

基于二阶矩稀疏编码的高光谱遥感图像分类

徐佳庆¹ 万文² 吕启³

(国防科技大学计算机学院 长沙 410073)¹ (中山大学国家超级计算广州中心 广州 510006)²
(中国人民解放军 31104 部队 南京 210016)³

摘要 高光谱遥感技术是当前遥感领域的前沿技术,将稀疏编码应用于高光谱遥感图像处理是近年来高光谱信息处理的一个热点研究方向。以提升高光谱遥感图像分类准确度为目标,提出一种基于二阶矩空谱联合稀疏编码的遥感图像分类方法。首先从各地物参考数据中选取训练样本,通过学习构造得到字典,然后在训练得到的字典的基础上通过稀疏编码获得每个像元的稀疏系数,之后将稀疏系数作为分类器的输入,通过分类器的分类判决得到最终的分类结果。利用北京市朝阳区的天宫一号可见近红外高光谱遥感图像数据和 KSC 高光谱数据,将该方法与支持向量机(SVM)、基于光谱维信息的稀疏编码以及一阶矩空谱联合稀疏编码等方法进行了比较。实验结果表明,提出的分类方法较其他几种方法可以取得更好的分类效果,在天宫一号和 KSC 数据上的总体分类精度分别可达到 95.74% 和 96.84%,Kappa 系数分别可达到 0.9476 和 0.9646。

关键词 高光谱遥感图像,分类,稀疏编码

中图分类号 TP751 文献标识码 A DOI 10.11896/j.issn.1002-137X.2018.09.048

Classification of Hyperspectral Remote Sensing Imagery Based on Second Order Moment Sparse Coding

XU Jia-qing¹ WAN Wen² LV Qi³

(School of Computer, National University of Defense Technology, Changsha 410073, China)¹

(National Supercomputer Center in Guangzhou, Guangzhou 510006, China)² (Unit 31104 of PLA, Nanjing 210016, China)³

Abstract Hyperspectral remote sensing is one of the frontier technologies in the field of remote sensing. It's a hot topic in hyperspectral information processing to apply sparse coding model to process hyperspectral remote sensing image. To improve the accuracy of hyperspectral image classification, a hyperspectral remote sensing image classification method based on the second-moment spatial-spectral joint contextual sparse coding (SM-CSC) was proposed. First, a dictionary was obtained by training the samples selected from the ground-truth data, then the sparse coefficient of each pixel was calculated based on the learned dictionary. Afterward, the sparse coefficient was inputted to the classifier and the final classification result was obtained. The visible and near-infrared hyperspectral remote sensing image collected by Tiangong-1 in Chaoyang District of Beijing and the KSC hyperspectral image were applied to estimate the performance of the proposed approach. Comparisons with three other classification methods such as support vector machine (SVM), spectral sparse coding (SSC), and first-moment spatial-spectral joint contextual sparse coding (FM-CSC) were made. Experimental results show that the proposed method can yield the best classification performance with the overall accuracy of 95.74% and the Kappa coefficient of 0.9476 on the Tiangong-1 data and with the overall accuracy of 96.84% and the Kappa coefficient of 0.9646 on the KSC data.

Keywords Hyperspectral remote sensing image, Classification, Sparse coding

1 引言

遥感图像分类是遥感应应用系统的关键技术,它是把遥感图像中的每个像元划归到类别中的过程,是模式识别技术在遥感领域的具体运用。其主要用途是根据地物电磁波辐射在遥感图像上的特征,判读识别地面物体的类属,实现对土地利用与土地覆盖(Land Use and Land Cover, LULC)情况的动态

监测。目前,遥感图像分类技术已经被广泛应用于地图测绘、城市规划、矿产资源探测、精细农业、环境监测、救灾抢险、军事侦察等领域。

高光谱遥感技术兴于 20 世纪 80 年代,是当前遥感领域的前沿技术。高光谱遥感图像由几十乃至数百个波段的图像组成,每个波段都是一幅特定波长的图像,而每个像元在各幅图像上的辐射值又组成了连续的光谱曲线。因此,高光谱遥

收到日期:2017-07-28 返修日期:2017-10-27 本文受国家 863 计划(2015AA015302),国家自然科学基金面上项目(61572509)资助。

徐佳庆(1982-),男,博士,CCF 会员,主要研究方向为计算机体系结构、机器学习,E-mail: xujiaqing@nudt.edu.cn(通信作者);万文(1987-),男,硕士,主要研究方向为计算机体系结构、机器学习;吕启(1987-),男,博士,主要研究方向为机器学习、遥感图像处理。

感图像同时记录了地物的图像信息和光谱信息,具有图谱合一的特点。利用地物的光谱信息可提高对地物的分类与监测能力,因此高光谱遥感分类受到了研究人员的较大关注^[1-2]。然而实际情况中,高光谱数据较多的波段数量和相对较小的训练样本规模给传统的遥感图像分类带来了挑战。

作为一种数据建模方法,稀疏编码近年来被广泛应用于信号与图像处理。其主要思想是,信号通过稀疏表示可以简洁地表达成字典中少数原子的线性组合形式。稀疏编码最初的提出受到视觉神经系统视觉感知的稀疏特性的启发。视觉神经通路的研究表明,视觉皮层对外界刺激的处理采用稀疏表示的方式,即只有很小一部分神经元处于活跃状态,大量的神经元处于非活跃状态^[3]。目前,稀疏编码已成为神经计算与人工智能领域的一个研究热点。

将稀疏编码(稀疏表示)应用于高光谱遥感图像处理,是近年来高光谱信息处理的一个热点研究方向。Chen 等^[4]提出利用基于字典的稀疏表示分类器(Sparse Representation Classifier, SRC)模型进行高光谱图像的分类; Yuan 等^[5]提出正则化稀疏表示(Regularized Sparse Representation, RSR)模型来提高分类精度; Cui 等^[6]考虑地物类别之间的相关性,提出了类相关稀疏表示分类器(class-dependent Sparse Representation Classifier, cdSRC)来进行高光谱遥感图像的分类; 宋相法等^[7]结合稀疏表示和光谱信息提出一种高光谱遥感图像分类方法,根据稀疏表示和光谱信息分别构造随机森林,通过投票机制得到最终的分类结果。然而,这些基于稀疏编码的方法都没有充分利用高光谱遥感图像的空间信息。通过挖掘地物空间相关性的信息,有望进一步提升高光谱遥感图像的分类精度。

本文以高光谱遥感数据为研究对象,提出一种基于空谱联合稀疏编码的地物分类方法。实验表明,该方法与支持向量机(Support Vector Machine, SVM)等方法相比,能够较大幅度地提升高光谱遥感图像的分类精度。

2 原理与方法

2.1 稀疏编码简介

稀疏编码是指在给定字典 $D \in \mathbb{R}^{M \times N}$ 的条件下,求解信号 $y \in \mathbb{R}^M$ 的稀疏系数 $\alpha \in \mathbb{R}^N$ 的过程。稀疏编码的目标函数为:

$$\hat{\alpha} = \arg \min_{\alpha} \|\alpha\|_0 \quad \text{s. t. } y = D\alpha \quad (1)$$

其中, $\|\cdot\|_0$ 为向量的 ℓ_0 范数,它表示 α 中非零元素的个数。字典 D 的每列 $d_i \in \mathbb{R}^M (i=1, 2, \dots, N)$ 称为基(basis)或原子(atom)。

然而在实际情况中,由于噪声的影响,稀疏系数 α 并不能对信号 y 进行完全无误差的表示,因此在式(1)中引入误差更符合实际应用,即:

$$\hat{\alpha} = \arg \min_{\alpha} \|\alpha\|_0 \quad \text{s. t. } \|y - D\alpha\|_2 \leq \epsilon \quad (2)$$

其中, $\|\cdot\|_2$ 表示向量的 ℓ_2 范数, ϵ 为误差阈值。

也可以对重构误差与稀疏性同时最小化,利用正则化参数 λ 对二者进行平衡:

$$\hat{\alpha} = \arg \min_{\alpha} \|y - D\alpha\|_2 + \lambda \|\alpha\|_0 \quad (3)$$

然而, ℓ_0 范数的求解是一个 NP(Non-deterministic Polynomial)问题。一种常用的方法是用 ℓ_1 范数代替 ℓ_0 范数,则式(3)可转化为如下凸优化问题:

$$\hat{\alpha} = \arg \min_{\alpha} \|y - D\alpha\|_2 + \lambda \|\alpha\|_1 \quad (4)$$

该式即为经典的 LASSO 模型^[8]。其中, $\|\cdot\|_1$ 为向量的 ℓ_1 范数,它表示向量中各元素的绝对值之和。

除了稀疏系数求解,字典构造是稀疏编码理论中的另一个核心问题。字典不仅关系到稀疏编码的有效性,还影响着稀疏编码求解算法的性能。字典的构造方式可分为两种类型:1)基于数学模型构造;2)基于样本学习构造。基于数学模型的方法通常是通过数学分析的方式构造一些变换矩阵,如离散余弦变换(DCT)、傅里叶变换、小波变换等。这些字典虽然易于实现,但通常性能不是最优的。基于样本学习的方法的主要目标是从训练样本库 $Y = \{y_i\}_{i=1}^N$ 中学习出字典 D ,使字典 D 能够对每个训练样本都能够进行有效的稀疏表示。以 D 表示字典, A 表示稀疏系数矩阵,该优化问题可形式化地描述为:

$$\arg \min_{D, A} \|Y - DA\|_F + \lambda \sum_{i=1}^N \|\alpha_i\|_0 \quad (5)$$

其中, $A = (\alpha_1, \alpha_2, \dots, \alpha_N)$ 为稀疏系数矩阵, $\|\cdot\|_F$ 表示矩阵的 Frobenius 范数。

通常,字典学习的过程可以通过交替优化(Alternating Optimization)^[9]的方式来实现,主要包括如下两个部分:

- 1) 稀疏系数求解(Sparse Inference): 保持当前字典 D 不变,求解稀疏系数矩阵 A ;
- 2) 字典更新(Dictionary Update): 保持当前稀疏系数矩阵 A 不变,更新字典 D 。

稀疏系数求解过程中,假设字典 D 保持不变,式(5)可转化为:

$$\arg \min_{\alpha_i} \|y_i - D\alpha_i\|_2 + \lambda \|\alpha_i\|_0, i=1, 2, \dots, N \quad (6)$$

该式可以转化成式(4)所示的 LASSO 模型,进而可通过求解算法得到各稀疏系数 α_i 。

在字典更新阶段,固定稀疏系数矩阵 A ,通过如下的优化模型对字典进行更新:

$$\arg \min_D \|Y - DA\|_F \quad (7)$$

上式成为一个经典的最小二乘优化问题,可以通过迭代算法求解字典 D 。

2.2 基于稀疏编码的高光谱遥感图像分类

研究表明,高光谱图像在光谱维具有较强的光谱稀疏性^[10-11]。即不同类别的地物光谱特征位于不同的子空间,某一光谱特征能够被该类训练样本组成的字典线性表示,而很难被其他类别的训练样本线性表示。因此,可以利用稀疏编码模型刻画光谱特征的相似性,从而实现地物分类。

基于稀疏编码的高光谱遥感图像分类的流程如图 1 所示,主要包括字典构造、稀疏系数求解、SVM 分类器 3 个部分。首先从各类中选取训练样本,通过学习构造得到字典,然后将测试样本在训练得到的字典上进行稀疏编码得到稀疏系数,最后将稀疏系数作为 SVM 分类器的输入,通过 SVM 的分类判决得到测试像元的分类结果。

式(5)所示的字典构造问题通过 BCD(Block Coordinate

Descent)方法^[12]迭代计算得到;对于式(4)所示的稀疏系数求解问题(LASSO模型),采用了开源工具 SPAMS^[13]进行求解。稀疏系数后所连接的 SVM分类器的实现采用常用的开源工具 LIBSVM^[14]。根据近年来计算机视觉关于稀疏编码的相关研究^[15-16],本文采用了线性 SVM。

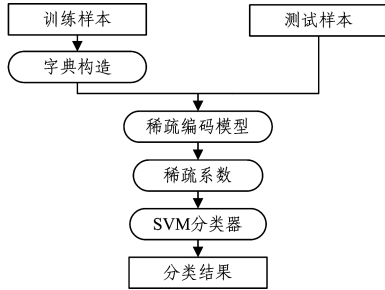


图1 基于稀疏编码的高光谱图像分类原理示意图

Fig. 1 Schematic diagram of classification method of hyperspectral image based on sparse coding

值得注意的是,对于稀疏编码的方式,我们采用了两种策略:1)只考虑光谱维信息的稀疏编码(Spectral Sparse Coding),简记为 SSC方法;2)同时考虑了光谱信息与空间信息的空谱联合稀疏编码(Contextual Sparse Coding),简记为 CSC方法。CSC方法的优化目标为式(4)的增广形式:

$$\hat{\alpha} = \arg \min_{\alpha} \|\tilde{y} - D\alpha\|_2^2 + \lambda \|\alpha\|_1 \quad (8)$$

(1)若 \tilde{y} 为一阶矩(First Moment),称该CSC方法为FM-CSC。在各个波段上,每个像元的辐射亮度值等于方形邻域中各个像元辐射亮度值的均值,即 $\tilde{y} = \mu = \frac{1}{W^2} \sum_{y_i \in N(y)} y_i$ 。其中, $N(y)$ 表示 y 的邻域像元的集合, W 表示邻域窗口的大小, W^2 表示邻域像元的总数。

(2)若 \tilde{y} 为二阶矩(Second Moment),称该CSC方法为SM-CSC。式(8)中的 \tilde{y} 除考虑邻域像元的均值外,还考虑到了邻域像元的方差,即 $\tilde{y} = (\mu, \sigma)$ 。其中, $\mu = \frac{1}{W^2} \sum_{y_i \in N(y)} y_i$, $\sigma = std(N(y))$ 。基于一阶矩和二阶矩的空谱联合稀疏编码的分类效果将在第3节进行评估。

3 实验与分析

3.1 分类精度评价

高光谱遥感图像分类精度评价是指在完成分类后,根据地物真实参考数据来评估分类的准确性。常用的分类精度评价方法包括混淆矩阵、总体精度和Kappa系数。

混淆矩阵(Confusion Matrix)也称误差矩阵,反映了分类结果与真实地物类别的相关信息,也是分析总体精度和Kappa系数等指标的基础。以 M 表示混淆矩阵,其元素 m_{ij} 表示测试样本中应属于类别 j 而实际被分到类别 i 的像素总数。混淆矩阵对角线的元素 m_{ii} 的值越大,分类精度越高。下面对总体精度和Kappa系数进行介绍。

(1)总体精度

总体精度(Overall Accuracy, OA)是对分类结果的质量的总体评价,等于被正确分类的像素总和除以总的像素个数。被正确分类的像素沿着混淆矩阵的对角线分布,它显示了被

正确分类到真实分类中的像元数。根据混淆矩阵可得OA的计算式为:

$$p = \sum_{i=1}^c m_{ii} / N \quad (9)$$

其中, c 表示类别数目, m_{ii} 表示混淆矩阵对角线上的元素,

$N = \sum_{i=1}^c \sum_{j=1}^c m_{ij}$ 表示测试样本的总数。

(2)Kappa系数

Kappa系数^[17]采用一种多元离散分析技术来反映分类结果与参考数据之间的吻合程度,它考虑了混淆矩阵的所有因子,是一种更为客观的评价指标,其定义为:

$$\kappa = \frac{N \sum_{i=1}^c m_{ii} - \sum_{i=1}^c (m_{i+} m_{+i})}{N^2 - \sum_{i=1}^c (m_{i+} m_{+i})} \quad (10)$$

其中, m_{i+} 和 m_{+i} 分别表示混淆矩阵的第 i 行的总和、第 i 列的总和。Kappa系数越大,分类精度越高。

3.2 在天宫一号数据上的实验

实验选用天宫一号上的可见近红外(Visible and Near-infrared, VND)传感器所探测处理后的L2级高光谱数据。天宫一号(TG-1)是我国首个空间目标飞行器,于2011年9月29日在酒泉卫星发射中心发射,其搭载的高光谱成像是目前我国空间和光谱综合指标最高的空间光谱成像仪。实验数据为2012年3月6日获取的可见近红外高光谱影像^[18],影像大小为 350×350 。该数据包含了64个有效波段,波长范围约为 $400 \sim 1000$ nm,光谱分辨率约为10 nm,空间分辨率为10 m。

研究区域位于北京市朝阳区金盏地区(见图2),该地区包含部分城市区域与未开发区域及过渡区,适合于土地利用与土地覆盖分类的研究。其主要地物类别包括水体、草地、树木、道路、裸土及建筑物,几类地物类型的光谱曲线如图3所示。

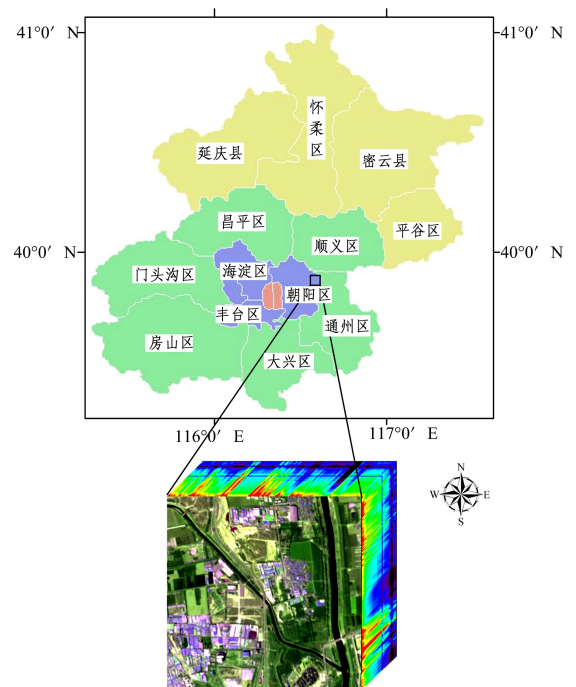


图2 天宫一号数据区域示意图

Fig. 2 Location of data site of Tiangong-1




图 3 6 种地物类别光谱曲线示意图

Fig. 3 Spectral curves of six land cover classes

图 4(a)和图 4(b)分别显示了天宫一号高光谱图像的伪彩色图与真实地物类别。训练样本按约 9% 的比例从参考数据中随机选取,参考数据的剩余样本作为测试样本,图 4(c)和图 4(d)分别显示了训练样本与测试样本的分布。训练样本共包含 293 个样本点,测试样本共包含 2649 个样本点,各地物类别的样本数目如表 1 所列。




图 4 天宫一号遥感图像示意图

Fig. 4 Diagram of sensing image of Tiangong-1 data

表 1 天宫一号数据地物类别与训练/测试样本数目

Table 1 Categories of objects and numbers of pixels in training/test set on Tiangong-1 data

| 类别 | 总样本数 | 训练样本数 | 测试样本数 |
|-----|------|-------|-------|
| 水体 | 543 | 54 | 489 |
| 草地 | 594 | 59 | 535 |
| 树木 | 507 | 50 | 457 |
| 道路 | 172 | 17 | 155 |
| 裸土 | 430 | 43 | 387 |
| 建筑物 | 696 | 70 | 626 |

本文所有实验均利用 MATLAB 2014a,在一台具有 16 核 AMD Opteron 处理器(2.3 GHz),48 GB 内存,操作系统为 Windows 7 的计算机上实现。

为了验证提出的空谱联合稀疏编码方法的有效性,对基于 SVM,SSC,FM-CSC,SM-CSC 的几种分类方法进行了比较。SVM 方法的实现采用常用的开源工具 LIBSVM^[14]。SVM 的核函数为多项式核函数,惩罚因子 C 和多项式的阶数 d 采用网格搜索(Grid Search)交叉验证进行寻优得到。SSC 和 CSC 方法的邻域窗口大小 W 取值为 3,因此邻域中像素总数为 9(含中心像素)。式(4)和式(5)中的 λ 的取值是从集合 $\{0.1,1,10,100\}$ 中通过 5 折交叉验证(5-fold Cross Validation)寻优获得。

几种方法对 6 类地物类别的分类精度如表 2 所列。可见,基于二阶矩空谱联合稀疏编码(SM-CSC)的方法在各类

割中都取得了最高的分类精度,特别是道路和建筑物的分类精度较其他方法有较大提高。表 3 列出了几种方法的总体分类精度与 Kappa 系数。从表 3 可以得出如下结论:1)采用稀疏编码的方式对特征进行提取挖掘,可以取得比单独使用 SVM 更好的分类效果;2)采用空谱联合的方式,在光谱维信息之外结合空间信息,可进一步提高分类精度,FM-CSC 方法和 SM-CSC 方法的分类精度都比 SSC 方法高;3)二阶矩比一阶矩引入了更多的空间邻域信息,可得到更高的分类精度。总体来看,SM-CSC 方法在几种方法中可获得最好的分类效果,其总体精度为 95.74%,Kappa 系数为 0.9476。

表 2 天宫一号数据上不同方法的各类分类精度

Table 2 Classification accuracy of different methods on Tiangong-1 data

| | (单位:%) | | | |
|-----|--------|-------|--------|--------|
| | SVM | SSC | FM-CSC | SM-CSC |
| 水体 | 98.57 | 99.59 | 99.80 | 99.80 |
| 草地 | 98.13 | 99.44 | 99.63 | 99.81 |
| 树木 | 94.53 | 98.25 | 98.47 | 98.69 |
| 道路 | 27.74 | 57.42 | 59.35 | 64.52 |
| 裸土 | 97.16 | 96.12 | 96.38 | 99.48 |
| 建筑物 | 80.19 | 77.96 | 84.98 | 92.33 |

表 3 天宫一号数据上不同方法的总体分类精度与 Kappa 系数

Table 3 Overall accuracies and Kappa coefficients of different methods on Tiangong-1 data

| | SVM | SSC | FM-CSC | SM-CSC |
|----------|--------|--------|--------|--------|
| 总体精度/% | 89.08 | 91.24 | 93.16 | 95.74 |
| Kappa 系数 | 0.8660 | 0.8931 | 0.9163 | 0.9476 |

图 5 给出了几种分类方法的分类结果图。从图 5 可以看出,由于 SVM 方法与 SSC 方法都没有考虑空间邻域信息,它们在一定程度上均存在“椒盐”现象,即整块区域中出现了小片破碎,而两种 CSC 方法由于引入空间信息,使得“椒盐”现象得到弱化。SSC 方法与 SVM 方法相比,道路轮廓更为清晰。而 SM-CSC 与 FM-CSC 方法相比,其他类别被错分为道路的情况得到了减少,并且建筑物类别的分类准确度有较大提高。




图 5 天宫一号数据上不同方法的分类结果示意图

Fig. 5 Classification results of different methods on Tiangong-1 data



3.3 在 KSC 数据上的实验

KSC (Kennedy Space Center) 高光谱数据集^[19]由 AVIRIS 传感器于 1996 年 3 月 23 日采集于美国佛罗里达州肯尼迪航天中心附近。该影像共包含 224 个波段,光谱范围为 400~2500nm,剔除掉噪声和大气吸收影响严重的 48 个波

段,将共 176 个波段的数据用于实验。影像大小为 512×614 ,空间分辨率为 18m。该高光谱数据包括 13 个地物类别,表 4 列出了各类的名称以及每个类总的样本数目。KSC 数据集伪彩色图和参考真实地物类别如图 6 所示。每个类使用了 50 个样本作为训练样本,剩下的样本均作为测试样本。

表 4 KSC 数据集的相关信息

Table 4 Related information of KSC dataset

| 类别 ID | 类别名称 | 中文名称 | 样本数目 | 类别颜色 |
|-------|-----------------------|---------|------|---|
| C1 | Scrub | 灌木 | 761 |  |
| C2 | Willow swamp | 柳树沼泽 | 243 |  |
| C3 | Cabbage palm hammock | 棕榈芦苇 | 256 |  |
| C4 | Cabbage palm/oak | 棕榈/橡树 | 252 |  |
| C5 | Slash pine | 湿地松 | 161 |  |
| C6 | Oak/broadleaf hammock | 橡树/阔叶芦苇 | 229 |  |
| C7 | Hardwood swamp | 硬木沼泽 | 105 |  |
| C8 | Graminoid marsh | 禾草湿地 | 431 |  |
| C9 | Spartina marsh | 米草湿地 | 520 |  |
| C10 | Cattail marsh | 蒲草湿地 | 404 |  |
| C11 | Salt marsh | 盐湿地 | 419 |  |
| C12 | Muld flats | 泥滩 | 503 |  |
| C13 | Water | 水体 | 927 |  |



(a) 伪彩色图



(b) 真实地物类别(类别名称及对应颜色参见表 4)

图 6 KSC 数据集

Fig. 6 KSC dataset

SVM,SSC,FM-CSC,SM-CSC 几种分类方法的参数选取范围与在天宫一号数据上的相同,邻域窗口大小也设置为 3,同时也采用网格搜索交叉验证进行参数寻优。表 5 列出了 4 种方法对 KSC 的 13 种地物的分类结果。从表 5 也可以得到如下结论:1)SSC 方法的精度比 SVM 略高,OA 高出约 1%;2)引入空间邻域信息后的空谱联合方法 FM-CSC 和 SM-CSC 的分类精度较只使用了光谱信息的 SSC 方法有较大提高,分别提升了约 4% 和 5%;3)SM-CSC 方法的总体精度达到 96.84%,Kappa 系数达到 0.9646,在几种方法中的分类精度为最高,再次证明了所提方法在高光谱图像分类中的有效性。4 种不同分类方法的分类结果如图 7 所示。


利用 Circos 弦图(Chord Diagram)工具^[20]分析几种方法的分类结果,如图 8 所示,其中不同类别之间的色带(Ribbon)表

示类间混淆情况,色带越宽,混淆越大。由图 8 可知,SM-CSC 的类间混淆最少,从而达到了最高的总体分类精度。

表 5 KSC 数据上不同方法的分类精度

Table 5 Classification accuracy of different methods on KSC data


| | (单位:%) | | | |
|----------|--------|--------|--------|--------|
| | SVM | SSC | FM-CSC | SM-CSC |
| C1 | 88.19 | 89.45 | 93.95 | 95.50 |
| C2 | 91.71 | 92.23 | 95.85 | 96.37 |
| C3 | 92.72 | 94.17 | 97.57 | 93.69 |
| C4 | 76.73 | 72.28 | 91.58 | 86.14 |
| C5 | 77.48 | 78.38 | 90.99 | 99.10 |
| C6 | 73.74 | 64.80 | 96.09 | 96.65 |
| C7 | 98.18 | 98.18 | 100.00 | 100.00 |
| C8 | 86.61 | 95.54 | 91.86 | 95.80 |
| C9 | 98.51 | 94.68 | 100.00 | 99.57 |
| C10 | 92.94 | 96.05 | 99.15 | 94.63 |
| C11 | 92.41 | 94.85 | 100.00 | 100.00 |
| C12 | 84.55 | 92.49 | 87.42 | 96.03 |
| C13 | 97.95 | 98.29 | 98.29 | 99.77 |
| 总体精度 | 90.48 | 91.89 | 95.70 | 96.84 |
| Kappa 系数 | 0.8934 | 0.9090 | 0.9517 | 0.9646 |



(a)SVM (b)SSC (c)FM-CSC (d)SM-CSC


图 7 KSC 数据上不同方法的分类结果

Fig. 7 Classification results of different methods on KSC data



(a)SVM

(b)SSC



(c)FM-CSC

(d)SM-CSC

图 8 KSC 数据上不同方法的类间混淆比较

Fig. 8 Confusions between classes for different methods on KSC data

结束语 本文以高光谱遥感图像为研究对象,提出一种基于二阶矩空谱联合稀疏编码的分类方法。将该方法与支持向量机、基于光谱维信息的稀疏编码以及一阶矩空谱联合稀疏编码几种方法进行比较。结果表明,基于二阶矩空谱联合信息的稀疏编码方法较其他几种方法可以取得更好的分类效果,在天宫一号和 KSC 数据上的总体分类精度分别可达到 95.74% 和 96.84%,Kappa 系数分别可达到 0.9476 和

0.9646,是一种有效的高光谱遥感地物分类方法。目前的方法中,像元的邻域是一个固定的方形结构。下一步工作中,将通过设计像元的自适应邻域结构,来更深入地挖掘高光谱数据的空间信息,从而进一步提高分类精度。

参 考 文 献

- [1] JOSE M B, ANTONIO P, GUSTAU C V, et al. Hyperspectral Remote Sensing Data Analysis and Future Challenges [J]. *IEEE Geoscience and Remote Sensing Magazine*, 2013, 1(2): 6-36.
- [2] 张良培, 杜博, 张乐飞. 高光谱遥感影像处理[M]. 北京: 科学出版社, 2014.
- [3] OLSHAUSEN B A, FIELD D J. Emergence of simple-cell receptive field properties by learning a sparse code for natural images [J]. *Nature*, 1996, 381(6583): 607-609.
- [4] 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.
- [5] YUAN H L, TANG Y Y, LU Y, et al. Hyperspectral Image Classification Based on Regularized Sparse Representation [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(6): 2174-2182.
- [6] CUI M, PRASAD S. Class-Dependent Sparse Representation Classifier for Robust Hyperspectral Image Classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(5): 2683-2695.
- [7] SONG X F, JIAO L C. Classification of Hyperspectral Remote Sensing Image Based on Sparse Representation and Spectral Information [J]. *Journal of Electronics and Information Technology*, 2012, 34(2): 268-272. (in Chinese)
宋相法, 焦李成. 基于稀疏表示及光谱信息的高光谱遥感图像分类[J]. *电子与信息学报*, 2012, 34(2): 268-272.
- [8] ROBERT T. Regression shrinkage and selection via the lasso [J]. *Journal of the Royal Statistical Society, Series B (Methodological)*, 1996, 58(1): 267-288.
- [9] ELAD M. *Sparse and Redundant Representations* [M]. Heidelberg: Springer, 2010.
- [10] CHARLES A S, OLSHAUSEN B A, ROZELL C J. Learning sparse codes for hyperspectral imagery [J]. *IEEE Journal of Selected Topics in Signal Processing*, 2011, 5(5): 963-978.
- [11] CASTRODAD A, XING Z, GREER J B, et al. Learning discriminative sparse representation for modeling, source separation, and mapping of hyperspectral imagery [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, 49(11): 4263-4281.
- [12] ALI S F, HAMID R R, SEYYED A H. Spatial-Aware Dictionary Learning for Hyperspectral Image Classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, 53(1): 527-541.
- [13] MAIRAL J, BACH F, PONCE J, et al. Online learning for matrix factorization and sparse coding [J]. *Journal of Machine Learning Research*, 2010, 11: 19-60.
- [14] CHANG C C, LIN C J. LIBSVM: A library for support vector machines [J]. *ACM Transactions on Intelligent Systems and Technology*, 2011, 2(3): 1-27.
- [15] YANG J C, YU K, GONG Y H, et al. Linear Spatial Pyramid Matching using Sparse Coding for Image Classification [C] // *Proceedings of 2009 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2009: 1794-1801.
- [16] CULPEPPER B J, SOHL D J, OLSHAUSEN B A. Building a better probabilistic model of images by factorization [C] // *Proceedings of 2011 International Conference on Computer Vision (ICCV)*. 2011: 2011-2017.
- [17] 罗小波, 赵春晖, 潘建平, 等. 遥感图像智能分类及其应用[M]. 北京: 电子工业出版社, 2011.
- [18] 中国科学院空间应用工程与技术中心. 载人航天空间应用数据推广服务平台 [EB/OL]. http://www.msadc.cn/t1-cms/t1/dataProduct/dataProduct_dxbyb_list.jsp.
- [19] UPV/EHU. Hyperspectral Remote Sensing Scenes [EB/OL]. http://www.ehu.eus/ccwintco/index.php?title=Hyperspectral_Remote_Sensing_Scenes.
- [20] KRZYWINSKI M. *Circos* [EB/OL]. <http://circos.ca>.
- [11] VASQUEZ D, SCHARCANSKI J, WONG A, et al. A novel 3D approach for the extraction of the wetting front in CT images of soil profiles [C] // *Instrumentation and Measurement Technology Conference, IEEE*, 2013: 1540-1543.
- [12] JYOTIBORA D, GUPTA A K. A New Approach towards Clustering based Color Image Segmentation [J]. *International Journal of Computer Applications*, 2014, 107(12): 23-30.
- [13] SAĞ T, CUNKAS M. Color image segmentation based on multiobjective artificial bee colony optimization [J]. *Applied Soft Computing*, 2015, 34(C): 389-401.
- [14] SUN H J, DENG T Q, LI Y C. Improved watershed image segmentation algorithm [J]. *Journal of Harbin Engineering University*, 2014, 35(7): 857-864. (in Chinese)
孙惠杰, 邓廷权, 李艳超. 改进的分水岭图像分割算法[J]. *哈尔滨工程大学学报*, 2014, 35(7): 857-864.

(上接第 282 页)

- [7] WONG A, SCHARCANSKI J, FIEGUTH P. Automatic skin lesion segmentation via iterative stochastic region merging [J]. *IEEE Transactions on Information Technology in Biomedicine A Publication of the IEEE Engineering in Medicine & Biology Society*, 2011, 15(6): 929-936.
- [8] BORA D J, GUPTA A K. A New Efficient Color Image Segmentation Approach Based on Combination of Histogram Equalization with Watershed Algorithm [J]. *International Journal of Computer & Engineering*, 2016, 4(6): 156-167.
- [9] RAJABY E, AHADI S M, AGHAEINIA H. Robust color image segmentation using fuzzy c-means with weighted hue and intensity [J]. *Digital Signal Processing*, 2016, 51(7): 170-183.
- [10] ZHOU C, WU D, QIN W, et al. An efficient two-stage region merging method for interactive image segmentation [J]. *Computers & Electrical Engineering*, 2016, 54(15): 220-229.