

融合高分夜光和 Landsat OLI 影像的不透水面自动提取方法

唐鹏飞^{1,2,3}, 苗则朗^{4*}, 林 聪^{1,2,3}, 杜培军^{1,2,3*}, 郭山川^{1,2,3}

- (1. 南京大学 地理与海洋科学学院, 江苏 南京 210023;
2. 江苏省地理信息技术重点实验室, 江苏 南京 210023;
3. 自然资源部 国土卫星遥感应用重点实验室, 江苏 南京 210023;
4. 中南大学 地球科学与信息物理学院, 湖南 长沙 410083)

摘要: 针对监督分类提取不透水面需要人工获取大量训练样本的制约, 提出了一种亚米级高空间分辨率夜光遥感影像引导下的不透水面自动提取方法。以夜光强度信息作为先验知识, 判别对应地理位置的 Landsat8 OLI 影像元为不透水面正负训练样本后, 提取 OLI 影像的光谱和纹理特征构建特征集, 利用集成 ELM 分类器提取不透水面。选择全球 4 个具有代表性的城市作为试验区进行验证, 结果显示, 该方法在 4 个试验区的不透水面提取精度均超过 93%, Kappa 系数均在 0.87 以上。对比 BCI 指数与人工选取训练样本的不透水面提取结果, 发现该方法在 4 个试验区的总体精度均优于指数法, 主要原因是该方法相较于 BCI 指数法可以更有效地区分裸土和不透水面。提出的自动提取方法在 3 个试验区的总体精度高于或接近人工样本分类方法, 但在哈尔滨试验区的总体精度略低, 主要是因为自动选择样本过程中灯光强度弱的不透水面未被选为正样本导致部分漏提。研究表明, 高分辨率夜光数据可以作用遥感影像解译与地物提取的先验知识, 引导自动分类提取模型的构建, 具有较高的实用性。

关键词: 不透水面; 夜光遥感; 极限学习机; 旋转森林

中图分类号: TP 79 文献标识码: A

An automatic method for impervious surface area extraction by fusing high-resolution night light and Landsat OLI images

TANG Peng-Fei^{1,2,3}, MIAO Ze-Lang^{4*}, LIN Cong^{1,2,3}, DU Pei-Jun^{1,2,3*}, GUO Shan-Chuan^{1,2,3}

- (1. School of Geography and Ocean Science, Nanjing University, Nanjing 210023, China;
2. Jiangsu Provincial Key Laboratory of Geographic Information Science and Technology, Nanjing University, Nanjing 210023, China;
3. Key Laboratory for Land Satellite Remote Sensing Applications of Ministry of Natural Resources, Nanjing 210023, China;
4. School of Geoscience and Info-Physics, Central South University, Changsha 410083, China)

Abstract: Supervised classification is a vital approach to extract impervious surface areas (ISA) from satellite images, but the training samples need to be provided through heavy manual work. To address it, this study proposed an automatic method to generate training samples from high-resolution night light data, considering that nighttime lights generated by human activities is strongly correlated with impervious surface. First, positive and negative samples for ISA were located according to the distribution of nighttime lights. Second, the feature sets were constructed by calculating the spectral and texture feature from the OLI images. Third, an ensemble ELM classifier was selected for ISA classification and extraction. Four large cities were selected as study areas to examine the performance of the

收稿日期: 2019-08-16, 修回日期: 2019-12-16

Received date: 2019-08-16, Revised date: 2019-12-16

基金项目: 国家自然科学基金重点项目(41631176)

Foundation items: Supported by the National Natural Science Foundation of China (41631176)

作者简介(Biography): 唐鹏飞(1997—), 男, 安徽合肥人, 博士生, 主要研究领域为遥感图像智能处理。E-mail: Sgos_tpf@smail.nju.edu.cn

* 通讯作者(Corresponding author): zelang.miao@csu.edu.cn; dupjrs@126.com

proposed method in different environment. The results show that the proposed method can automatically and accurately acquire ISA with an overall accuracy higher than 93% and Kappa coefficient higher than 0.87. Furthermore, comparative experiments by biophysical composition index (BCI) and classification by manual sample were conducted to evaluate its superiority. The results show that our method has better separability for ISA and soil than the BCI. In general, the proposed method is superior to manual methods, except Harbin mostly because some impervious surfaces with weak light intensity are selected as negative samples.

Key words: impervious surface area, nighttime light remote sensing, extreme learning machine, rotation forest

PACS: TP79

引言

不透水面是指城市中各种不透水材料覆盖的地表面,主要包括与交通相关的土地(如道路,街道和停车场)、建筑屋顶(商业,住宅和工业区)和其他构筑用地等^[1]。不透水面既是衡量城市化的指标^[2],也是评估城市环境质量的重要指标^[3]。不透水面的扩张对城市环境有着多种直接或间接的影响,如影响地表径流^[4]、间接加剧水质恶化^[5]、增加市政排水和城市防洪压力^[6]、增强城市热岛效应^[7-8]等。因此,快速准确地提取不透水面对研究城镇化过程、城市水热环境、海绵城市建设和可持续发展具有至关重要的意义。

目前遥感影像解译已逐渐成为提取不透水面的主要手段^[1,9],常用方法包括指数法和监督分类方法。指数法是通过构建光谱指数来增强不透水面信息,其中包括植被指数^[10-12]、ISA 指数^[13]、归一化建设指数 NDBI (Normalized Difference Built-up Index)^[14]、不透水面指数 NDISI (Normalized Difference Impervious Surface Index)^[15]、BCI (Biophysical Composition Index) 指数^[16]等。这些光谱指数虽然可以有效增强不透水面信息,但如何确定阈值仍然是个亟待解决的问题,而且多数指数难以准确区分不透水面和裸土信息^[9]。监督分类法通过选择样本和特征训练分类器,获取不透水面范围,常用的分类器包括决策树^[17]、随机森林(Random Forest, RF)^[18]、支持向量机(Support Vector Machines, SVMs)^[19]等。基于监督分类的不透水面提取都需要准确且符合研究区真实地表分布的样本集。但是,训练可靠的分类器需要大量的人工标记样本,面向长时间序列或大范围应用时,往往难以获得足够的训练样本。这些样本集大多数依靠人工从高分辨率卫星影像上标记,是劳动密集型和高度耗时的工作,且精度高度依赖先验知识。

相比其他光学遥感卫星影像,夜间灯光(Night-time Light, NTL)可以更直接地反映人类活动和人工地表^[20],为研究城市化和其带来的影响提供了独特的视角。因此一些 NTL 数据如 DMSP/OLS (Defense Meteorological Satellite Program-Operational Linescan System)、NPP/VIIRS (National Polar-Orbiting Partnership's Visible Infrared Imaging Radiometer Suite)、珞珈一号等也被应用于不透水面提取^[21-22]。

综合使用光学和灯光遥感数据被认为是提高不透水面提取精度的方法之一^[23]。近年来,将光学影像和夜间灯光影像结合,综合利用光学影像中的纹理和光谱等特征、夜间灯光影像中的亮度和形态学信息提取不透水面,取得了理想的效果^[24-27]。但是,目前使用的 NTL 影像以百米级分辨率为主,难以满足区域精细提取的要求。

提出一种结合高分辨率夜间灯光数据与 Landsat8 OLI 多光谱遥感影像的不透水面自动提取方法 RoF-ELM,该方法的优点在于:(1)无需人工勾选样本,直接通过灯光数据辅助构建决策规则,从 OLI 影像中自动分离出不透水面的正负样本标签;(2)相比于低分辨率的灯光数据,选用高分夜光数据辅助分离样本可以进一步提升样本的准确性;(3)考虑到自动选取的正负样本比例与地表真实分布的不确定性,采用集成学习的方法,训练多个极限学习机并通过多数投票法获得最终的提取结果,能够有效地提高精度和稳定性。

1 数据源与方法

1.1 研究区与数据源

选择四个典型城市作为试验区域进行不透水面提取,分别是北京、哈尔滨、巴黎和伦敦,这四个城市具有不同的城市形态、植被分布以及经济发展水平。选择这四个城市可以有效检测自动提取方

法对于不同的建成区特征的有效性。

使用的高分辨率夜光数据由中国商业卫星吉林1号03B星(JL1-3B)采集。JL1-3B卫星由长光卫星技术有限公司发射,于2017年4月1日开始正式运营(<http://www.charminglobe.com>)。JL1-3B卫星的夜间灯光影像具有高空间分辨率(0.92m),具有红、绿、蓝三个波段,相比仅具有单波段的DMSP/OLS、NPP/VIIRS等具有更多的光谱信息,最低可以探测到 $7E^{-7}$ W/cm²/sr的光,所探测到的光与人类活动密切相关^[28],可以有效指示不透水面区域^[22],选取不透水面的训练样本,提高不透水面的提取精度和效率。

对于JL1-3B数据,在辐射校正的基础上,对于图像的每个波段,采用中值滤波来消除异常像素和异常值^[29]。将处理后的JL1-3B数据重投影,并选择控制点进行几何校正,采用最邻近插值法将校正后的影像重采样至30 m。

由于JL1-3B卫星拍摄的影像为多光谱数据,无法直接量化灯光的亮度,对此本文采用以下方程将其转化为灰度亮度^[30]:

$$\text{Brightness} = 0.2989 * \text{Red} + 0.5870 * \text{Green} + 0.1140 * \text{Blue} \quad (1)$$

其中Brightness代表JL1-3B夜光数据的灰度亮度值,Red、Green、Blue分别对应着JL1-3B夜光数据中的相应波段的亮度值。

从USGS网站上获取与JL1-3B卫星采集时间相近的无云覆盖的Landsat8 OLI影像。利用ENVI对OLI数据进行辐射定标等预处理,用FLAASH模型对定标后的影像进行大气校正。

将预处理后的JL1-3B和Landsat8 OLI影像输入到图2中进行不透水面自动提取。

表1列出了各影像的具体拍摄日期。图1为北京JL1-3B卫星影像和对应区域的Google Earth影像。

1.2 样本选择策略

JL1-3B夜光数据分辨率高,但由于存在高层建

表1 卫星影像获取日期表

Table 1 Satellite image acquisition date

序号	试验区	Landsat8 OLI影像获取时间	JL1-3B获取时间(当地时间)
1	哈尔滨	2017/4/14	2017/3/20 21:35
2	北京	2017/5/7	2017/4/8 22:16
3	伦敦	2017/6/10	2017/3/31 21:43
4	巴黎	2017/1/19	2017/2/24 22:33

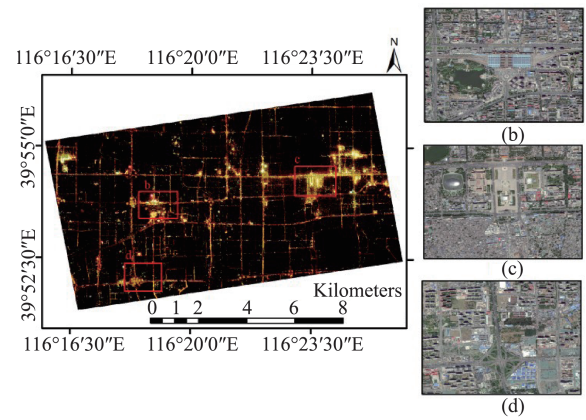


图1 北京市JL1-3B灯光影像和对应区域Google Earth影像
Fig. 1 JL1-3B Image in Beijing and Subsets of selected areas in the JL1-3B image for Google Earth Images

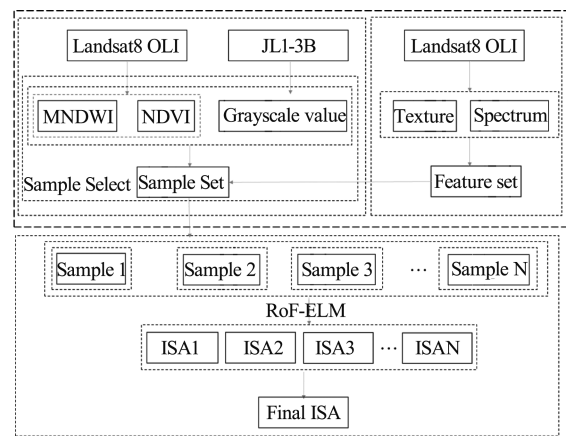


图2 自动提取方法算法流程

Fig. 2 Auto-extraction method algorithm flow

筑物或树冠遮挡等原因使得部分灯光无法被传感器探测到。此外,由于卫星过境时间不是最佳夜间灯光观测时间,存在建成区没有检测到灯光的可能。VIIRS中的低光成像检测限为 $2E^{-11}$ W/cm²/sr^[31],而JL1-3B的低光成像检测限为 $7E^{-7}$ W/cm²/sr,因此JL1-3B可能会漏提一些低亮度的不透水面。为了提高自动提取样本的正确率,结合灯光数据和Landsat OLI光谱指数建立决策树来选取样本。

对于正样本,将处理后的JL1-3B影像中灰度亮度值不小于89 nW/cm²/sr的像元所指示的OLI影像中的像元作为ISA初始的正样本^[32]。

对于负样本,该类样本选取需同时满足以下条件:(1)JL1-3B影像灰度亮度值小于89 nW/cm²/sr;(2)OLI计算的植被指数(Normalized Difference Vegetation Index, NDVI)或水体指数(Modified Normalized Difference Water Index, MNDWI)大于某一个阈

值。其中 MNDWI 的阈值选择 0^[15], NDVI 的阈值由最大类别间差法计算获得^[33]。

1.3 特征提取

为了提高不透水面的提取精度,特征集由光谱特征和纹理特征组成。光谱特征选择 OLI 第一波段至第七波段,纹理特征通过灰度共生矩阵对 OLI 影像主成分分析(Principal Component Analysis, PCA)后的前四个分量提取,取前四个主成分是由于其累计方差贡献率达到了 99.95% 以上,几乎集中了所有波段的信息。纹理特征取均值、方差、协同性、对比度、非相似性、熵值、二阶矩、相关性 8 个常用的纹理测度。因此,研究中共选择 39 个特征(7 个光谱特征和 32 个纹理特征)形成分类特征集。

1.4 分类算法

不透水面提取方法选择一种结合旋转策略(Rotation Forest, RoF)^[37]的极限学习机(Extreme Learning Machine, ELM)^[34-35]集成分类器 RoF-ELM,该方法既弥补了 RoF 算法容易出现过拟合的现象,也可以较好地提高 ELM 算法的泛化能力,相较于其他集成分类算法具有一定的优势^[38]。此外该集成分类算法采用 Bootstrap 采样,可以有效地减少类别不平衡带来的误差影响^[36]。

RoF-ELM 算法的实现流程如下表:

1.5 精度评估

为了评估自动提取方法的精度,从高分辨遥感影像中随机选择区域进行人工目视判读,作为验证精度的参考数据,验证样本的像元个数分别为巴黎 9827,北京 5929,哈尔滨 9115,伦敦 8789。以 Kappa 系数和总体分类精度(Overall Accuracy, OA)作为模型的精度评价指标。本文同时为了进一步探究提出的自动提取方法的有效性,选择指数法和人工选择样本的监督分类法两种传统不透水面提取方法进行比较,并与 FromGLC30^[38]产品对比。

由于 BCI 指数相对于其他不透水面指数对不透水面有更好的区分性,利用 BCI 指数对四个试验区进行不透水面提取^[16]。BCI 的阈值通过人工判断,选取不透水面和非不透水面的样本,根据不透水面样本和非不透水面样本的统计直方图选择。目视监督分类法利用人工从高分辨数据上选择训练样本,利用 RoF-ELM 分类器提取不透水面,两种方法中所选择的样本数量,特征维数和分类器的参数均一致。

最后为了检验本文所提出的集成分类器的优

算法流程:RoF-ELM 算法

训练部分

输入 X : 训练样本数据集($N*n$ 矩阵)

Y : 训练样本数据对应的标签集($N*1$ 矩阵)

L : 基分类器的个数(ELM 的个数)

K : 特征子集的数目

F : 特征集

For $i=1:L$

将特征集 F 随机分为 K 个子集,对于第 E_i 个基分类器,用 F_{ij} 表示对应所使用的数据集 X_{ij} 的第 j 个属性集。

For $j=1:K$

对训练样本集进行 bootstrap 采样,采样数量为原数据的 75%,得到子样本集 X'_{ij} 。

用 PCA 对子样本集 X'_{ij} 进行特征提取,在增大数据差异性同时可以减少变量之间的相关性,计算得到分类器 E_i 的第 j 个特征子集主成分系数 C_{ij} 。

End for

将得到 K 个主成分系数 C_{ij} 储存在 R_i 中,并根据原数据属性集进行重新排列得到稀疏旋转矩阵 R'_i ,

利用新的训练数据集 $[XR'_i, Y]$, 训练极限学习机 E_i 。

End for

分类阶段

对于一个待分类样本 x , 对训练好的 L 个极限学习机的分类结果进行多数投票获得最终标签。

势,选择随机森林分类器进行比较。两种方法中所选择的样本数量,特征维数均一致,其中随机森林中选择树的数量与 RoF-ELM 中的基分类器数量保持一致。

2 结果

所用方法 RoF-ELM 构造旋转矩阵选择的特征子集中所包含的特征的个数选择文献中的最佳参数 3^[39], ELM 神经网络的隐含层节点个数选择为 100。对于集成分类方法而言,选择的基分类器个数不同会导致不同的分类结果。因此,还探究了基分类器个数对 RoF-ELM 分类结果的影响。实验表明,在基分类器数为 30 时, RoF-ELM 的分类结果最好。综上, ELM 隐含层节点个数选择为 100, 旋转矩阵选择的子特征个数为 3, 基分类器个数设置为 30。为了研究提出的不透水面自动提取方法的适用性,对巴黎、北京、哈尔滨和伦敦四个城市进行试验。四个城市的 Landsat8 OLI 影像与提取的不透水面(红色区域)如图 3 所示。同时对提取结果进行精度评估,表 2 为精度评估结果。

研究中可以看出四个研究区域的 ISA 提取 OA 精度都在 93% 以上,其中伦敦的提取精度效果最

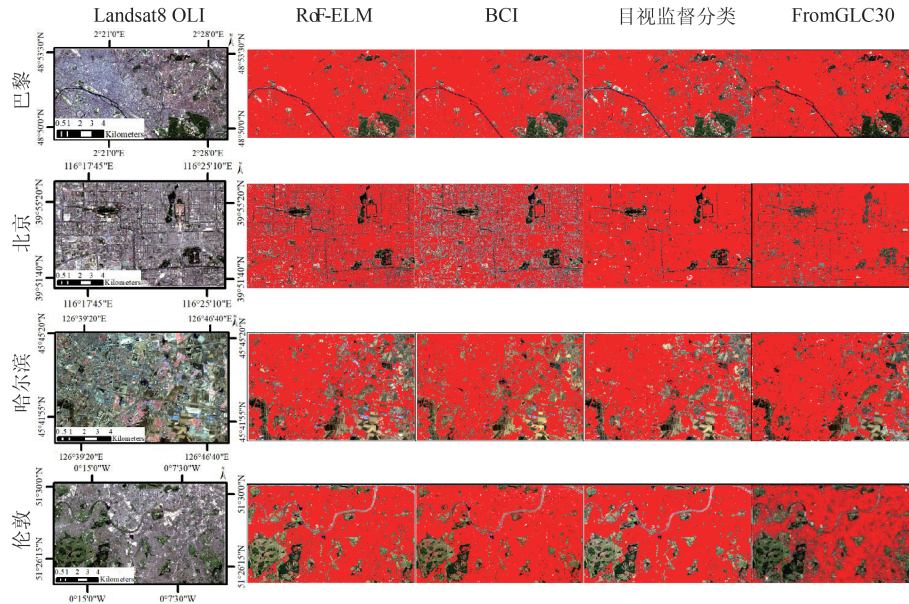


图3 OLI影像与不透水面提取结果

Fig. 3 Images and Impervious Surface Area

表2 几种不透水面提取方法精度对比表

Table 2 Comparison of accuracy of several ISA extraction methods

研究区	RoF-ELM		监督分类		BCI指数法		RF分类器		FROMGLC30	
	OA(%)	Kappa	OA(%)	Kappa	OA(%)	Kappa	OA(%)	Kappa	OA(%)	Kappa
巴黎	93.89	0.8789	93.34	0.8573	91.44	0.8202	89.70%	91.34%	90.52%	92.01%
北京	94.82	0.8900	94.74	0.8863	88.47	0.7907	0.8066	0.8106	0.8018	0.8435
哈尔滨	93.85	0.8789	97.24	0.9528	91.60	0.8368	93.35%	97.33%	76.98%	93.42%
伦敦	97.13	0.9436	97.53	0.9482	92.37	0.8564	0.8615	0.9433	0.5648	0.8758

好,其OA精度为97.13%,Kappa系数为0.9436。北京的提取效果其次,其OA精度为94.82%,而Kappa系数为0.8900。哈尔滨和巴黎提取的总体精度接近,OA精度分别为93.85%和93.89%,而Kappa系数分别为0.8789和0.8709。表2显示,4个试验区中有3个试验区文中提出的RoF-ELM分类器获得更高的提取精度,而RF算法仅有一个研究区精度略高。该结果验证了基于RoF-ELM集成分类器可以有效地提高分类准确性。总体来说,本文提出的自动提取方法具有较高的精度和适用性。

3 讨论与分析

3.1 裸土与不透水面的区分

在不透水面提取中,如何区分裸土和不透水面一直是研究的难点。虽然部分裸土的光谱特征与不透水面相似,但是由于裸土在夜晚没有灯光信息,通过加入高分辨的灯光辅助信息可以有效地将不透水面与裸土区分开来(如图4中的区域1和

区域2)。

3.2 混合像元的处理

从图4中的区域3和区域4两种典型混合像元严重的区域中不透水面提取结果来看,本文方法能够很好的处理不透水面与透水面的边缘部分。对比目视监督分类和BCI指数法,在城市绿地、裸土和不透水面混杂的城市中心区域,可以有效、准确地提取出不透水面。这主要是由于人工采样方法所得到的样本都是光谱特征十分明确的样本,缺少对混合像元类型样本的采集,因此容易产生对ISA的漏分误差;而本方法在选取样本时均为随机采样,使得样本在空间分布和光谱特征上具有更好的代表性和随机性。

3.3 与FROMGLC30的对比

FROMGLC30^[38]是清华大学等单位利用Landsat系列数据和国产卫星影像制作的全球土地覆盖数据集。其中包括10/15/17年三期数据产品。选择2017年数据产品与本文提取方法进行对比。图3第

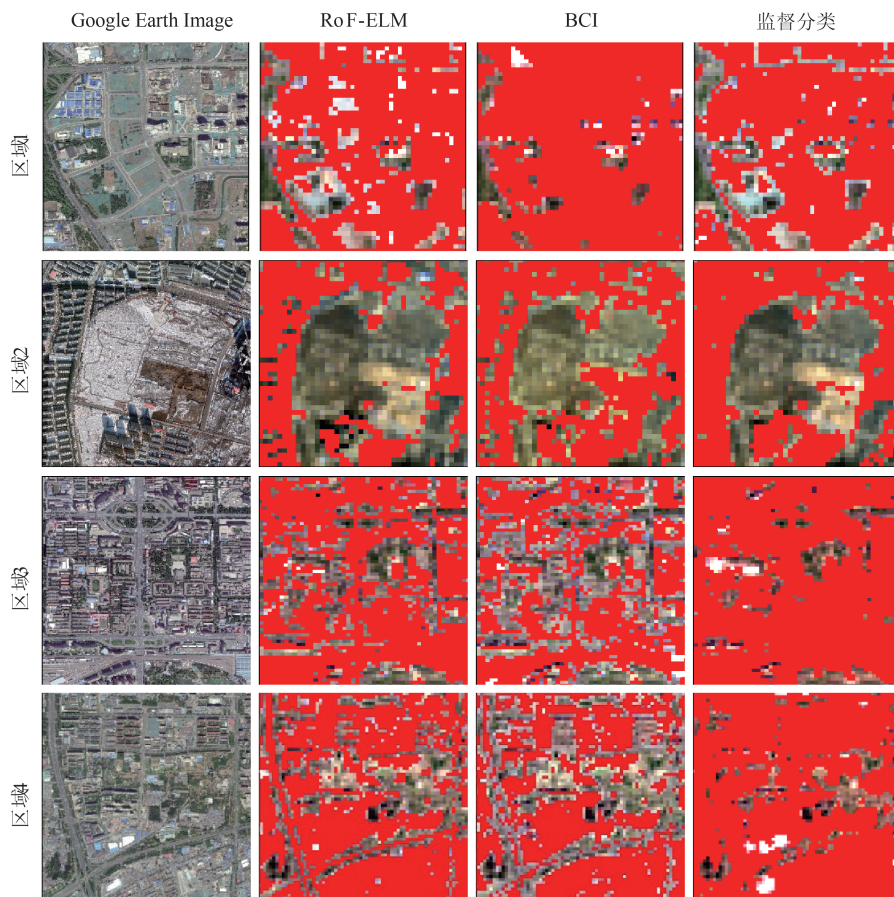


图4 四个区域不透水面提取结果对比

Fig. 4 Comparison of ISA extraction results in four typical areas

5列和图5为提取效果的比较分析图。

通过表2,图3和图5可以看出,RoF-ELM精度均优于FROMGLC30产品,在制图效果上具有一定的优势(图5区域2),特别是对于准确区分城市不透水面和城市绿地上具有一定的优势。

3.4 误差分析

根据表2的精度检验,在三种提取方法(RoF-ELM、监督分类、BCI指数法)中,RoF-ELM方法在四个试验区的提取效果明显优于指数法,在除哈尔滨外的三个城市中目视监督分类方法在总体精度上接近或者更优。RoF-ELM在哈尔滨的OA为93.85%,Kappa系数为0.8789,而监督分类方法的OA为97.24%,Kappa系数为0.9528。进一步分析发现,在哈尔滨ISA的自动提取方法中,漏分了部分不透水面,这些不透水面在OLI影像中表现为蓝色斑块(如图6所示),且在JL1-3B中的灰度亮度值均小于 $89 \text{ nW/cm}^2/\text{sr}$,所以在样本自动选择中未将该类标记为不透水面。由此可以看出,单个的灯光数据是对城市人类活动的一个瞬时观测,并不能记录

完整的城市信息,而本文提出的方法依赖灯光数据引导自动选取样本,因此最终的结果存在对不透水面漏分的问题。

综合来看,本文提出的联合高空间分辨率夜光遥感数据自动选取样本的集成提取方法具有较大的优势。对比利用BCI指数法提取不透水面,该方法在精度和制图上都拥有着明显优势,通过利用灯光数据,可以有效地区分裸土和不透水面。对比监督分类的方法,RoF-ELM方法在精度上与其保持一致或者精度接近,说明利用灯光数据和指数规则所提取出的样本具有较高的准确性,且该方法全程自动,无需人为干涉,这相对以往研究需要依赖一定的人工样本是一个重要的改进。

4 结论

提出了一种联合高空间分辨率夜光遥感数据JL1-3B与Landsat8 OLI多光谱影像的不透水面自动提取方法。该方法综合利用夜间灯光信息与光谱信息选取不透水面正负样本,通过光谱和纹理特征

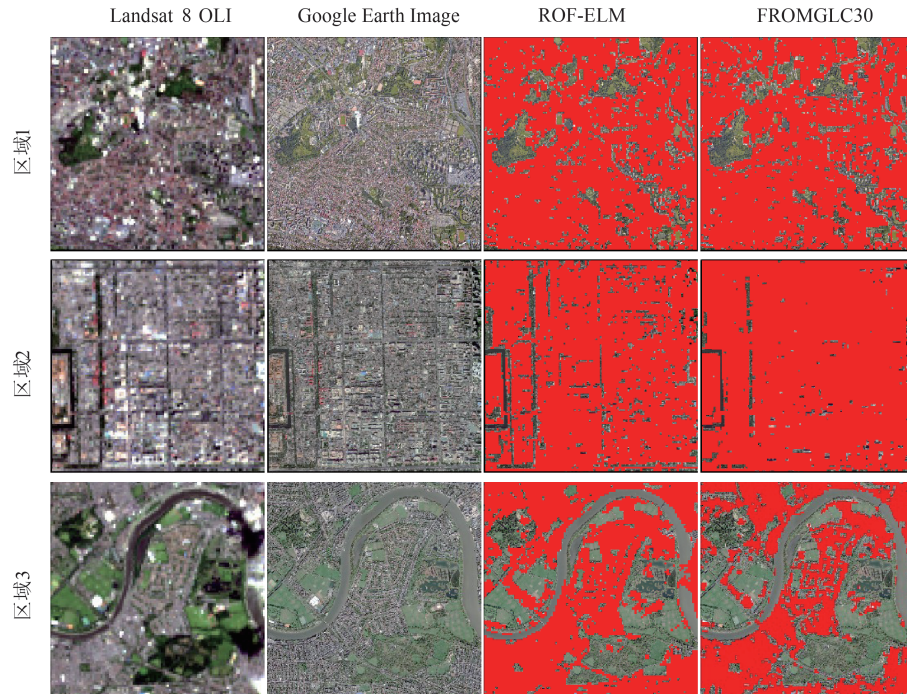


图5 三个区域不透水面提取结果对比

Fig. 5 Comparison of ISA extraction results in three typical areas

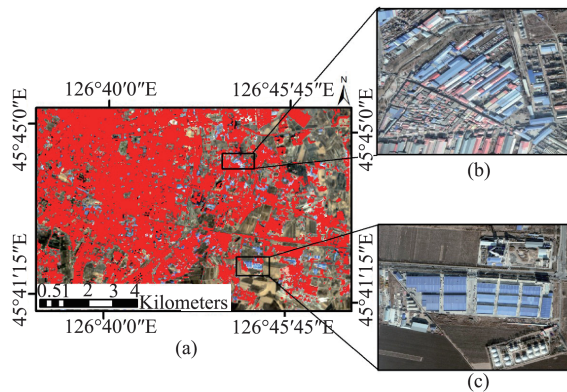


图6 (a)为哈尔滨自动提取不透水面分类结果,(b)(c)为相应区域在Google Earth上高分辨影像

Fig. 6 (a) is the result of the automatic extraction of ISA in Harbin, (b) (c) for the corresponding area on Google Earth images

构建特征集,利用基于旋转策略的ELM集成分类器实现不透水面自动分类提取。本文主要结论如下:

(1) RoF-ELM不透水面自动提取方法的优势在于不需要任何人工预先标记的训练样本,而是利用灯光数据和OLI光谱指数建立规则自动选择不透水面正负样本,在四个区域提取效果很好,都具有较高的OA精度和Kappa系数,从而节省大量的人力物力,极大地提高了提取效率。

(2) 对比RF分类算法,RoF-ELM集成分类算

法可以获得更好的分类性能,能够提高或保持好的分类准确率。

(3) 对比其他不透水面提取方法,RoF-ELM方法在精度上明显优于BCI指数法,原因在于加入灯光信息后,可以有效准确地将不透水面和裸土分开。对比人工从高分辨影像上选择样本分类的方法,在三个试验区的提取效果与其保持一致或精度接近,在哈尔滨的提取效果相较于目视监督分类的方法略差。

提出的方法融合多源遥感影像数据提供的地物信息、集成多个分类器的多样性结果,实现了对研究区的不透水面自动提取,相对于以往需要人工选择样本是一个重要的改进。总之,在城市尺度上对于不透水面的快速和精细提取实现了创新性的研究,具有一定的指导意义和实用意义。

References

- [1] Weng, Q. Remote sensing of impervious surfaces in the urban areas: Requirements, methods, and trends [J]. *Remote Sensing of Environment*, 2012, **117**: 34-49.
- [2] Liu Z., He C., Zhang Q., Huang, *et al.* Extracting the dynamics of urban expansion in China using DMSP-OLS nighttime light data from 1992 to 2008 [J]. *Landscape and Urban Planning*, 2012, **106**: 62 - 72.
- [3] Arnold, C. L. and C. J. Gibbons. Impervious Surface Coverage: The Emergence of a Key Environmental Indicator [J].

- Journal of the American Planning Association*, 1996, **62** (2): 243–258.
- [4] Weng Q. Modeling Urban Growth Effects on Surface Runoff with the Integration of Remote Sensing and GIS [J]. *Environmental Management*, 2014, **28**(6): 737–748.
- [5] Hurd J D, Civco D L. Temporal characterization of impervious surfaces for the State of Connecticut [C]//ASPRS Annual Conference Proceedings, Denver, Colorado. 2004.
- [6] Brun S. E., Band L. E. Simulating runoff behavior in an urbanizing watershed [J]. *Computers, Environment and Urban Systems*, 2000, **24**: 5–22.
- [7] Yang L., Huang C., Homer C. G., et al. An approach for mapping large-scale impervious surfaces: Synergistic use of Landsat-7 ETM+ and high spatial resolution imagery [J]. *Canadian Journal of Remote Sensing*, 2003, **29**: 230–240.
- [8] Yuan F, Bauer M. E. Comparison of impervious surface area and normalized difference vegetation index as indicators of surface urban heat island effects in Landsat imagery [J]. *Remote Sensing of Environment*, 2007, **106**: 375–386.
- [9] Xu H, Wang M. Remote sensing-based retrieval of ground impervious surfaces [J]. *Journal of Remote Sensing* (徐涵秋, 王美雅. 地表不透水面信息遥感的主要方法分析. 遥感学报), 2016, **20**(5): 1270–89
- [10] Gillies R. R., Box J. B., et al. Effects of urbanization on the aquatic fauna of the Line Creek watershed, Atlanta — A satellite perspective [J]. *Remote Sensing of Environment*, 2003, **86**: 411–422.
- [11] Carlson T. N. Analysis and prediction of surface run off in an urbanizing watershed using satellite imagery [J]. *Journal of the American Water Resources Association*, 2004, **40** (4): 1087–1098.
- [12] Boegh E., Poulsen R. N., Butts M., et al. Remote sensing based evapotranspiration and runoff modeling of agricultural, forest and urban flux sites in Denmark: From field to macro-scale [J]. *Journal of Hydrology*, 2009, **377** (3–4): 300–316.
- [13] Carlson T N and Arthur S T The impact of land use—land cover changes due to urbanization on surface microclimate and hydrology: a satellite perspective [J]. *Global and Planetary Change*, 2000, **25**(1/2): 49–65.
- [14] Zha Y., et al. Use of normalized difference built-up index in automatically mapping urban areas from TM imagery [J]. *International Journal of Remote Sensing*, 2003, **24** (3): 583–594.
- [15] Xu H Q. Analysis of impervious surface and its impact on urban heat environment using the normalized difference impervious surface index (NDISI) [J]. *Photogrammetric Engineering and Remote Sensing*, 2010, **76** (5): 557–565.
- [16] Deng C B and Wu C S. BCI: a biophysical composition index for remote sensing of urban environments [J]. *Remote Sensing of Environment*, 2012, **127**: 247–259.
- [17] Li C, Wang J, Wang L, et al. Comparison of Classification Algorithms and Training Sample Sizes in Urban Land Classification with Landsat Thematic Mapper Imagery [J]. *Remote sensing*, 2014, **6**(2): 964–983.
- [18] Rodriguez-Galiano V. F., et al. An assessment of the effectiveness of a random forest classifier for land-cover classification [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2012, **67**: 93–104.
- [19] Bulut, S. and A. Gunlu. Comparison of Different Supervised Classification Algorithms for Land Use Classes [J]. *Kastamonu University Journal of Forestry Faculty*, 2016, **16**(2): 528–535.
- [20] Sutton P., et al. Census from Heaven: An estimate of the global human population using night-time satellite imagery [J]. *International Journal of Remote Sensing*, 2001, **22**(16): 3061–3076.
- [21] Xie Y., et al. Temporal variations of artificial nighttime lights and their implications for urbanization in the conterminous United States 2013–2017 [J]. *Remote Sensing of Environment*, 2019, **225**: 160–174.
- [22] Ou J., et al. Evaluation of Luojia 1-01 nighttime light imagery for impervious surface detection: A comparison with NPP-VIIRS nighttime light data [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2019, **81**: 1–12.
- [23] Zhang Q. L., et al. Building a Better Urban Picture: Combining Day and Night Remote Sensing Imagery [J]. *Remote Sensing*, 2015, **7**(9): 11887–11913.
- [24] Cheng X, Wu W, Xia L, et al. Automatic Extraction Method for Impervious Surface Area by Integrating Night-time light Data and Landsat TM Images [J]. *Journal of Geo-Information Science* (程熙, 吴炜, 夏列钢, 等. 集成夜间灯光数据与 Landsat TM 影像的不透水面自动提取方法研究. 地球信息科学学报), 2017, **19**(10): 1364–74.
- [25] Ma X., et al. Optimized Sample Selection in SVM Classification by Combining with DMSP-OLS, Landsat NDVI and GlobeLand30 Products for Extracting Urban Built-Up Areas [J]. *Remote Sensing*, 2017, **9**(3): 236.
- [26] Zhang, X. and P. Li. A temperature and vegetation adjusted NTL urban index for urban area mapping and analysis [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2018, **135**: 93–111.
- [27] Kuang W, Mapping global impervious surface area and green space within urban environments [J]. *In Journal of SCIENTIA SINICA Terrae* (匡文慧. 全球城市人居环境不透水面与绿地空间特征制图. 中国科学: 地球科学), 2019, **49**(07): 1151–1168.
- [28] Du M., et al. Modeling the Census Tract Level Housing Vacancy Rate with the Jilin1-03 Satellite and Other Geospatial Data [J]. *Remote Sensing*, 2018, **10**(12).
- [29] Elvidge D. C., et al. Automatic Boat Identification System for VIIRS Low Light Imaging Data [J]. *Remote Sensing*, 2015, **7**(3).
- [30] Grundland, M. and N. A. Dodgson. Decolorize: Fast, contrast enhancing, color to grayscale conversion [J]. *Pattern Recognition*, 2007, **40**(11): 2891–2896.
- [31] Elvidge C.D., Baugh K.E., Zhizhin M., et al. Why VIIRS data are superior to DMSP for mapping nighttime lights [J]. *Proc. Asia Pac. Adv. Netw*, 2013, **35** (0): 62.
- [32] Zheng Q., et al. A new source of multi-spectral high spatial resolution night-time light imagery—JLI-3B [J]. *Remote Sensing of Environment*, 2018, **215**: 300–312.
- [33] Ohtsu N. A Threshold Selection Method from Gray-Level Histograms [J]. *IEEE Transactions on Systems Man & Cy-*

- bernetics*, 2007, **9**(1):62-66.
- [34] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: a new learning scheme of feedforward neural networks [C]//2004 IEEE International Joint Conference on Neural Networks. Budapest, Hungary: IEEE, 2004: 985-990.
- [35] Guang-Bin Huang, Qin-Yu Zhu, Chee-Kheong Siew. Extreme learning machine: Theory and applications [J]. *Neurocomputing*, 2005, **70**(1).
- [36] Stumpf A, Kerle N. Object-oriented mapping of landslides using Random Forests [J]. *Remote Sensing of Environment*, 2011, **115**(10): 2564-2577.
- [37] Rodriguez J J, Kuncheva L I, Alonso C J. Rotation forest: a new classifier ensemble method [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2006, **28**(10): 1619-1630.
- [38] Gong P. Finer resolution observation and monitoring of global land cover: first mapping results with Landsat TM and ETM+ data [J]. *International Journal of Remote Sensing*, 2013, **34**(7): 2607-2654.
- [39] Han M, Liu B. An Improved Rotation Forest Classification Algorithm [J]. *Journal of Electronics & Information Technology* (韩敏, 刘贲. 一种改进的旋转森林分类算法. 电子与信息学报), 2013, **35**(12): 2896-900.