

引用格式:张斌,刘越岩,汪林宇.基于多特征软概率级联的土地利用/土地覆盖分类[J].资源科学,2017,39(3):557-565.
[Zhang B, Liu Y Y, Wang L Y. Land use and cover classification based on multi-feature soft probability cascading[J]. *Resources Science*, 2017, 39(3): 557-565]. DOI: 10.18402/resci.2017.03.17

基于多特征软概率级联的土地利用/土地覆盖分类

张斌,刘越岩,汪林宇

(中国地质大学土地资源管理系,武汉 430074)

摘要:为实现高分辨率遥感影像低层特征的有效组织与优化,提高特征的可判别性,重点研究了基于稀疏编码的中层特征学习、基于支持向量机(Support Vector Machine, SVM)的分类技术,提出了基于软概率级联中层特征学习模型实现土地利用/土地覆盖(Land Use and Land Cover, LULC)分类。首先,提取影像的灰度共生矩阵(Gray-level Co-occurrence Matrix, GLCM)、光谱特征、密集尺度不变特征转换(Dense Scale Invariant Feature Transform, DSIFT)作为低层特征;然后由稀疏编码分别对GLCM、DSIFT和光谱特征进行稀疏编码,并结合最大平滑方法对稀疏系数进行优化,获得影像的中层特征,并通过SVM分类器分别计算LULC类别软概率,对其级联获得影像的特征表达;最后,利用SVM分类器再次分类获得LULC分类结果。选用武汉市远城区农村居民点作为实验样区,对该方法进行了验证,实验结果表明,该方法总体精度达到88%左右;相较于提取单一低层特征的分类方法,本文算法可有效提高LULC分类精度。

关键词:高分辨率;遥感影像;图像分类;土地利用/土地覆盖;稀疏编码;支持向量机

DOI: 10.18402/resci.2017.03.17

1 引言

遥感现已成为获取地表信息的重要手段,随着传感器技术的不断发展,可获取大量高分辨率遥感影像,如IKONOS、QuickBird、World-View-2、国产资源3C以及高分1号、2号等高分辨率遥感数据,其分辨率可接近1m甚至亚米级。另外,随着无人机航拍技术的推广,可获得大量分米级超高分辨率遥感影像。目前,国内外已经加快对高分辨率影像在城市环境、精准农业、交通及道路设施、林业测量、军事目标识别和灾害评估中的应用^[1-3]。土地利用/土地覆盖(Land Use and Land Cover, LULC)分类是高分辨率遥感影像处理以及土地资源管理领域的热点及难点问题,高分辨率遥感影像提供了更为丰富的纹理结构特征信息,为解决这一难题提供了可能^[1,2]。

遥感影像分类模型经历了像元解译、局部结构特征提取、面向对象解译的发展历程。高分辨率遥

感影像分类,需综合利用计算机视觉、信号处理、模式识别等相关领域的前沿热门理论与技术方法^[3]。在利用遥感影像对LULC分类方面,国内外研究者往往将LULC进行统一分类或是对土地LULC实现变化监测。中等空间分辨率的Landsat系列卫星影像在区域尺度LULC分类中发挥了较大的作用。为获得更高的分类精度,研究者在迭代自组织数据分析算法(ISODATA, Iterative Self Organizing Data Analysis)、最大似然及平行六面体等传统分类方法基础上将模糊数学、GIS技术以及多源数据融合方法等应用于Landsat卫星影像LULC分类^[3]。在高分辨率遥感影像处理方面,发展了较多的分类方法,如面向对象的方法、决策树算法、人工神经网络、支持向量机(Support Vector Machine, SVM)等^[4-11]。这些方法大部分是基于低层特征学习的分类方法,然而基于低层特征学习的遥感影像新的分类方法仍是一个突破点,因为基于中层及高层特征学习的

收稿日期:2016-09-20;修订日期:2017-02-05

基金项目:国家自然科学基金资助项目(41601480);对地观测技术国家测绘地理信息局重点实验室开放基金(K201407)。

作者简介:张斌,男,湖南益阳人,博士,讲师,硕士生导师,主要从事高分辨率遥感影像土地利用分类。E-mail: zhangbin@cug.edu.cn

分类方法不一定在一些简单的小数据集上有效^[12]。

目前,综合利用局部特征和稀疏编码建立特征的分层学习模型是高分辨率遥感影像处理在土地利用解译领域的热点问题。基于中层特征学习的高分辨率遥感影像LULC分类方法,通常提取影像的密集尺度不变特征转换(Dense Scale Invariant Feature Transform, DSIFT)作为低层特征并对其进行稀疏编码,然后结合超像素分割、空间金字塔匹配(Spatial Pyramidal Matching, SPM)、最大空间平滑方法实现影像的中层特征表达,最后由分类器实现LULC分类^[13-17]。Chen Y.提出了一种考虑空间上下文信息的稀疏编码方法,并将其应用于高光谱遥感影像地物分类^[14]。Yang Y.在考虑特征的局部空间相关性的基础上,对传统的视觉词袋模型(Bag of Visual Words, BOVW)进行了改进,实现了场景级土地利用分类^[15]。Qi K.L.等对影像的局部特征以及光谱直接级联然后进行稀疏编码得到影像的特征表达,并与传统的场景级分类方法相比较,其分类精度更高^[16]。刘越岩等提出了一种多特征软概率级联的场景级土地利用分类方法^[17]。Cheriyadat A. M.提出了一种非监督中层特征学习方法,实现了特殊用地的检索^[18]。Hu F.等结合稀疏编码对卷积神

经网络模型(Convolutional Neural Networks, CNN)结构进行微调实现场景级土地利用分类,然而该方法的CNN模型参数缺乏土地利用类型信息,其特征可判别性不强^[19]。

中层特征学习方法在高分辨率遥感影像场景级土地利用分类以及LULC地物分类中具有较大的优势,然而由于稀疏编码的视觉字典通常是由非监督聚类方法获得的,会导致中层特征的可判别性不强。同时基于中层特征学习的分类方法通常采用DSIFT局部特征作为低层特征,未考虑光谱特征以及其它结构纹理特征。为有效实现LULC分类,本文提出了多特征软概率级联的支持向量机(Multi-features soft probability cascading and Support Vector Machine, MFSP-SVM)分类模型,在获取影像中层特征表达后,利用SVM分类器分别计算光谱、纹理以及DSIFT三种低层特征对应的软概率,对其进行级联得到影像的特征表达,最后由SVM分类器进行第二次分类得到LULC分类结果。

2 研究方法

研究方法流程如图1所示,主要分为低层特征提取、中层特征学习、软概率级联、SVM分类四个步骤。首先提取影像的低层特征,包含DSIFT特征,

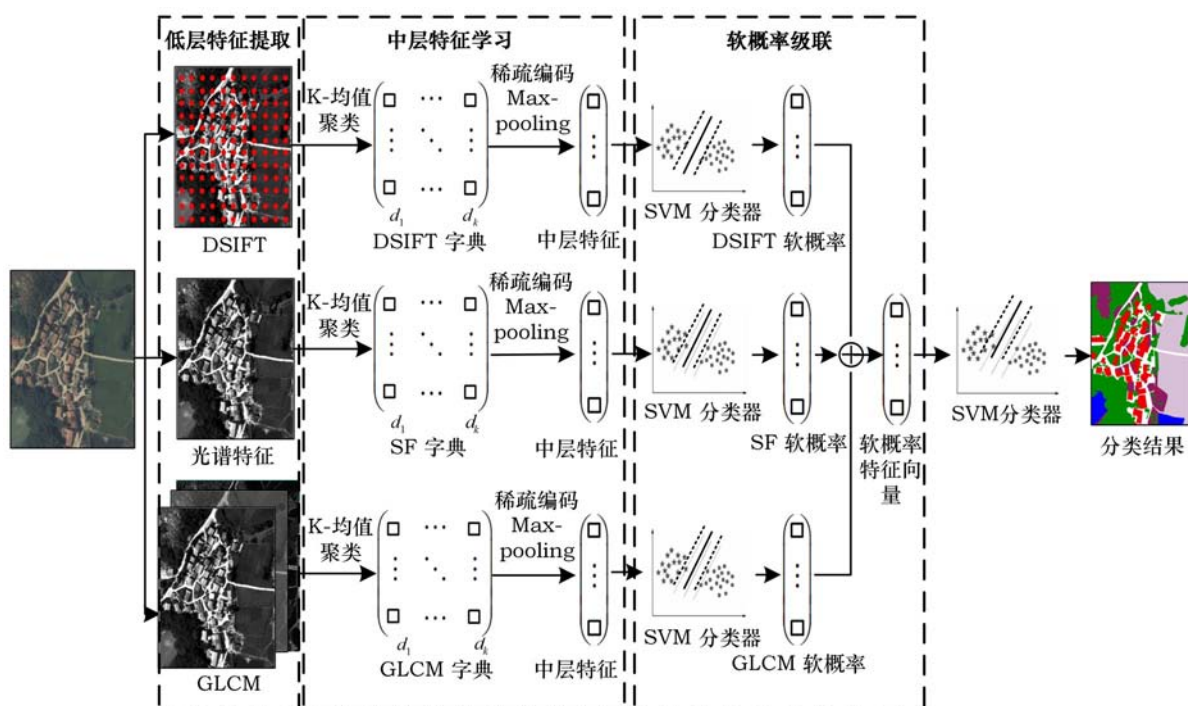


图1 研究方法流程

Figure 1 Flow diagram of research method

2017年3月

灰度共生矩阵 (Gray-level Co-occurrence Matrix, GLCM) 特征以及光谱特征。然后,采用K-均值非监督聚类的方式获得稀疏编码的字典,对低层特征进行稀疏分解,同时采用超像素分割获得影像的超像素区域,通过最大平滑进行优化获得影像的中层特征。由SVM分类器进行第一次分类,分别计算三种特征的软概率,进行级联,获得影像最终的特征表达。最后,对级联后的软概率特征向量采用SVM分类器进行第二次分类,获得LULC分类结果图。

2.1 中层特征提取

在提取低层特征后,利用视觉词袋 (Bag of Visual Words, BOVW) 模型对其进行稀疏编码。采用K-均值非监督聚类的方法,求取字典 D :

$$D=[d_1, d_2, \dots, d_K] \in \mathbf{R}^{N \times K} \quad (1)$$

式中 N 为BOVW模型低层特征维数; K 为BOVW的维数,即视觉词汇数目; \mathbf{R} 为矩阵;视觉词汇 d_k 为经K-均值聚类后获得的聚类中心。

BOVW模型,采用一种量化稀疏编码的方式:

$$\alpha = \arg \min \|x - D\alpha\|_2^2 \quad (2)$$

$$s.t. \|\alpha\|_0^0 = 1, \|\alpha\|_1^1 = 1, \alpha \geq 0$$

式中 x 为图像低层特征; α 为稀疏系数,若直接采用其作为中层特征,则缺乏周围邻域信息,因此需要对稀疏系数进一步的优化。

图像 i 实现 quick-shift 分割^[20]后,得到了 N_L 个分割区域; N_s 为分割区域与邻接区域构成的像素点的集合,本文选择了4个邻接的超像素区域对特征描述子进行空间平滑。对分割区域采用最大平滑处理,可得:

$$x_{i_l, D} = [\max_{j \in N_s} \langle \alpha_j^l \times d_1 \rangle, \dots, \max_{j \in N_s} \langle \alpha_j^l \times d_K \rangle]^T \in \mathbf{R}^K \quad (3)$$

式中 $x_{i_l, D}$ 为分割区域 l 的中层特征,整幅图像 i 的中层特征为:

$$x_D(i) = [x_D(l_1), \dots, x_D(l_{N_L})] \in \mathbf{R}^{K \times N_L} \quad (4)$$

公式(3)和公式(4)表示,经K-均值非监督聚类后获得了字典的视觉词汇,若分割区域与邻接区域中像素点的中层特征与其中的某些视觉词汇相似度越大,即可用这些视觉词汇代表该区域的特性,

进而对整个区域进行相似性度量。

2.2 软概率特征向量级联

图像 i 的三种低层特征通过稀疏编码与最大平滑后,可获得三种独立的中层特征向量 x_{i_l, D_1}^1 、 x_{i_l, D_2}^2 和 x_{i_l, D_3}^3 。 x_{i_l, D_1}^1 、 x_{i_l, D_2}^2 和 x_{i_l, D_3}^3 分别为 DSIFT、GLCM 和光谱特征通过公式(1)-公式(3)计算获得的各自的中层特征, i_l 为分割区域, D_1 、 D_2 、 D_3 为其对应的字典。首先利用SVM分类器对三种中层特征进行单独分类,分别产生三种特征对应的软概率,然后对这三种特征的软概率进行级联,将其作为影像的特征向量,由SVM分类器进行第二次分类得到LULC分类结果。

SVM分类器目标函数为:

$$f_j(x) = w_j^T \times x + b_j \quad (5)$$

式中 $j \in \{1, \dots, N_L\}$, j 为类别号; N_L 为LULC类别数目; w_j 为决策面; x 为输入特征向量; b_j 为偏置项; T 为转置运算。

图像的中层特征表达向量 x_{i_l, D_1}^1 、 x_{i_l, D_2}^2 和 x_{i_l, D_3}^3 分别作为特征向量 x 输入公式(5)中,其最终分类结果为LULC类别号 j 的软概率^[21,22]:

$$P(j|x) = \frac{1}{1 + \exp[A_j f_j(x) + B_j]} \quad (6)$$

式中 A_j 、 B_j 为待估计参数,可利用训练样本通过迭代求解获得。

根据公式(6),影像的中层特征表达向量 x_{i_l, D_1}^1 、 x_{i_l, D_2}^2 和 x_{i_l, D_3}^3 对应的软概率为:

$$\begin{aligned} P_{i_l}^1 &= [P(1|x_{i_l, D_1}^1), \dots, P(N_L|x_{i_l, D_1}^1)] \\ P_{i_l}^2 &= [P(1|x_{i_l, D_2}^2), \dots, P(N_L|x_{i_l, D_2}^2)] \\ P_{i_l}^3 &= [P(1|x_{i_l, D_3}^3), \dots, P(N_L|x_{i_l, D_3}^3)] \end{aligned} \quad (7)$$

式中 $P_{i_l}^1$ 、 $P_{i_l}^2$ 、 $P_{i_l}^3$ 均为 N_L 维的行向量; N_L 为类别数。

将公式(7)的三种软概率级联可得到图像 i 中分割区域 i_l 最终的特征向量 v ,定义如下:

$$v = [P_{i_l}^1, P_{i_l}^2, P_{i_l}^3]^T \quad (8)$$

其中特征向量 v 为 $3 \times N_L$ 维的列向量,结合SVM分类器进行第二次分类可得到LULC分类

结果。

3 研究区概况及数据预处理

3.1 研究区域概况

选取湖北省武汉市蔡甸区农村居民点作为研究区域。蔡甸区原名汉阳县,位于武汉西南,长江汉江交汇的三角地带,江汉平原末端,全区版图面积约1100.8km²。现辖11个街乡镇和1个省级经济开发区(蔡甸经济开发区),总人口约50万。境内地势由中部向南北逐减降低,中部均为丘陵岗地,坡度较缓,北部为平坦平原区,地面高程多位于20~24m之间,南部为洼地平原区,地面高程在19~22m之间。全境地貌是垄岗为主体的丘陵性湖沼平原,气候属北、中亚热带过渡性季风气候,具有热丰、水富、光足的气候特征。随着经济的快速发展,蔡甸区农村土地利用变化较快。研究样区地貌是垄岗为主体的丘陵性湖沼平原,农村宅基地是农村居民点主要用地类型,且较为分散,其中包括各种房屋、围墙及其他设施等,具有空间相关性及语义结构特性,经研究这种语义标注类别是可分的,并且这种划分对后续的农村地籍图调绘、农村宅基地使用权确权等具有指导意义。

3.2 数据来源与处理

实验数据为武汉市国土资源局提供的无人机航拍高分辨率遥感数据,拍摄时间均为2012年10

月24日,分辨率均为0.2m(如图2,图3所示)。图2原始影像大小为1024×1200,拍摄地区为武汉市蔡甸区索河镇盐山村(E113°0'57.54", N30°1'44.00");图3原始影像大小为1113×1777,拍摄地区为武汉市蔡甸区索河镇彭新村(E113°3'31.81", N30°4'25.75")。两幅影像均标注了6种地物类别。研究小组人员参照德国摄影测量与遥感协会(German Association of Photogrammetry and Remote Sensing, DGPF)的ISPRS语义分类数据集标注方法,ISPRS数据集总共标注了6种地物类别,对其中的部分地物类别进行了合并,重点标注了建筑物这种特定的地物类别,主要是为了便于后续的建筑物三维重建。小组成员对高分辨率遥感影像和土地利用现状图及地籍图进行分析,对农村居民点土地利用类型进行了语义标注,重点标注了农村宅基地,其次标注了植被、树木、道路、水体、农田,总共6种地物类别。

4 结果分析

基于Matlab 2013平台,首先采用提取影像的低层特征,通过超像素分割、稀疏编码,最大平滑方法获取其中层特征,通过由SVM分类器分别计算其软概率,进行级联获得特征表达,最后由SVM分类器获得分类结果(如图4,图5所示,见第562页)。武汉市蔡甸区索河镇盐山村居民点数据集原始影

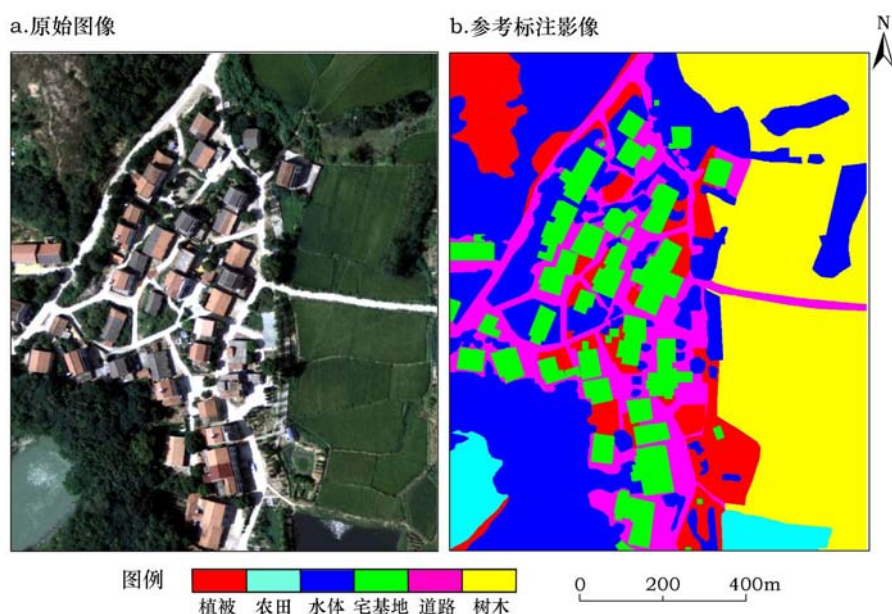


图2 武汉市蔡甸区索河镇盐山村居民点数据集

Figure 2 Dataset of Yanshan Village, Suohe Town, Caidian District, Wuhan City

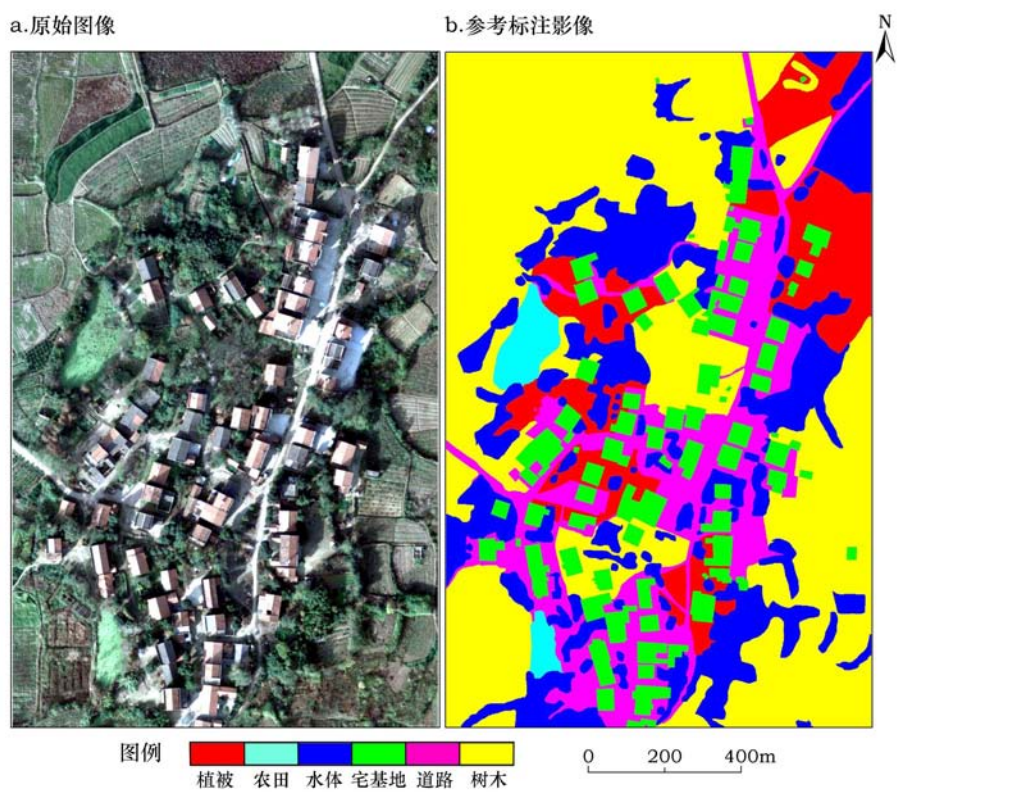


图3 武汉市蔡甸区索河镇彭新村居民点数据集
Figure 3 Dataset of Pengxin Village,Suohe Town,Caidian District,Wuhan City

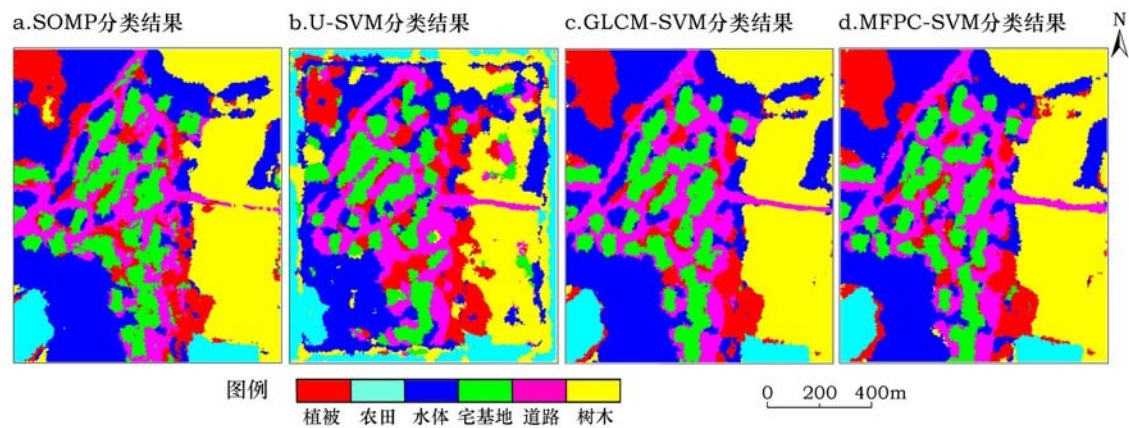


图4 武汉市蔡甸区索河镇盐山村居民点数据集分类结果
Figure 4 Classification results of the Yanshan Village,Suohe Town,Caidian District,Wuhan City dataset

像经quick shift算法^[20]分割后获得了52 654个分割区域;武汉市蔡甸区索河镇彭新村居民点数据集原始影像经quick shift算法分割后获得了92 441个分割区域,实验中,随机抽取一定数目的超像素区域作为分类器的训练样本,其余的作为测试样本,如表1,表2所示。选择了传统的SOMP^[14],U+SVM^[21]作为对比试验方法。

本文选择了三种对比试验方法:①传统的

表1 武汉市蔡甸区索河镇盐山村居民点数据集分类信息
Table 1 Classification information of Yanshancun village,
Suohe town,Caidian district,Wuhan City dataset

类别	训练样本数目	测试样本数目
低层植被	100	6 055
宅基地	100	6 518
树木	100	17 710
农田	100	13 022
水体	100	2 294
道路	100	7 055

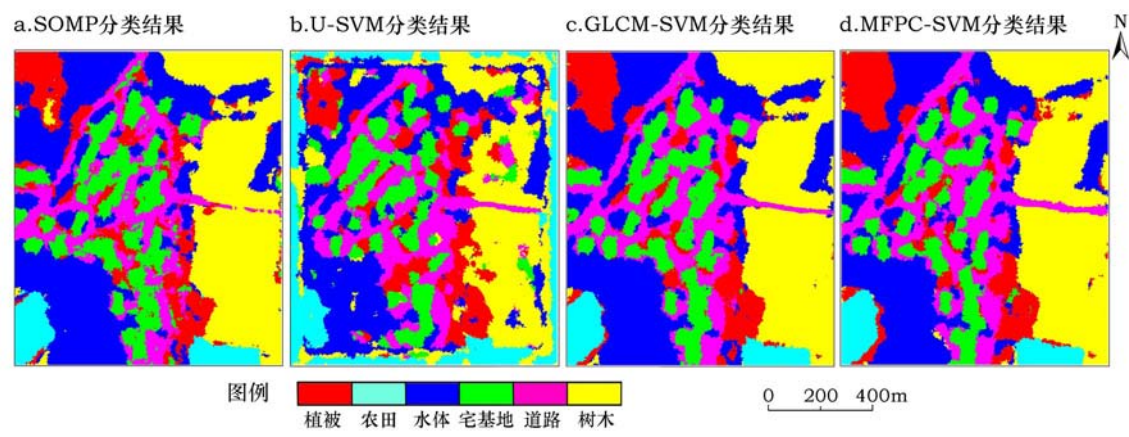


图5 武汉市蔡甸区索河镇彭新村居民点分类结果

Figure 5 Classification results of the Pengxin Village, Suohe Town, Caidian District, Wuhan City dataset

表2 武汉市蔡甸区索河镇彭新村居民点数据集分类信息

Table 2 Classification information of the Pengxin Village, Suohe Town, Caidian District, Wuhan City dataset

类别	训练样本数目	测试样本数目
低层植被	500	8 964
宅基地	500	9 215
树木	500	20 304
农田	500	41 528
水体	500	1 781
道路	500	10 649

SOMP分类方法^[14],采用光谱特征作为低层特征,经中层特征学习后最后由SVM分类器得到分类结果;②U+SVM分类方法^[21],与SOMP方法不同之处在于采用DSIFT作为低层特征;③GLCM+SVM分类方法,采用GLCM作为低层特征。训练字典参数设置为400,SVM分类器训练样本数目如表1,表2所示。

实验结果如图4,图5所示,MFSC-SVM分类方法明显优于其他三种分类方法,其中宅基地这种特定的LULC类别整体性较好,道路也较为完整的与

其他地物类别区分开。同时,GLCM+SVM分类方法要优于SOMP与U+SVM分类方法,这是因为GLCM是一种较为稳定的局部特征,包含的纹理以及结构信息较为丰富。MFSC-SVM分类方法综合了不同的低层特征,因此分类效果最好。

为分析方法的准确性以及普适性,采用了总体分类精度(Overall Accuracy, OA),Kappa系数,以及单类地物类别分类精度等指标进行定量分析评价(如表3,表4所示)。在武汉市蔡甸区索河镇盐山村居民点数据集中,MFSC-SVM分类方法精度达到了85.3%,相较于其他三种方法,分别提升了4.9%,20.7%,1.8%;在武汉市蔡甸区索河镇彭新村居民点数据集中,MFSC-SVM分类方法精度达到了87.9%,相较于其他三种方法分别提升了9.7%,10.0%,4.3%。U-SVM分类方法精度最低,主要是因为该方法采用了DSIFT特征作为低层特征,DSIFT特征能对目标的形状结构进行较好的描述表达,然而缺乏地物的光谱信息,因此分类精度较低。在农村宅基地这种特定地物分类精度方面,在

表3 武汉市蔡甸区索河镇盐山村居民点数据集不同分类方法精度

Table 3 Classification accuracy for the Yanshan Village, Suohe Town, Caidian District, Wuhan City dataset with different classifiers

分类方法	精度/%						OA/%	Kappa
	植被	宅基地	树木	农田	水体	道路		
SOMP	67.8	84.2	79.9	91.4	96.0	63.0	80.4	0.765
U-SVM	57.9	62.4	54.6	68.2	87.7	56.8	64.6	0.575
GLCM-SVM	74.1	83.6	76.2	93.1	97.6	76.3	83.5	0.802
MFSC-SVM	75.9	88.7	81.2	93.1	96.7	76.2	85.3	0.823

2017年3月

表4 武汉市蔡甸区索河镇彭新村居民点不同分类方法精度

Table 4 Classification accuracy for the Pengxin Village, Suohe Town, Caidian District,

分类方法	精度/%						OA/%	Kappa
	植被	宅基地	树木	农田	水体	道路		
SOMP	76.5	76.6	73.7	73.3	96.0	73.3	78.2	0.739
U-SVM	77.8	80.1	66.2	70.7	99.1	73.5	77.9	0.735
GLCM-SVM	82.5	83.9	76.4	80.4	99.1	79.1	83.6	0.803
MFSC-SVM	89.4	88.0	81.6	85.6	99.6	83.5	87.9	0.855

武汉市蔡甸区索河镇盐山村居民点数据集中, MFSC-SVM分类方法达到了88.7%,相较于其他三种方法,分别提升了4.5%,26.3%,5.1%;在武汉市蔡甸区索河镇彭新村居民点数据集中, MFSC-SVM分类方法达到了88.0%,相较于其他3种方法,分别提升了11.4%,7.9%,4.1%。

在进行LULC分类时,训练样本的数目会影响最后的分类结果,选择了武汉市蔡甸区索河镇盐山村居民点数据集进行实验,通过随机抽取影像中的超像素区域作为训练样本,分析其对结果的影响(如图6所示)。随着训练样本的增加,四种方法分类精度都随之提升, MFSC-SVM分类方法分类精度始终高于其他三种方法。当训练样本数由100递增至500时, MFSC-SVM分类方法的分类精度以3%速度递增。然而,当训练样本由500增至600时,总体分类精度仅提升了0.6%。当训练样本数目为1000时,其分类精度高达92.8%。




图6 训练样本数目对分类结果影响

Figure 6 The influence of training sample number per LULC class type on classification accuracy

5 结论

本文以航拍高分辨率遥感影像作为数据源,综合利用中层特征学习, SVM分类方法,对光谱特征、纹理特征(GLCM)、结构几何特征(DSIFT)进行软概率特征级联,提出了一种基于软概率特征级联的SVM分类方法,实现了武汉市蔡甸区农村居民点LULC分类。实验结果表明: MFSC-SVM分类总体精度高达88%左右, Kappa系数保持在0.85左右,高于采用单一特征作为低层特征的分类方法,能够为农村地籍图调绘、农村宅基地使用权确权、农村土地利用格局分析提供一定的科学参考。针对实验,可得出以下结论:

对4种方法的分类结果进行比较分析发现,采用单一DSIFT特征作为低层特征分类效果较差;采用GLCM特征作为低层特征的分类方法,与采用光谱特征、DSIFT特征作为低层特征的分类方法相比较,其效果更好;本文构建的多特征软概率级联模型由于综合了这三种低层特征,同时特征向量是通过SVM分类器监督训练获得的,因此特征可判别性更强,分类精度比其他三种方法更高,分类结果中农村宅基地这种特定的地物类别精度也更高。同时,本文提出的MFSC-SVM是开放的模型,可根据具体的分类需求,级联各种不同的低层特征。

参考文献(References):

- [1] 宫鹏,黎夏,徐冰,等. 高分辨率影像解译理论与应用方法中的一些研究问题[J]. 遥感学报, 2006, 10(1): 1-4. [Gong P, Li X, Xu B, et al. Interpretation theory and application method development for information extraction from high resolution remotely sensed data[J]. *Journal of Remote Sensing*, 2006, 10(1): 1-4.]

- [2] 邸向红,侯西勇,吴莉. 中国海岸带土地利用遥感分类系统研究[J]. 资源科学, 2014, 36(3): 463-472. [Di X H, Hou X Y, Wu L. Land use classification system for China's coastal zone based on remote sensing[J]. *Resources Science*, 2014, 36(3): 463-472.]
- [3] 李德仁,童庆禧,李荣兴,等. 高分辨率对地观测的若干前沿科学问题[J]. 中国科学:地球科学, 2012, 42(6): 805-813. [Li D R, Tong Q X, Li R X, et al. Current issues in high-resolution Earth observation technology[J]. *Sci. China Earth Sci*, 2012, 42(6): 805-813.]
- [4] 白穆,刘慧平,乔瑜,等. 高分辨率遥感图像分类方法在LUCC中的研究进展[J]. 国土资源遥感, 2010, (1): 19-23. [Bai M, Liu H P, Qiao Y, et al. New progress in the classification of high spatial resolution satellite images for LUCC[J]. *Remote Sensing of Land and Resources*, 2010, (1): 19-23.]
- [5] Paul A, Peter M A, Paul J C. Fine spatial resolution simulated satellite sensor imagery for land cover mapping in the United Kingdom[J]. *Remote Sensing of Environment*, 1999, 68(3): 206-216.
- [6] Olivier D, Isabelle V S, Patrice L, et al. Textural and contextual land-cover classification using single and multiple classifier system[J]. *Photogrammetric Engineering & Remote Sensing*, 2002, 68(6): 597-605.
- [7] Forkuor G, Cofie O. Dynamics of land-use and land-cover change in Freetown, Sierra Leone and its effects on urban and peri-urban agriculture- a remote sensing approach[J]. *International Journal of Remote Sensing*, 2011, 32(4): 1017-1037.
- [8] Stuart K M. Using the Normalized Difference Water Index (NDWI) within a geographic information system to detect swimming pools for mosquito abatement: A practical approach [J]. *Remote Sensing*, 2013, 5(7): 3544-3561.
- [9] 王荣,江东,韩惠,等. 高分辨率遥感影像天然林与人工林植被覆盖信息提取[J]. 资源科学, 2013, 35(4): 868-874. [Wang R, Jiang D, Han H, et al. Extracting natural and artificial forest information based on high resolution remote sensing data[J]. *Resources Science*, 2013, 35(4): 868-874.]
- [10] 李艳华,丁建丽,闫人华. 基于国产GF-1遥感影像的山区细小水体提取方法研究[J]. 资源科学, 2015, 37(2): 408-416. [Li Y H, Ding J L, Yan R H. Extracting natural and artificial forest information based on high resolution remote sensing data[J]. *Resources Science*, 2015, 37(2): 408-416.]
- [11] 陈文倩,丁建丽,李艳华,等. 基于国产GF-1遥感影像的水体提取方法[J]. 资源科学, 2015, 37(6): 1166-1172. [Chen W Q, Ding J L, Li Y H, et al. Extraction of water information based on China-made GF-1 remote sense image[J]. *Resources Science*, 2015, 37(6): 1166-1172.]
- [12] 李学龙,史建华,董永生,等. 场景图像分类技术综述[J]. 中国科学:信息科学, 2015, 45(7): 827-848. [Li X L, Shi J H, Dong Y S, et al. A survey on scene image classification[J]. *Sci. China Information Sci*, 2015, 45(7): 827-848.]
- [13] Lobel H, Vidal R, Soto A. Learning shared, discriminative, and compact representations for visual recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, 37(11): 2218-2231.
- [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] Yang Y, Newsam S. Bag-of-Visual-Words and Spatial Extensions for Land-Use Classification[C]. San Jose: ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems, 2010.
- [16] Qi K L, Wu H Y, Shen C, et al. Land-use scene classification in high-resolution remote sensing images using improved correlations[J]. *IEEE Geoscience & Remote Sensing Letters*, 2015, 12(12): 2403-2407.
- [17] 刘越岩,汪林宇,张斌,等. 基于多特征软概率级联的场景级土地利用分类方法[J]. 农业工程学报, 2016, 32(22): 266-272. [Liu Y Y, Wang L L, Zhang B, et al. Scene-level land use classification based on multi-features soft-probability cascading[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2016, 32(22): 266-272.]
- [18] Cheriadat A M. Unsupervised feature learning for aerial scene classification[J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2014, 52(1): 439-451.
- [19] Hu F, Xia G S, Hu J W, et al. Transferring deep convolutional neural networks for the scene classification of high-resolution remote sensing imagery[J]. *Remote Sensing*, 2015, 7(11): 14680-14707.
- [20] Fulkerson B, Vedaldi A, Soatto S. Class segmentation and object localization with superpixel neighborhoods[J]. *IEEE Int. Conf. on Computer Vision*, 2009, 30(2): 670-677.
- [21] Wu T F, Lin C J, Weng R C. Probability estimates for multi-class classification by pairwise coupling[J]. *Journal of Machine Learning Research*, 2004, 5(4): 975-1005.
- [22] Lee C H, Schmidt M, Murtha A, et al. Segmenting Brain Tumors with Conditional Random Fields and Support Vector Machines [C]. Beijing: Computer Vision for Biomedical Image Applications, 2005.

Land use and cover classification based on multi-feature soft probability cascading

ZHANG Bin, LIU Yueyan, WANG Linyu

(China University of Geosciences, Department of Land Resources Management, Wuhan 430074, China)

Abstract: In order to realize the effective organization and optimization of low-level features for high resolution remote sensing images, and make feature descriptors more discriminative, we focused on mid-level feature learning based on sparse coding and support vector machine (SVM) classification, and propose a land use / land cover (LULC) classification method based on soft probability cascading and mid-level feature learning model. First, the gray level co-occurrence matrix (GLCM), Dense Scale-Invariant Feature Transform (DSIFT) and spectral feature descriptors are extracted as low-level feature descriptors. Second, sparse coding is adopted to obtain the sparse coefficients of GLCM, DSIFT and spectral features, and then max-pooling methods are used for learning mid-level feature descriptors. Combined with SVM classification with training samples of LULC class types the soft probabilities of different LULC class types are calculated. Three different kinds of soft probabilities belong to each LULC class type, which takes GLCM, DSIFT and spectral features as low-level feature descriptors respectively, and are cascaded for the construction of final feature descriptors. The cascaded feature descriptors are more discriminative than unsupervised mid-level feature descriptors, because it is learned by a supervised way. This method incorporates different low-level feature descriptors effectively. Finally, using the cascaded feature descriptors, the LULC classification map is achieved by the SVM classifier in a supervised way. Taking rural residents in the district area of Wuhan City as an experimental area, our proposed method was verified by aerial high resolution remote sensing images. Experimental results show that the overall accuracy is 88%. Compared with the extraction of a single low-level feature classification method, the algorithm in this paper can effectively improve LULC classification accuracy.

Key words: high-resolution; remote sensing images; image classification; land use and land cover; sparse coding; support vector machine