

文章编号:1673-9469(2020)02-0100-07

DOI: 10.3969/j.issn.1673-9469.2020.02.015

基于 Sentinel-2A 的太行山区土地覆被分类方法研究

宋宏利¹,雷海梅¹,霍志敏²,尚明¹,邵明超¹,史宜梦¹,孙庆松¹

(1. 河北工程大学 地球科学与工程学院,河北 邯郸 056038;2. 河北省地矿局第六地质大队,河北 石家庄 050085)

摘要:以太行山区为研究对象,基于 Sentinel-2A 遥感影像数据,采用基于像元和面向对象分类两种策略,定量分析不同特征组合模式下,最大似然法(ML)、贝叶斯(Bayes)、支持向量机(SVM)、决策树(Decision Tree)以及随机森林(RF)5 种分类方法在该区域地表土地覆被信息分类中的表现差异。结果表明:(1)基于像元的 RF 分类器取得了最高精度,仅使用光谱特征参与分类和使用光谱、红边、指数特征参与分类的总体精度分别为 96.85% 和 96.64%。(2)红边和指数特征的加入能够对各分类器分类精度产生不同程度的影响,即使基于像元的 RF 和面向对象的 CART 决策树总体精度有所下降,但降幅均在 0.5% 左右,其他分类器精度均有所提升。

关键词:太行山区;面向对象分类;土地利用/覆被;Sentinel-2A 影像

中图分类号:P237

文献标识码:A

Land Use/Cover Classification in Taihang Mountain Area Based on Sentinel-2A Imagery

SONG Hongli¹, LEI Haimei¹, HUO Zhimin², SHANG Ming¹,

SHAO Mingchao¹, SHI Yimeng¹, SUN Qingsong¹

(1. College of Geosciences and Engineering, Hebei University of Engineering, Handan, Hebei 056038, China; 2. The Sixth Geological Brigade of Hebei Provincial Bureau of Geology and Mineral Resources, Shijiazhang, Hebei 050085, China)

Abstract: Based on Sentinel-2A remote sensing image data, this paper took Taihang Mountain Area as the research object to quantitatively analyze the different performance of five classification methods of maximum likelihood (ML), Bayes, support vector machine (SVM), decision tree, and random forest (RF) in the region under different feature combination modes, which adopting two strategies of pixel based and object-oriented classification. The results show that (1) the RF classifier based on pixel achieves the highest accuracy, while the overall accuracy of only using spectral features and using spectral, red edge and exponential features is 96.85% and 96.64%, respectively. (2) The addition of red edges and exponential features can have different degrees of impact on the classification accuracy of each classifier. Even if the overall accuracy of the pixel-based RF and object-oriented CART decision trees decreases, but the decline is about 0.5%. The accuracy of other classifiers has been improved.

Key words: Taihang Mountain Area; object-oriented classification; land use / cover; Sentinel-2A image

土地覆被及其变化是全球环境变化过程中的重要因子,在地球生态系统过程的物质和能量交换中有着非常重要的地位,已成为能量传输模型、陆地生态系统过程模型研究的关键输入参数,同时也是全球变化和碳循环模拟、气候模拟等研究

的重要内容^[1-3]。近年来,随着遥感技术的不断发展,利用遥感数据及各种分类算法可以快速准确地获取区域土地利用/覆被信息,并且具有成本低、效率高、时效性强等优势。国内外学者在此方面作出了大量研究,并得出有价值的研究成果

收稿日期:2020-02-24

基金项目:河北省自然科学基金资助项目(D2019402067);河北省高等学校科学技术研究重点项目(ZD2017212)

作者简介:宋宏利(1980-),男,河北抚宁人,博士,副教授,主要研究方向为 3S 技术集成及应用。

果^[4-9]。综合分析,当前利用遥感手段对土地覆被的研究主要集中于平原区域,且主要以 Landsat、MODIS 等为遥感数据源,而将 Sentinel 数据结合不同分类策略及分类方法在地表景观异质性区域土地覆被信息提取方面的研究相对较少。太行山区位于我国地势第二级阶梯东缘,集革命老区、集中连片贫困区、矿区于一体,是华北地区重要的天然屏障和水源涵养地。因此,如何基于遥感数据,采用机器学习方法识别区域的土地覆被类别及其动态变化,对于掌握区域生态环境演变,制定区域生态保护政策具有重要意义。

1 研究区概况

涉县地处晋冀豫三省交界处,河北省西南部,太行山东麓,介于北纬 36°17'—36°55',东经 113°26'—114°之间。东西长 37.5 km,南北宽 64.5 km,海拔高度 203~1 563 m,总面积 1 509 km²。涉县气候属于暖温带半湿润大陆性季风气候,年平均降水量 540.5 mm,雨热同期。研究区地形为典型山地地貌,太行山余脉贯穿全境,地势由西北向东南缓慢倾斜(图 1)^[10]。经文献调查及野外勘测,将研究区土地覆被类型分为 5 类:耕地、林地、草地、建设用地、水域。

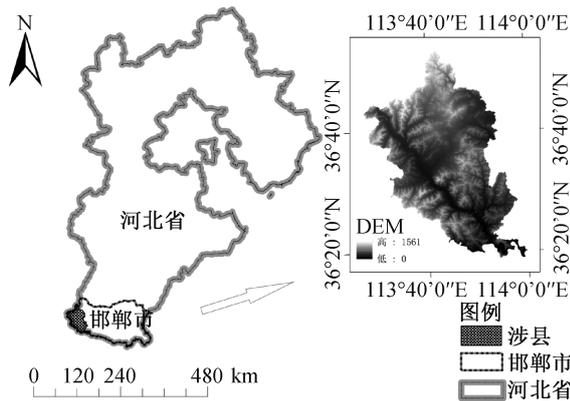


图 1 研究区地理区位图

Fig.1 Geographical location map of the study area

2 数据及预处理

2.1 遥感数据

Sentinel-2A 卫星发射于 2015 年 6 月,携带一个多光谱成像仪(MSI),包含 13 个光谱波段(波段信息如表 1 所示),空间分辨率为 10~60 m,重访周期为 10 d,光谱范围覆盖可见光、近红外及短波红外波段。本文选用 2019 年 6 月 22 日成像的 Sentinel-

2 A L1C 级影像用于土地覆被类别提取,数据下载自欧空局数据中心(<https://scihub.Copernicus.eu/dhus>)^[11],选择空间分辨率为 10 m 的 3 个可见光、1 个近红外和 20 m 的 3 个红边波段。利用欧空局提供的 Sen2Cor 软件对影像进行辐射定标及大气校正处理,并使用 SNAP 软件进行重采样将其转存为 ENVI5.3 能够支持的格式,经矢量边界裁剪之后生成研究区影像。为了减小因波段间空间分辨率不一致而引起的分类误差,本文使用最邻近插值法将 20 m 空间分辨率的红边波段重采样至 10 m。

表 1 Sentinel-2A 卫星波段参数

Tab.1 Sentinel-2A satellite band parameters

波段号	波段类型	中心波长/nm	波段宽度/nm	空间分辨率/m	时间分辨率/d
b1	Coastal aerosol	443.9	27	60	10
b2	Blue	496.6	98	10	10
b3	Green	560	45	10	10
b4	Red	664.5	38	10	10
b5	Red edge	703.9	19	20	10
b6	Red edge	740.2	18	20	10
b7	Red edge	782.5	28	20	10
b8	NIR-1	835.1	145	10	10
b8a	NIR-2	864.8	33	20	10
b9	Water vapor	945	26	60	10
b10	Cirrus	1 373.5	75	60	10
b11	MIR-1	1 613.7	143	20	10
b12	MIR-2	2 202.4	242	20	10

2.2 样本数据

在 Sentinel-2A 原始影像基础上,结合 Google Earth 及野外采样数据进行样本选取,按照训练样本占 60%、验证样本占 40%的比例^[12],在影像上随机选取样本点并保证均匀分布,样本点数量如表 2 所示。

表 2 训练样本及验证样本数量

Tab.2 Number of training samples and verification samples

地物类型	训练样本	验证样本
林地	100	70
草地	100	70
建设用地	100	70
耕地	100	70
水域	60	40

3 研究方法

3.1 尺度分割及特征选择

图像分割是指根据地表覆盖类型在遥感影像

上显现出的光谱、纹理等其他类型特征的不同,将影像像素合并成互不相交的同质单元的过程。在综合分析已有文献的基础上,本文基于 eCognition 软件中提供的多尺度分割算法,通过尺度优化工具 ESP 进行分割尺度的选择^[13-14],最终将形状因子设置为 0.1,紧致度因子设置为 0.5,尺度因子取值范围为 1~100,经迭代计算并结合目视判别,最终选定分割尺度为 30。

有效的分类特征对于提高陆表土地覆被信息提取精度具有重要意义。本文在进行特征选择时,除了采用 Sentinel-2A 影像原始波段特征外,同时选取了归一化差值植被指数(Normalized Difference Vegetation Index, NDVI)、归一化差值水体指数(Normalized Difference Water Index, NDWI)、增强型植被指数(Enhanced Vegetation Index, EVI)、改进型叶绿素吸收反射指数(Modified Chlorophyll Absorption Ratio Index, MCARI)、地形(高程、坡度、坡向)、灰度共生矩阵(GLCM)、形状特征、几何特征等共计 95 个特征。

为了降低数据冗余,本文采用随机森林算法中 MDA(Mean Decrease Accuracy)方法评价 95 个特征的重要性,该方法是基于 OOB 误差进行模型评估从而确定模型最优特征数量,值越大表示特征越重要。图 2 展示了前 30 个重要性较高的分类特征的重要性,从图中可以看出,光谱特征、指数特征以及纹理特征的重要性较高,形状特征及几何特征对分类影响较小。

通过以上对特征重要性的排序,选取不同数量的特征进行随机森林分类,研究特征数量对分类精度的影响。依次选择 5、10、15、20、25 和 30 个分类特征进行分类,结果表明特征个数增加到 10 个以后总体精度(89.7%)和 Kappa 系数(0.87)达到平衡态,再增加特征个数对分类精度的影响不大。最后使用全部 95 个特征进行分类,分类精度依然较高,说明过多的特征未导致随机森林算法出现过拟合问题。由于特征数量过多会导致模型复杂度过高且运行时间过长,因此本文选择重要性排列前 10 的特征(5 个光谱特征、1 个红边波段和 4 个植被指数)作为基于特征优选的随机森林模型的输入特征。

3.2 分类方法及参数训练

在综合分析已有文献基础上,本文选择了最大似然法、贝叶斯、支持向量机、CART 决策树及随机森林 5 种分类方法,并使用验证样本数据对分类结果进行了评价。

贝叶斯分类算法是统计学分类方法,是一类利用概率统计知识进行分类的算法,该算法能运用到大型数据库中,且方法简单、分类准确率高、速度快^[15]。

SVM 分类器是基于统计学习理论的机器学习方法,已广泛应用于农作物种植信息提取和地表覆盖类型调查研究中^[16]。由于本研究中样本的数量远远大于特征的数量,故本文选择径向基核

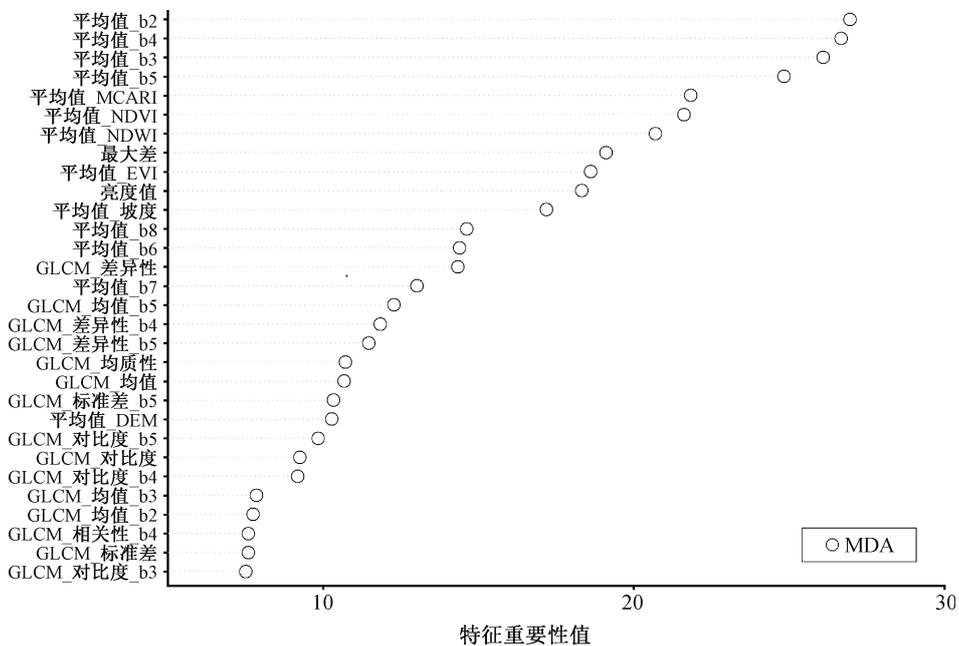


图 2 前 30 个重要性较高的特征变量

Fig.2 Top 30 characteristic variables with higher importance

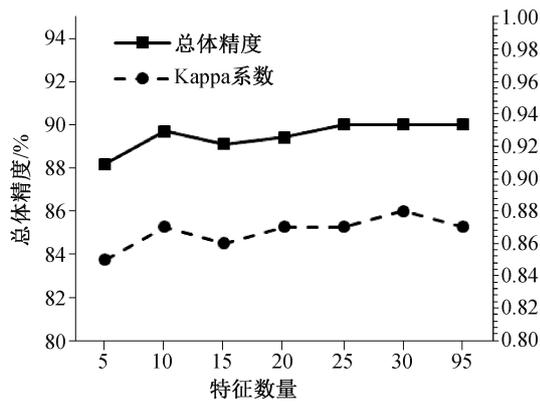


图 3 随机森林特征数量及精度

Fig.3 Number and accuracy of random forest features

表 3 特征参数特点及意义

Tab.3 Characteristics and significance of characteristic parameters

特征参数	计算公式
光谱特征	
Band2-Blue	-
Band3-Green	-
Band4-Red	-
Max.diff.	-
Brightness	$b = \frac{1}{n_L} \cdot \sum_{i=1}^{n_L} C_i$
红边波段	
Band5-Red edge	-
指数信息	
NDVI	$(NIR-RED)/(NIR+RED)$
NDWI	$(GREEN-NIR)/(GREEN+NIR)$
MCARI	$[(RedEdge-RED)-0.2(RedEdge-Green)] * (RedEdge/RED)$
EVI	$2.5 * [(NIR-RED)/(NIR+6 * RED-7.5 * BLUE+1)]$

函数(BRF)作为 SVM 分类器的核函数,并使用 LIBSVM^[17]对 C 和 γ 两个参数进行优化。在面向对象分类过程中,仅使用光谱特征时,惩罚参数和

核参数分别设置为 32.0 和 2.0,红边波段及指数信息加入后,惩罚参数和核参数分别设置为 128.0 和 0.5。

CART 决策树 (Classification And Regression Tree) 基本原理是通过由测试变量和目标变量构成的训练数据集的循环分析而形成二叉树形式的决策树结构^[18]。在 CART 决策树分类过程中,depth 是影响分类结果的一个重要参数,本文设置 depth 试值范围为 1~20,通过迭代循环从而使分类器内部达到最优。如图 4 所示,仅使用光谱特征时,当 depth 值从 5 开始时,总体精度 (Overall accuracy, OA) 和 Kappa 系数趋于稳定且分类精度达到最优。红边波段及指数信息加入后,depth 值从 3 开始时,OA 和 Kappa 系数趋于稳定且分类精度达到最优。

随机森林(RF)分类算法属于一个集合分类器,建立在多个决策树上,该分类方法只需要定义两个参数来生成预测模型:所需的分类树数量(n)和每个节点中用于使树增长的特征数量(m)^[17]。本文使用 R 语言“Random Forest”包中的 random forest 函数循环计算随机森林的分类误差,经过迭代计算,确定 $n = 1\ 000, m = \sqrt{M}$ (M 为分类特征总数)。

3.3 精度评价方法

为了评估各分类器在不同特征组合模式下的分类准确性,本文采用 OA、Kappa 系数、生产者精度 (Producer accuracy, PA) 和用户精度 (User accuracy, UA) 4 个指标来定量评价各分类器分类结果。其中,OA 和 Kappa 系数用于比较整体分类精度(表 4),PA 和 UA 用于评价特定地类的分类精度。

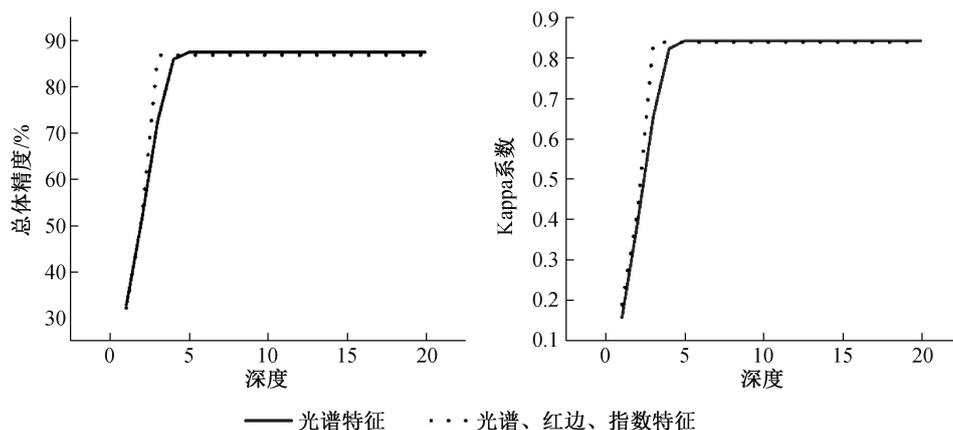


图 4 CART 决策树参数优化

Fig.4 CART decision tree parameter optimization

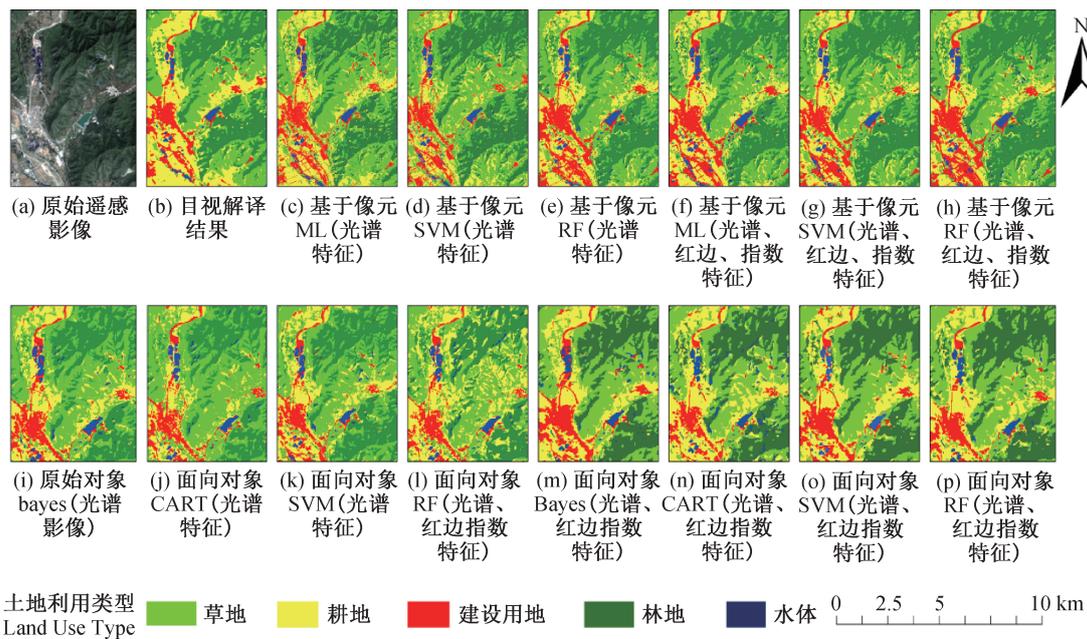


图5 各分类器分类结果图

Fig.5 Classification results of each classifier

表4 面向对象各分类器分类精度

Tab.4 Classification accuracy of each object-oriented classifier

分类特征	精度指标	基于像元分类器			面向对象分类器			
		ML	SVM	RF	Bayes	CART 决策树	SVM	RF
光谱特征	总体精度/%	91.82	86.67	96.85	91.21	87.58	90.9	86.67
	Kappa 系数	0.9	0.83	0.96	0.89	0.84	0.89	0.83
光谱特征+红边波段+指数特征	总体精度/%	94.75	91.39	96.64	94.24	86.97	92.42	89.7
	Kappa 系数	0.93	0.89	0.96	0.93	0.84	0.9	0.87

4 结果与讨论

根据各分类器获得的分类结果,绘制了研究区非典型区域的各土地覆被类型空间分布图(图5)。

4.1 不同分类策略对分类精度的影响

表4对基于像元和面向对象两种分类策略下5种不同分类器所得精度进行了比较。总体上看,所有分类器在不同特征组合下均取得了较高的分类精度,总体精度均在86%以上,表明两种分类策略均适用于山区地表一级土地覆被分类。基于像元分类策略使用了ML、SVM和RF三种分类器,其中RF取得了最高的分类精度,OA为96.85%,Kappa系数为0.96;面向对象分类策略使用了Bayes、CART决策树、SVM和RF四种分类器,其中Bayes取得了最高的分类精度,OA为94.24%,Kappa系数为0.93。在相同分类方法下,面向对象SVM分类器较基于像元SVM分类器精度有所提高,仅使用光谱特征进行分类和使用光谱特征、红

边波段、指数特征参与分类所得OA分别提升4.23%和1.03%,Kappa系数分别提升0.06和0.01;而面向对象RF较基于像元RF分类器精度降低,同种分类情况下,OA分别降低10.18%和4.22%,Kappa系数分别降低0.13和0.09。

为了更加清晰地对比基于像元与面向对象分类结果,本文选取典型区域(图5(a)),将两种分类策略下各分类器分类结果与目视解译结果(图5(b))进行比较。结果表明,基于像元ML(图5(c)、(f))和SVM(图5(d)、(g))有少量山地阴影被分类为水域,且耕地与草地混淆较为明显,耕地与建设用地内部小斑块较多,椒盐现象严重。基于像元RF(图5(e)、(h))虽然也存在一定程度的椒盐现象,但各地类内部相对完整,破碎度较小;面向对象各分类器(图5(i)—(p))分类结果较为相似,山地阴影被分类为水域的面积较多,林地与草地基于像元分类效果好,部分耕地与草地发生混淆,建设用地分类效果基于像元更为细致。

4.2 分类特征对各分类精度的影响

基于随机森林参数优化结果,分两种情况选取特征参与分类:一种是仅使用光谱特征参与分类,另一种是联合使用光谱、红边、指数特征参与分类。由表 4 可知,同种分类策略下的同种分类器在不同特征参与下分类精度不同。在基于像元分类中,联合使用光谱、红边、指数特征和仅使用光谱特征参与分类相比,ML 和 SVM 的分类精度有所提升,OA 分别提升了 2.93% 和 4.72%,Kappa 系数分别提升了 0.03 和 0.06;RF 的总体精度略微下降 0.21%,Kappa 系数不变,表明红边波段和指数特征的加入有助于提升 ML 和 SVM 的分类精度,而对提高 RF 分类精度作用较小。

面向对象分类中,联合使用光谱、红边、指数特征和仅使用光谱特征参与分类相比,Bayes、SVM 和 RF 分类器分类精度提高,OA 分别提高 3.03%、1.52% 和 3.03%,Kappa 系数分别提高 0.04、0.01 和 0.04;CART 决策树精度有所下降,OA 降低 0.61%,Kappa 系数不变。由此可见,在面向对象分类中,红边波段和指数特征对提高 Bayes、SVM 和 RF 分类精度作用较大。

4.3 不同分类器对不同地类提取精度的影响

由表 5 可知,对于类别的生产者精度,基于像元中使用光谱、红边和指数特征参与分类的 ML 和 RF 对林地分类效果最好,PA 为 99.03%;仅使用光谱特征参与分类时的 RF 和光谱、红边、指数特征参与分类的 ML、RF 对草地分类效果最好,PA 为 99.03%;仅使用光谱特征参与分类的 RF 对水域分类效果最好,PA 为 93.75%;仅使用光谱特征参与分类的 ML 对建设用地分类效果最好,PA 为 98.8%;仅使用光谱特征参与分类的 RF 对耕地的分类效果最好,PA 为 95.15%。

由表 6 可知,对于类别的用户精度,基于像元中仅使用光谱特征参与分类的 RF 对林地分类效果最好,UA 为 100%;使用光谱、红边、指数特征参与分类的 RF 对草地分类效果最好,UA 为 97.14%;使用光谱、红边、指数特征参与分类的 ML 对建设用地分类效果最好,UA 为 97.94%;仅使用光谱特征参与分类的 RF 对耕地分类效果最好,UA 为 95.15%;面向对象分类中使用光谱、红边、指数特征参与分类的 RF 对水域的分类效果最好,UA 为 99.2%。

表 5 土地利用类型生产者精度 (PA)

Tab.5 Land use type producer accuracy (PA)

土地利用类型 PA/%	基于像元						面向对象								
	光谱特征			光谱特征+红边 波段+指数特征			Bayes	光谱特征			光谱特征+红边 波段+指数特征				
	ML	SVM	RF	ML	SVM	RF		CART 决策树	SVM	RF	Bayes	CART 决策树	SVM	RF	
林地	93.15	91.8	98.06	99.03	97.09	99.03	98.61	97.14	98.57	97.14	98.57	94.29	98.57	98.57	
草地	89.04	78.1	99.03	99.03	98.06	99.03	84.29	87.14	84.29	74.29	91.43	77.14	94.29	84.29	
水域	84.09	84.1	93.75	92.19	89.06	92.19	93.18	86.36	88.64	86.36	93.18	86.36	81.82	84.1	
建设用地	98.8	98.6	97.09	92.23	90.29	97.09	90.41	87.67	90.41	87.67	95.9	84.93	94.52	87.67	
耕地	90	80	95.15	90.29	81.55	94.17	89.04	79.45	91.78	87.67	91.78	91.78	89.04	91.78	

表 6 土地利用类型用户精度 (UA)

Tab.6 Land use type user accuracy (UA)

土地利用类型 PA/%	基于像元						面向对象								
	光谱特征			光谱特征+红边 波段+指数特征			Bayes	光谱特征			光谱特征+红边 波段+指数特征				
	ML	SVM	RF	ML	SVM	RF		CART 决策树	SVM	RF	Bayes	CART 决策树	SVM	RF	
林地	94.44	85.9	100	99.03	97.09	99.03	98.6	98.55	97.18	97.14	98.57	98.5	98.58	98.57	
草地	82.28	72.2	94.44	96.23	92.66	97.14	90.77	79.22	90.77	86.67	96.97	90	95.65	90.77	
水域	97.37	97.4	98.36	89.39	91.94	98.33	95.35	98.91	98.91	97.44	91.11	92.68	94.74	99.2	
建设用地	94.59	94.5	97.09	97.94	89.42	95.24	97.06	94.12	94.29	94.12	97.22	96.88	92	96.97	
耕地	94.03	90.3	95.15	89.42	85.71	94.17	78.31	74.36	78.82	68.82	87.01	68.37	83.33	72.83	

5 结论

1)5种分类器总体精度均能达到86%以上,其中,基于像元的RF分类精度最高,仅使用光谱特征及联合使用光谱、红边、指数特征两种分类情况下的总体精度分别为96.85%和96.64%。

2)分类特征的优化选择对监督分类方法的分类精度影响较大。在光谱特征参与分类的基础上加入红边、指数特征后,基于像元的RF和面向对象的CART决策树总体精度有所下降,但降幅均在0.5%左右,但其他分类器的总体精度均有所提升,表明红边和指数特征的加入能够在整体上提高分类精度。

本文仅探索了面向对象与面向像元两种分类策略和5种分类方法在土地覆被一级类别的精度比较,并没有考虑面向地块的分类策略和二级地类分类精度,同时也没有采用当前流行的深度学习分类算法,在今后的研究中,将会对上述问题进行深入探索。

参考文献:

- [1]SELLERS P J, DICKINSON R E, RANDALL D A, et al. Modeling the Exchanges of Energy, Water, and Carbon between Continents and the Atmosphere [J]. *Science*, 1997, 275(5299):502-509.
- [2]FRIEDL M A, MCIVER D K, HODGES J C F, et al. Global Land Cover Mapping from MODIS: Algorithms and Early Results[J]. *Remote Sensing of Environment*, 2002, 83(12):287-302.
- [3]NEMANI R, RUNNING S W. Implementation of a Hierarchical Global Vegetation Classification in Ecosystem Function Models[J]. *Journal of Vegetable Science*, 1996, 7(3):337-342.
- [4]QIU Jiangxiao, WANG Xiaoke. A Comparative Study on Object-based Land Cover Classification in High Spatial Resolution Remote Sensing Imagery of Urban Areas[J]. *Remote Sensing Technology and Application*, 2010, 25(5):653-661.
- [5]PEI Huan, SUN Tianjiao, WANG Xiaoyan. Object-oriented Land Use/Cover Classification Based on Texture Features of Landsat 8 OLI Image[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2018, 34(2):248-225.
- [6]LI Xiaohong, CHEN Erxue, LI zengyuan, et al. Object Based Land Cover Classification Method Integrating Multi-Source Remote Sensing Data[J]. *Scientia Sylvae Sinicae*, 2018, 54(2):68-80.
- [7]JIA Mingming, WANG Zongming, ZHANG Peng, et al. Land cover Classification of Compositing HJ-1 and MODIS Data Based on Object-based Method[J]. *Geomatics and Information Science of Wuhan University*, 2014, 39(3):305-310.
- [8]DEILMAI B Rokni, AHMAD B Bin, ZABIHI H. Comparison of Two Classification Methods (MLC and SVM) to Extract Land Use and Land Cover in Johor Malaysia[J]. *IOP Conference Series: Earth and Environmental Science*, 2014, 20(1):012052-012052.
- [9]ZENG T, WANG C. SVM-based Land Use/Cover Classification in Shihezi Area[C]//2016 Progress in Electromagnetic Research Symposium (PIERS). IEEE, 2016.
- [10]ZHOU Xiangshan, SUN Baoping, ZHAO Yan, et al. Study on the Change and Prediction of the Land Use/Vegetation Dynamic——Taking the She County as Example[J]. *Chinese Agricultural Science Bulletin*, 2010, 26(19):306-311.
- [11]DU Baojia, ZHANG Jing, WANG Zongming, et al. Crop Mapping Based on Sentinel-2A NDVI Time Series Using Object-oriented Classification and Decision Tree Model [J]. *Journal of Geo-information Science*, 2019, 21(5):740-751.
- [12]SHAN Zhibin, KONG Jinling, ZHANG Yongting, et al. Remote Sensing Investigation Method of Object-oriented Crops with Special Characteristics[J]. *Journal of Geo-information Science*, 2018, 20(10):1509-1519.
- [13]宋茜.基于GF-1/WFV和面向对象的农作物种植结构提取方法研究[D].北京:中国农业科学院,2016.
- [14]DRĂGUT L, TIEDE D, LEVICK S. ESP: A Tool to Estimate Scale Parameters for Multi-resolution Image Segmentation of Remotely Sensed Data [J]. *International Journal of Geographical Information Science*, 2010, 24(6):859-871.
- [15]CHEN Chen, DONG Qian, WU Yujie. Agricultural Product Quality Mining based on Bayesian Classification[J]. *Journal of Anhui Agricultural Sciences*, 2011, 39(12):7448-7449.
- [16]BAUMANN M, OZDOGAN M, KUEMMERLE T, et al. Using the Landsat Record to Detect Forest-cover Changes During and after the Collapse of the Soviet Union in the Temperate Zone of European Russia[J]. *Remote Sensing of Environment*, 2012, 124:174-184.
- [17]LI Manchun, MA Lei, THOMAS Blaschke, et al. A Systematic Comparison of Different Object-based Classification Techniques Using High Spatial Resolution Imagery in Agricultural Environments [J]. *International Journal of Applied Earth Observations and Geoinformation*, 2016, 49:87-98.
- [18]ZHANG Xiaojuan, YANG Yingjian, GAI Liya, et al. Research on Vegetation Classification Method Based on Combined Decision Tree Algorithm and Maximum Likelihood Ratio[J]. *Remote Sensing Information*, 2010, 2:88-92.

(责任编辑 王利君)