

基于空谱融合特征主动学习的高光谱图像分类

王 琰¹, 刘丽芹², 沈霞宏¹, 侯 俊¹, 张 宁¹, 史振威²

(1. 上海航天电子技术研究所, 上海 201109; 2. 北京航空航天大学 宇航学院, 北京 100191)

摘要:针对高光谱图像分类过程中存在的样本量少和分类精度低的问题,提出一种基于空谱融合特征主动学习的高光谱图像分类方法。主要包括构造三通道图像,全卷积网络提取空间特征,空谱特征结合,主动学习方法选择训练样本几个部分。通过结合像素的光谱特性和相邻像素间的空间关联,提取出可以反映像素空谱联合特性的综合特征,提高了像素特征的表达能。为克服高光谱图像标注数据少、缺乏训练样本的问题,应用主动学习算法,充分选择更具有代表性的样本进行训练,达到少样本情况下较高的分类正确率。通过在标准数据集上进行实验,结果表明:该方法可以达到在总样本数1%作训练样本的情况下,分类正确率达到99.79%,优于传统的高光谱分类算法。

关键词:高光谱分类; 全卷积网络; 空谱融合; 主动学习

中图分类号:N 37 **文献标志码:**A

DOI:10.19328/j.cnki.1006-1630.2019.05.007

Active Learning Based on Spatial-Spectral Feature for Hyperspectral Image Classification

WANG Yan¹, LIU Liqin², SHEN Xiahong¹, HOU Jun¹, ZHANG Ning¹, SHI Zhenwei²

(1. Shanghai Aerospace Electronic Technology Institute, Shanghai 201109, China;

2. School of Astronautics, Beihang University, Beijing 100191, China)

Abstract: In order to solve the problem that the number of samples is limited and the accuracy of the classification is low, the authors propose a hyperspectral classification method which extracts the spatial feature with fully convolutional networks in three-channels image built by themselves. The following parts are included in this method: three channel image building, spatial feature extracting, spatial and spectral feature fusion and training examples selecting. Active learning method is used to select training sample after the fusion of spatial and spectral feature. By combining the spectral characteristic of the pixel and the spatial correlation of adjacent pixels, the integrated feature which can reflect associated spatial-spectral characteristic of the pixel is obtained. The combination can also enhance the expression ability of the pixel. In order to overcome the limits of the labelled data of hyperspectral image and lack of training samples, the active learning algorithm is put into use. The algorithm selects the most representative sample for training, and occurs ideal accuracy using limited samples. Experiment on the standard dataset shows that the accuracy of the method is as high as 99.79% when one percent samples are selected to train.

Keywords: hyperspectral image classification; fully convolutional networks; spectral-spatial fusion; active learning

0 引言

随着成像技术的发展,机载或星载传感器可以

获得越来越高的光谱分辨率,高光谱数据以三维形式存储,具有光谱响应范围广、波段宽度窄、图谱合

收稿日期:2019-04-09;修回日期:2019-06-08

基金项目:国家自然科学基金(61671037);上海航天科技创新基金(SAST2018096, SAST2017108)

作者简介:王 琰(1988—),女,工程师,主要研究方向为图像处理 and 抗辐射加固电子学。

一等特点。高光谱分类的内涵是对每个像素所代表的地物类别进行区分,近年来,我国已成功发射多颗高光谱分辨率的遥感卫星,高光谱图像的分类已经在环境监测、精确农业、智慧城市和信息国防方面得到广泛的应用。尤其是高分五号卫星于 2018 年 5 月 9 日发射成功,更是对提高我国高光谱遥感数据自给率,推动高光谱遥感数据应用有重要作用。

很多基于传统机器学习的算法被应用于高光谱分类,例如支持向量机(support vector machine, SVM)^[1]、线性邻域传播(linear neighborhood propagation, LNP)^[2]、随机森林(random forest)^[3]、极限学习机(extreme learning machine, ELM)^[4]和基于稀疏表达的分类(sparse representation-based classifier, SRC)^[5]方法,另外还有局部二值模式(local binary pattern, LBP)^[6-7]特征提取、Gabor 滤波^[8]和滚动引导滤波(hierarchical guidance filtering, HGF)^[9]等空间域方法。近年来,深度学习方法在高光谱分类领域得到了广泛应用,最早应用于高光谱分类的深度学习方法是 2014 年 CHEN 提出的栈式自动编码器(stacked auto-encoders, SAE)^[10],之后卷积神经网络(convolutional neural network, CNN)^[11-12]被广泛地用于高光谱分类问题。随着各种深度神经网络的提出,学者们逐渐将它们应用到高光谱分类中,例如 CHEN^[13]应用深度置信网络(deep belief network, DBN)实现高光谱分类,LI^[14]提出了应用深度森林(deep forest)解决高光谱分类问题,ZHONG^[15]应用残差网络(deep residual networks, DRN)来解决高光谱图像的分类,MOU^[16]和 ZHU^[17]分别提出循环神经网络(recurrent neural network, RNN)和生成对抗网络(generative adversarial networks, GAN)用于高光谱分类问题。

以上提出的深度学习方法,其应用于高光谱分类的本质都是人为地对每个需要分类的像素点构建一组数据作为特征输入,实际上还是应用深度网络对浅层特征提取深层表达的过程,因此本文选用像素级分割网络——全卷积网络(fully convolutional networks, FCN)^[18]直接对构造的三通道图像提取空间特征,再将其与光谱特征结合进行分类。

由于人工标注高光谱样本的成本高,标注困难,造成已知标签的高光谱像素数目是有限的,因此,如何用少量的样本得到较高的分类精度成为一项亟待解决的问题。主动学习可以充分挖掘数据之间的

关系,寻找最具代表性的样本用作训练。因此,近年来也有一系列主动学习算法被应用于高光谱分类^[19-20],这些方法取得了一定的效果,但也存在一定的只针对特定问题特定算法的局限性。本文提出一种新的主动学习方法选择训练样本,适应高光谱分类任务,充分保证样本的代表性,使应用一定数目的样本可以获得更高的分类正确率。

综上所述,本文提出了一种基于空谱融合特征主动学习的高光谱图像分类算法,通过构造三通道图像,利用全卷积网络提取空间特征,将其与光谱特征相结合,利用主动学习的算法选择训练样本,送入分类器进行训练,并得到分类结果。将高光谱图像构造成更适用于自然图像上训练好的模型的三通道图像,可以更加充分地挖掘高光谱图像中的光谱信息和空间邻域信息,使特征具备更好的表达能力。通过引入主动学习算法,可以选取更有用的训练样本送入分类器训练,从而达到在少量样本下更好的分类效果。算法流程如图 1 所示。

1 三通道图像构建与空间特征提取

由于高光谱数据量有限,不能用于对全卷积网络的训练,所以我们采用在自然图像上训练好的模型对高光谱图像提取空间特征。

由于自然图像为 RGB 三波段图像,因此需要从高光谱数据中提取对应的三波段图像,常用的将高光谱图像构造成三波段图像的方式通常是采用主成分分析(principal component analysis, PCA)方法,但考虑到已有模型是基于 RGB 三个波段的自然图像训练而成,因此其对于 RGB 对应波段的图像颜色和边缘更敏感,因此需要构造更接近于自然图像的 RGB 波段图像。

本文提出了一种虚拟 RGB 图像构建方法,主要是利用高光谱传感器每个波段的波长信息,寻找对应于 RGB 三个波段波长的高光谱波段,然后再将它们合成构成一个虚拟的 RGB 图像。以 ROSIS(reflective optics system imaging spectrometer)成像传感器为例,其对应红光波长的波段有 39~66 共 28 个波段,对应绿光波段为 13~29 共 17 个高光谱波段,蓝光波段对应 2~4 共 3 个波段,将这些波段以类似高斯分布的方式合成。以红光波段为例,将高斯分布的均值定为

$$\mu = \frac{39 + 66}{2} = 52.5$$




图 1 高光谱图像分类算法流程图

Fig.1 Flow chart of the hyperspectral image classification method

标准差 σ 根据 3σ 原则确定,即大部分合理波段都在 3σ 范围内,所以 $3\sigma = \mu - 39 = 13.5, \sigma = 4.5$ 。三波段图像每个波段的值为对应高光谱波段的值和它对应的高斯权重加权得到。

图 2 为 Pavia University 数据集上的结果,其中图 2(a)为合成后的虚拟 RGB 图,图 2(b)、图 2(c)、图 2(d)分别为合成后 3 个波段的灰度图。




图 2 合成三波段图像

Fig.2 Composed three-bands image

将提取到的三波段图像送入自然图像上训练好的 FCN 模型,提取其在 Softmax 之前的特征层,由于自然图像共 20 类物体,所以特征图共有 21 层(20 类和背景层)。在 Pavia University 数据集上提取到的特征如图 3 所示。

2 空谱特征融合

参考 JIAO 等^[21]的做法,将每个像素点的空间和光谱特征进行融合,构成空谱融合特征。假设 X_{spe} 为光谱特征,由原始光谱 PCA 取前 s_1 维主成分得到, X_{spa} 为深层空间特征,其维度为 s_2 ,所以可知




图 3 空间特征图

Fig.3 Spatial characteristic diagram

$$X_{\text{spe}} \in R^{s_1 \times n}, X_{\text{spa}} \in R^{s_2 \times n} \quad (1)$$

式中: n 为要融合的像素点数目。首先对 $X_{\text{spe}}, X_{\text{spa}}$ 进行如下操作

$$f(X) = \left(\frac{X - \bar{X}_{(i)}}{\sigma(i)} \right)_{(j)} \bigg/ \left| \frac{X - \bar{X}_{(i)}}{\sigma(i)} \right|_{(j)} \quad (2)$$

式中: X 分别代表 $X_{\text{spe}}, X_{\text{spa}}$; 下标 (j) 为按列进行操作; $\bar{X}_{(i)}, \sigma(i)$ 分别为列的均值和方差。空谱特征的组合方式为

$$X_f = [f(X_{\text{spe}}); f(X_{\text{spa}})] \quad (3)$$

此处,将原始光谱降维至 15 维,即 $s_1 = 15$,空间特征维度取所有 21 层,即 $s_2 = 21$ 。至此,得到空谱融合特征。

3 SVM 分类器主动学习

将得到的空谱融合特征送入分类器即可对每个像素所属的地物类别进行区分,由于样本数目限制,此处应用主动学习选择训练样本并与支持向量机(SVM)^[22]相结合用于对空谱联合特征进行学习^[23-24],实现像素分类。

支持向量机是一种经典的二分类分类器,在将其用于多分类时通常有以下两种做法:一对多(one-versus-rest, OVR) SVMs,即依次将某个类别的样本单独化为一类,其他类别化为另一类,假设共有 K 类,则会产生 K 个分类器,对一未知样本分类时,将其送入这 K 个分类器,选择其中分为某类的概率值最大的那一类作为最终决策;一对一(one-versus-one, OVO) SVMs,在任意两类样本之间均设计分类器,若有 K 类,则会产生 $K(K-1)/2$ 个分类器,

将未知样本送入左右分类器,并对分成各类的次数进行统计,选择次数最多的那一类作为最终决策。

本文基于一对一分类设计主动学习策略,假设有 K 类数据,最初选择一部分进行标注,记为 D_L ,其余未标注部分记为 D_U 。每次选择加入训练集的样本数目记为 n_a 。用 D_L 训练 $K(K-1)/2$ 个一对一分类器,对于 D_U 中每个样本,将其送入所有分类器中,获得投票数最多的两个类 ω_1, ω_2 ,将针对 ω_1, ω_2 的分类器的预测值 f 作为该样本所含信息量的评价指标,该数绝对值越小,证明分类器在决策时把握越小,该样本所含信息将会越多,所以取 $|f|$ 最小的 n_a 个样本进行标注后加入 D_L ,并将其从 D_U 中删除。可重复几次操作,得到选定的训练集 D_S 。SVM 分类器主动学习算法流程为:

输入:数据类别数 K ;标注数据 D_L ;未标注数据 D_U ;每次加入样本数 n_a 。

- 1) 用 D_L 训练 $K(K-1)/2$ 个一对一分类器;
 - 2) 将 D_U 中每个样本送入 $K(K-1)/2$ 个分类器,对每个类别进行投票,得到投票数最多的两个类别 ω_1, ω_2 ;
 - 3) 找出 ω_1, ω_2 之间的分类器,将分类器预测值 f 作为判定该样本是否加入训练集的依据;
 - 4) 找到 $|f|$ 最小的 n_a 个样本进行标注后加入 D_L ,并将其从 D_U 中删除;
 - 5) 循环几次,得最终训练集 D_S 和测试集 D_U 。
- 输出:最终训练集 D_S 和测试集 D_U 。

4 实验结果及分析

4.1 实验数据集

Pavia University 数据集,是由反射光学系统成像光谱仪(reflective optics system imaging spectrometer, ROSIS-3)在意大利帕维亚城拍摄制作,如图 4 所示。该传感器共有 115 个光谱通道,覆盖的波段范围为 $0.43 \sim 0.86 \mu\text{m}$,去除噪声和水吸收波段后,Pavia University 有 103 个高光谱波段,空间维度为 610×340 ,空间分辨率为 1.3 m ,共包含 42 776 个标注的样本,其中包括草地、树木、沥青等共 9 类地物,其假彩色图和分类真值图分别如图 4(a)、图 4(b)所示,每类样本数目详见表 1。

4.2 实验结果对比

本部分主要验证 ALbS²F 的效果,将其与随机




图 4 Pavia University 数据集
Fig.4 Pavia University data

选取样本进行比较,这里随机选取采用两种方式,一种是每类数目与主动学习相同,另一种是按照总数目相近原则平均或等比例分配给各类别。两种随机方法分别被定义为随机方法 A、B。

图 5(a)、图 5(b)、图 5(c)为 Pavia University 数据集上 ALbS²F、A、B 三种方法分别选取的样本位置图,其中彩色代表选取的训练样本,白色代表测试样本,黑色代表未被考虑的背景,由于选取样本数较少,所以彩色的点不太容易被找到。图 5(d)、图 5(e)、图 5(f)展示了 3 种方法的分类效果,图 5(g)为分类真值图。可以看到应用主动学习后,

表 1 Pavia University 数据集地物分布
Tab.1 Pavia University ground distribution

类别号	类别名	总样本数目
1	柏油	6 631
2	草地	18 649
3	碎石	2 099
4	树木	3 064
5	油漆金属板	1 345
6	裸地	5 029
7	沥青	1 330
8	联锁块	3 682
9	阴影	947

图 5(d)中分类效果几乎接近真值图。表 2 详细展示了 3 种方法的每类分类正确率情况,加粗的表示最优的结果,可以看出,主动学习的应用,可使样本数相同或相近的情况下总正确率提高 4%左右,效果提升明显。

为验证本文提出的虚拟 RGB 图像构建方式的有效性,针对 PCA 取前三维主成分和虚拟 RGB 图像进行了比较。首先,在运行时间方面,由于只是更改了系统的输入而对其他操作无变化,所以两种方




图 5 Pavia University 数据集分类结果
Fig.5 Pavia University classification results

表 2 主动学习方法正确率
Tab.2 Accuracy of active learning

类别号	ALbS ² F			随机法 A			随机法 B		
	训练	测试	正确率	训练	测试	正确率	训练	测试	正确率
1	86	6 545	1.000	86	6 545	0.958	49	6 582	0.954
2	90	18 559	1.000	90	18 559	0.984	49	18 600	0.925
3	43	20 56	0.999	43	2 056	0.957	49	2 050	0.979
4	60	3 004	0.991	60	3004	0.970	49	3015	0.998
5	12	1 333	0.999	12	1 333	0.995	49	1 296	0.999
6	43	4 986	1.000	43	4 986	0.879	49	4 980	0.966
7	21	1 309	0.995	21	1309	0.859	49	1281	0.999
8	67	3 615	0.993	67	3 615	0.940	49	3 633	0.964
9	18	929	0.982	18	929	0.906	49	898	0.961
总正确率 OA			0.998	总正确率 OA		0.956	总正确率 OA		0.951
平均正确率 AA			0.995	平均正确率 AA		0.939	平均正确率 AA		0.972
Kappa 系数 κ			0.997	Kappa 系数 κ		0.942	Kappa 系数 κ		0.936

法的耗时是相同的,主要比较其分类性能。在保证两种方法选用的训练样本完全相同的前提下,表 3 为分类正确率的比较。

表 3 两种三通道图像构造方式正确率
Tab.3 Accuracy of two three-channel image constructing

类别号	训练样本数	测试样本数	PCA 法正确率	Virtual RGB 法正确率
1	100	6 531	0.970	0.987
2	100	18 549	0.979	0.975
3	100	1 999	0.984	0.998
4	100	2 964	0.977	0.981
5	100	1 245	0.999	0.999
6	100	4 929	0.982	0.998
7	100	1 230	0.998	1.000
8	100	3 582	0.996	0.995
9	100	847	1.000	1.000
总正确率 OA			0.981	0.985
平均正确率 AA			0.987	0.993
Kappa 系数 κ			0.975	0.980

两种方法中,性能较优越的数据被加粗标出,可以看出 Virtual RGB 方法相对于 PCA 方法有较明显的优势,可以使分类总正确率提高 0.4%左右,效果如图 6 所示,其中图 6(a)为 PCA 构造法的分类效果图,图 6(b)为 Virtual RGB 方法的分类效果,图 6(c)为标注的真值图,即 GroundTruth。可以看出,图 6(a)图中有很多细微的错分现象在图 6(b)中

得到了改善。




图 6 两种三通道图像构建方式分类效果
Fig.6 Comparison between two three-channel images

5 结束语

本文通过提出一种基于全卷积空间特征和光谱特征融合,基于主动学习方式选择训练样本的高光谱图像分类算法,实现了在一定数量样本的情况下较高的分类精度,并提出了一种新的 RGB 图像构造方式。实验表明:该方式相比于主成分分析等方法更加适合用于自然图像上训练好的网络来提取空间特征。

参考文献

[1] GUALTIERI J A, CROMP R F. Support vector machines for hyperspectral remote sensing classification [J]. Proceedings of SPIE - The International Society for Optical Engineering, 1998, 3584(25): 1-28.
[2] WANG F, ZHANG C. Label propagation through

- linear neighborhoods [J]. IEEE Transactions on Knowledge & Data Engineering, 2007, 20(1): 55-67.
- [3] XIA J, GHAMISI P, YOKOYA N, et al. Random forest ensembles and extended multiextinction profiles for hyperspectral image classification[J]. IEEE Transactions on Geoscience & Remote Sensing, 2018, 56(1): 202-216.
- [4] HERAS D B, ARGÜELLO F, QUESADABARRI-USO P. Exploring ELM-based spatial-spectral classification of hyperspectral images [J]. International Journal of Remote Sensing, 2014, 35(2): 401-423.
- [5] CHEN Y, NASRADADI N M, TRAN T D. Hyperspectral image classification using dictionary-based sparse representation[J]. IEEE Transactions on Geoscience & Remote Sensing, 2011, 49(10): 3973-3985.
- [6] LI J, BIOUCAS-DIAS J M, PLAZA A. Spectral-spatial classification of hyperspectral data using loopy belief propagation and active learning[J]. IEEE Transactions on Geoscience & Remote Sensing, 2013, 51(2): 844-856.
- [7] OJALA T, PIETI K, INEN M, et al. A generalized local binary pattern operator for multiresolution gray scale and rotation invariant texture classification[J]. 2001, 24(7): 397-406.
- [8] JIA S, XIE H, DENG L, et al. Gabor feature based support vector guided dictionary learning for hyperspectral image classification [C]// IGARSS 2017-2017 IEEE International Geoscience and Remote Sensing Symposium. IEEE, 2017: 2211-2214.
- [9] PAN B, SHI Z, XU X. Hierarchical guidance filtering-based ensemble classification for hyperspectral images[J]. IEEE Transactions on Geoscience & Remote Sensing, 2017, 55(7): 4177-4189.
- [10] CHEN Y, LIN Z, ZHAO X, et al. Deep learning-based classification of hyperspectral data[J]. IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing, 2014, 7(6): 2094-2107.
- [11] CHEN Y, JIANG H, LI C, et al. Deep feature extraction and classification of hyperspectral images based on convolutional neural networks [J]. IEEE Transactions on Geoscience & Remote Sensing, 2016, 54(10): 6232-6251.
- [12] YU S, JIA S, XU C. Convolutional neural networks for hyperspectral image classification[J]. Neurocomputing, 2017, 219: 88-98.
- [13] CHEN Y, ZHAO X, JIA X. Spectral-spatial classification of hyperspectral data based on deep belief network[J]. IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing, 2015, 8(6): 2381-2392.
- [14] LI M, ZHANG N, PAN B, et al. Hyperspectral image classification based on spectral-spatial cooperative feature and deep forest[C]//9th International Conference on Image and Graphics. 2017: 325-336.
- [15] ZHONG Z, LI J, LUO Z, et al. Spectral on: a 3-D deep learning framework[J]. IEEE Transactions on Geoscience & Remote Sensing, 2017, 56(2): 8471-858.
- [16] MOU L, GHAMISI P, ZHU X. Deep recurrent neural networks for hyperspectral image classification [J]. IEEE Transactions on Geoscience & Remote Sensing, 2017, 55(7): 3639-3655.
- [17] ZHU L, CHEN Y, GHAMISI P, et al. Generative adversarial networks for hyperspectral image classification[J]. IEEE Transactions on Geoscience & Remote Sensing, 2018, 56(9): 5046-5063.
- [18] SHELHAMER E, LONG J, DARRELL T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(4): 640-651.
- [19] SUN Z, CHI M. Superpixel-based active learning for the classification of hyperspectral images [C]// Workshop on Hyperspectral Image & Signal Processing: Evolution in Remote Sensing. IEEE, 2015: 1-4.
- [20] INMACULADA D, LI J, PLAZA A, et al. Semi-supervised active learning for urban hyperspectral image classification [C]// Geoscience & Remote Sensing Symposium. IEEE, 2012: 1586-1589.
- [21] JIAO L, LIANG M, CHEN H, et al. Deep fully convolutional network-based spatial distribution prediction for hyperspectral image classification [J]. IEEE Transactions on Geoscience & Remote Sensing, 2017, 55(10): 1-15.
- [22] CHANG C, LIN C. LIBSVM: a library for support vector machines[M]. ACM, 2011: 2157-6904.
- [23] 张宁, 赵睿, 白郁, 等. 基于集成学习约束能量最小化的高光谱目标检测算法研究[J]. 上海航天, 2018, 35(1): 23-29.
- [24] 濮建福, 裴加军, 张宁, 等. 基于 CCSDS 的高光谱压缩空谱联合 FPGA 设计与实现[J]. 上海航天, 2015, 32(6): 53-57.