63 | 96.35 | 98.89 |

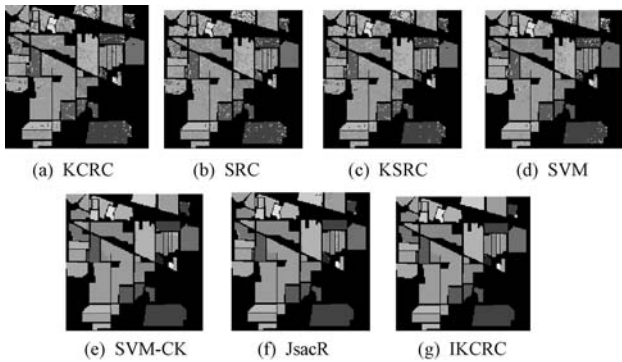


图 5 不同算法在 Indian Pines 数据上的对比实验

表 3 给出了 7 种不同算法在 Indian Pines 数据上的分类精度,其中最好的结果由黑体标出。可以看出,本文算法在 Corn、Oats、Soybean-notill、Soybean-mint 等数据上的分类精度优于其他 6 种算法,在 Grass-pasture-mowed、Hay-windrowed 等 5 类数据上精确度都达到了 100%。从表 3 还可以看出,本文算法在 OA、AA 和 Kappa 系数上的指标均优于其他 6 种算法。图 5 给出的是 7 种算法的分类结果图,由此可以看到:由 KCRC、SRC 等 4 种算法产生的分类结果图噪声都比较多,SVM-CK 和 JSaCR 分类效果较好,本文算法 IKCRC 分类效果最准确。

3.5 在 Salinas 数据集上的实验结果

我们在 Salinas 数据集上将本文所提出的算法与

KCRC、SRC、KSRC、SVM、SVM-CK、JSaCR 进行对比。7 种不同分类算法在 Salinas 数据集上的分类结果如表 4 所列,其分类结果如图 6 所示。

表 4 Salinas 数据分类中不同分类算法的比较

| 数据集 | KCRC | SRC | KSRC | SVM | SVM-CK | JSaCR | IKCRC |
|--------------------------|-------|-------|-------|---------------|---------------|---------------|---------------|
| Brocoli_g_weeds_1 | 98.38 | 99.69 | 98.53 | 98.69 | 99.95 | 99.95 | 100.00 |
| Brocoli_green_weeds_2 | 99.89 | 98.50 | 99.86 | 99.94 | 99.89 | 100.0 | 100.00 |
| Fallow | 99.25 | 72.51 | 97.55 | 99.84 | 99.73 | 99.89 | 100.00 |
| Fallow_rough_plow | 99.62 | 95.47 | 99.62 | 99.70 | 98.04 | 97.81 | 99.70 |
| Fallow_smooth | 97.72 | 87.22 | 97.17 | 97.80 | 99.72 | 99.69 | 99.65 |
| Stubble | 99.76 | 99.81 | 99.76 | 99.73 | 100.00 | 100.00 | 100.00 |
| Celery | 99.09 | 99.74 | 99.09 | 99.68 | 99.68 | 100.00 | 100.00 |
| Grapes_untrained | 86.74 | 83.29 | 71.34 | 89.10 | 98.96 | 97.36 | 99.98 |
| Soil_vinyard_develop | 99.46 | 97.88 | 99.13 | 99.93 | 99.83 | 100.00 | 100.00 |
| Corn_s_g_weeds | 92.23 | 80.48 | 90.98 | 93.06 | 98.91 | 98.78 | 100.00 |
| Lettuce_roumaine_4wk | 94.08 | 95.07 | 91.72 | 98.52 | 99.51 | 99.70 | 100.00 |
| Lettuce_roumaine_5wk | 100.0 | 63.33 | 99.78 | 100.00 | 99.95 | 98.96 | 100.00 |
| Lettuce_roumaine_6wk | 98.51 | 69.20 | 98.05 | 98.97 | 99.43 | 100.00 | 100.00 |
| Lettuce_roumaine_7wk | 93.80 | 72.34 | 93.41 | 98.03 | 98.92 | 99.11 | 100.00 |
| Vinyard_untrained | 70.76 | 38.22 | 58.17 | 71.83 | 98.97 | 96.47 | 99.45 |
| Vinyard_vertical_trellis | 98.08 | 99.01 | 97.26 | 98.66 | 99.83 | 99.48 | 100.00 |
| OA | 92.15 | 82.40 | 86.96 | 93.17 | 99.41 | 98.75 | 99.90 |
| AA | 95.46 | 84.48 | 93.21 | 96.47 | 99.46 | 99.20 | 99.92 |
| Kappa | 91.26 | 80.29 | 85.49 | 92.39 | 99.34 | 98.60 | 99.89 |




图 6 不同算法在 Salinas 数据上的对比实验

可以看到,本文算法的分类精度总体优于其他对比的 6 种算法。特别是在 Brocoli_green_weeds_1、Fallow 等 12 类数据上精确度都达到了 100%。而且


IKCRC 在 OA、AA 和 Kappa 系数上均优于其他 6 种算法。

由图 6 可以观察到, SRC、KCRC 两种算法的分类结果图包含了较多的噪声。


由以上实验结果与对比可见本文算法具有在高光谱图像分类中显示出良好的结果,从而验证了该算法对高光谱图像分类的有效性。本文算法有效性的原因在于:在有限的高光谱图像训练样本下,运用图像数据训练样本的几何结构散度信息,同时采用空谱融合的特征提取策略,构造新的核协同模型。

3.6 训练样本选取的影响

本节给出 CRC、SRC、KSRC、SVM、SVM-CK、JSACR 以及本文算法在不同训练样本个数情况下的分类性能实验。我们分别在 Indiana Pines 和 Salinas 两个数据集上进行实验,在 Indian Pine 数据集上分别随机选取该类样本数的 1%、2%、3%、4%、5%、6%、7%、8%、9%、10% 作为训练样本,其余的作为测试样本。在 Salinas 数据集上分别随机选取该类样本数的 0.5%、0.1%、1.5%、2%、2.5%、3%、3.5%、4%、4.5%、5% 作为训练样本,其余的作为测试样本。将实验的总体分类准确度(OA)作为评价指标。实验结果如图 7 所示。



(a) indian pines 数据集




(b) Salinas 数据集

图 7 不同训练样本个数下各种算法的分类准确率


由图 7(a)可知,在 Indian Pine 数据集上,IKCRC、JSACR、SVM-CK 等 3 类算法 OA 指标识别曲线明显优于 SRC、KSRC、KCRC、SVM 算法,其中本文提出的 IKCRC 分类准确率最高。由图 7(b)可以看出,在 Salinas 数据集上,几种算法的准确率都有所提高。IKCRC、JSACR、SVM-CK 这 3 类算法依然在 OA 指标识别曲线明显优于 SRC、KSRC、KCRC、SVM 算法,其中本文提出的算法 IKCRC 在训练样本取 5% 的时候总体分类精度接近 100%。

3.7 修正参数分析

在本节中,我们分析主要修正参数 μ 影响 IKCRC 性能,实验结果如图 8 所示,其显示了不同的参数值和相应的分类精度。



(a) indian pines 数据集



(b) Salinas 数据集

图 8 不同修正参数取值在两个数据集对分类准确率的影响

由图 8 可以看出,参数 μ 的不同值带来不同的结果。对于 Indian Pines 的数据集, $\mu = 0.2$ 时分类精度最高;对于 Salinas 数据集, $\mu = 0.1$ 时分类精度最高。IKCRC 的性能可以通过改变参数进行调整。

4 结 语

本文给出散度核协同表示构建新方法,采用空谱融合特征信息模块构造出新的高光谱图像分类方法的

框架模型(包括对应算法的模块构造和目标函数的设计)。该研究旨在针对高光谱图像样本相对少的现实情况能够更有效刻画与提取分类所需要的数据信息。由对比实验表明,IKCRC 在标准数据集上的分类效果优于其他对比算法。同时,在不同训练样本的选择下进行了分析对比,由此进一步验证了 IKCRC 具有更稳定更好的分类性能。在进一步的研究中,为更好地刻画数据信息,引入流形学习的技术方法到算法的改进中是一个值得探索的方面。

参 考 文 献

- [1] 成宝芝,赵春晖,张丽丽,等. 联合空间预处理与谱聚类的协同稀疏高光谱异常检测[J]. 光学学报,2017,37(4): 304-314.
- [2] Ghamisi P, Benediktsson J A, Ulfarsson M, et al. Spectral-spatial classification of hyperspectral images based on hidden Markov random fields[J]. IEEE Transactions on Geoscience and Remote Sensing,2014, 52(5):2565-2574.
- [3] Li J, Marpu P R, Plaza A, et al. Generalized composite kernel framework for hyperspectral image classification[J]. IEEE Transactions on Geoscience Remote Sensing, 2013, 51(9):4816-4829.
- [4] Du B, Zhang Y X, Zhang L P, et al. A hypothesis in dependent subpixel target detector for hyperspectral images [J]. Signal Process, 2015, 110: 244-249.
- [5] Caballero D, Calvini R, Amigo J M. Hyperspectral imaging in crop fields: Precision agriculture[M]. London:Elsevier, 2020.
- [6] Dalm M, Buxton M W, Ruitenbeek F J. Discriminating ore and waste in a porphyry copper deposit using short-wavelength infrared (SWIR) hyperspectral imagery[J]. Minerals Engineering, 2017,105: 10-18.
- [7] Washburn K E, Stormo S K, Skjelvareid M H, et al. Non-invasive assessment of packaged cod freeze-thaw history by hyperspectral imaging [J]. Journal of Food Engineering, 2017, 205: 64-73.
- [8] Luo S,Wang C, Xi X,et al. Fusion of airborne LiDAR data and hyperspectral imagery for aboveground and belowground forest biomass estimation[J]. Ecological Indicators, 2017, 73:378-387.
- [9] Mei S, Ji J, Geng Y, et al. Unsupervised spatial-spectral feature learning by 3D convolutional autoencoder for hyperspectral classification[J]. IEEE Transactions on Geoscience and Remote Sensing,2019, 57(9):6808-6820.
- [10] Yang H, Du Q, Chen G. Particle swarm optimization-based hyperspectral dimensionality reduction for urban land cover classification[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2012, 5(2): 544-554.
- [11] Xiong M M,Ran Q,Li W, et al. Hyperspectral image classification via weighted joint nearest neighbor and sparse representation[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2018, 11(11): 4063-4075.
- [12] Waske B, Van D,Benediktsson J A,et al. Sensitivity of support vector machines to random feature selection in classification of hyperspectral data[J]. IEEE Transactions on Geoscience and Remote Sensing, 2010, 48(7):2880-2889.
- [13] Li W,Chen C,Su H J, et al. Local binary patterns and extreme learning machine for hyperspectral imagery classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(7):3681-3693.
- [14] Chen Y, Nasrabadi N M, Tran T D. Hyperspectral image classification using dictionary-based sparse representation [J]. IEEE Transactions on Geoscience and Remote Sensing, 2011, 49(10):3973-3985.
- [15] 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.
- [16] Wright J, Yang A Y, Ganesh A, et al. Robust face recognition via sparse representation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2008,31(2):210-227.
- [17] Zhang H, Li J, Huang Y, et al. A nonlocal weighted joint sparse representation classification method for hyperspectral imagery[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing,2014,7(6):2056-2065.
- [18] Kalluri H R, Prasad S, Bruce L M. Decision-level fusion of spectral reflectance and derivative information for robust hyperspectral land cover classification[J]. IEEE Transactions on Geoscience Remote Sensing,2010,48(11):4047-4058.
- [19] Jolliffe I, Principal Component Analysis [M]. Hoboken: Wiley, 2005.
- [20] Li J,Huang X,Gamba P, et al. Multiple feature learning for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing,2015,53(3):1592-1606.
- [21] Li J, Zhang H, Huang Y, et al. Hyperspectral image classification by nonlocal joint collaborative representation with a locally adaptive dictionary[J]. IEEE Transactions on Geoscience & Remote Sensing, 2014, 52(6):3707-3719.
- [22] Chen J, Jiao L. Hyperspectral imagery classification using local collaborative representation[J]. International Journal of

- Remote Sensing, 2014, 36(3):734–748.
- [23] Chen X, Li S, Peng J. Hyperspectral imagery classification with multiple regularized collaborative representations [J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(7):1121–1125.
- [24] Li W, Du Q, Xiong M. Kernel collaborative representation with Tikhonov regularization for hyperspectral image classification [J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(1):48–52.
- [25] Li W, Tramel E W, Prasad S, et al. Nearest regularized subspace for hyperspectral classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(1):477–489.
- [26] Li J, Zhang H, Zhang L, et al. Joint collaborative representation with multitask learning for hyperspectral image classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(9):5923–5936.
- [27] Xiong M, Ran Q, Li W, et al. Hyperspectral image classification using weight-ed joint collaborative representation [J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(6):1209–1213.
- [28] Li J, Zhang H, Zhang L. Column-generation kernel nonlocal joint collaborative representation for hyperspectral image classification [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2014, 94(10):25–36.
- [29] Chen Y. Hyperspectral image classification via kernel sparse representation [J]. IEEE Transactions on Geoscience & Remote Sensing, 2013, 51(1):217–231.
- [30] Wang D, Lu H, Yang M H, Kernel collaborative face recognition [J]. Pattern Recognit. 2015, 48, 3025–3037.
- [31] Jiang J, Chen C, Yu Y, et al. Spatial-aware collaborative representation for hyperspectral remote sensing image classification [J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(3):404–408.
- [32] Belhumeur P N, Hespanha J P, Kriegman D J. Eigenfaces vs. Fisherfaces: Recognition using class specific linear projection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1997, 19(7):711–720.
- [33] Zhou Y C, Wei Y T. Learning hierarchical spectral-spatial features for hyperspectral image classification [J]. IEEE Transactions on Cybernetics, 2016, 46(7):1667–1678.
- [34] Li Z M, Lai Z H, Xu Y, et al. A locality-constrained and label embedding dictionary learning algorithm for image classification [J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28(2):278–293.
- [35] Zheng M, Bu J, Chen C, et al. Graph regularized sparse coding for image representation [J]. IEEE Transactions on Image Process, 2011, 20(5):1327–1336.
- [36] Gualtieri J A, Crompton R F. Support vector machines for hyperspectral remote sensing classification [C]//27th AIPR Workshop: Advances in Computer-Assisted Recognition, 1999, 3584:221–232.
- [37] Zhou Y, Peng J, et al. Extreme learning machine with composite kernels for hyperspectral image classification [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2015, 8(6):2351–2360.
- [38] He Z, Zhou S H. Learning group-based sparse and low-rank representation for hyperspectral image classification [J]. Pattern Recognition, 2016, 60:1041–1056.
- [39] Marconcini M, Camps-Valls G, Bruzzone L. A composite semisupervised SVM for classification of hyperspectral images [J]. IEEE Geoscience and Remote Sensing Letters, 2009, 6(2):234–238.
- [40] Richards J A, Jia X P. Remote sensing digital image analysis [M]. Berlin: Springer, 1999.
- [41] Zhang L, Yang M, Feng X. Sparse representation or collaborative representation: Which helps face recognition. Proceedings International conference on computer vision [C]//2011 IEEE International Conference on Computer Vision (ICCV 2011). IEEE, 2011:471–478.
- [42] Tu B, Zhang X, Kang X, et al. Hyperspectral image classification via fusing correlation coefficient and joint sparse representation [J]. IEEE Geoscience and Remote Sensing Letters, 2018, 15(3):340–344.
- [43] Tu B, Kuang W, Zhao G, et al. Hyperspectral image classification by combining local binary pattern and joint sparse representation [J]. International Journal of Remote Sensing, 2019, 40(24):9484–9500.
- [44] Sun H, Ren J, Zhao H, et al. Superpixel based feature specific sparse representation for spectral-spatial classification of hyperspectral images [J]. Remote Sensing, 2019, 11(5):536.
- [45] Sun H, Ren J, Zhao H, et al. Superpixel based feature specific sparse representation for spectral-spatial classification of hyperspectral images [J]. Remote Sensing, 2019, 11(5):536.
- [46] Zhu D, Du B, Zhang L. Target dictionary construction-based sparse representation hyperspectral target detection Methods [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2019, 12(4):1254–1264.
- [47] Guo T, Luo F, Zhang L, et al. Target detection in hyperspectral imagery via sparse and dense hybrid representation [J]. IEEE Geoscience and Remote Sensing Letters, 2020, 17(4):716–720.