

引用格式:陈昂,杨秀春,徐斌,等.基于面向对象与深度学习的榆树疏林识别方法研究[J].地球信息科学学报,2020,22(9):1897-1909. [Chen A, Yang X C, Xu B, et al. Research on recognition methods of Elm sparse forest based on object-based image analysis and deep learning [J]. Journal of Geo-information Science, 2020,22(9):1897-1909. ] DOI:10.12082/dqxxkx.2019.190598

## 基于面向对象与深度学习的榆树疏林识别方法研究

陈昂<sup>1</sup>,杨秀春<sup>1,2\*</sup>,徐斌<sup>1,2</sup>,金云翔<sup>1</sup>,张文博<sup>1</sup>,郭剑<sup>1</sup>,邢晓语<sup>1</sup>,杨东<sup>1</sup>

1. 农业部农业信息技术重点实验室 中国农业科学院农业资源与农业区划研究所,北京 100081;
2. 北京林业大学草业与草原学院,北京 100083

### Research on Recognition Methods of Elm Sparse Forest based on Object-based Image Analysis and Deep Learning

CHEN Ang<sup>1</sup>, YANG Xiuchun<sup>1,2\*</sup>, XU Bin<sup>1,2</sup>, JIN Yunxiang<sup>1</sup>, ZHANG Wenbo<sup>1</sup>, GUO Jian<sup>1</sup>, XING Xiaoyu<sup>1</sup>, YANG Dong<sup>1</sup>

1. Key Laboratory of Agri-informatics, Ministry of Agriculture/Institute of Agricultural Resources and Regional Planning, Chinese Academy of Agricultural Sciences, Beijing 100081, China; 2. College of Grassland Science, Beijing Forestry University, Beijing 100083, China

**Abstract:** Elm sparse forest is a special vegetation type in Hunsh and ake sandy land. It has important significance for maintaining the stability of regional ecosystem, and plays a key role in sand fixation, water conservation and climate regulation. Rapid and accurate access to the distribution of elm sparse forest is conducive to the protection of the fragile ecosystem in the area. In this paper, the automatic recognition methods of elm sparse forest in high spatial resolution data source was studied by using Unmanned Aerial Vehicle(UAV) image and GF-2 image. After processing the original images of UAV, the Digital Ortho photo Map and the Canopy Height Model were obtained. The preprocessing of GF-2 data included atmospheric correction, orthorectification, image fusion et al. In the object-based method, firstly, the optimal segmentation scale was obtained by calculating the change rate of local variance in the image objects; Secondly, the importance of the selected features was sorted by the random forest algorithm, and the irrelevant features were deleted; Finally, the parameters of three classifiers, namely, Support Vector Machine(SVM), Random Forest(RF) and Deep Neural Network(DNN), were optimized, and then they were used to identify the elm sparse forest. In addition, based on the Tensor Flow framework in ENVI 5.5, a deep learning model based on U-Net was constructed to identify elm sparse forest. The results showed that: (1) through the optimization of the object-based method process, the final recognition accuracy was improved than the previous study. In GF-2 image, the overall accuracy of SVM was 90.14%, the overall accuracy of RF was 90.57%, and the overall accuracy of DNN was 91.14%. In UAV image, the overall accuracy of SVM was 97.70%, and the overall accuracy of RF and DNN were 97.42%.(2) In the deep learning method, the overall accuracy of the GF-2 image was 91%, and the overall accuracy of the UAV image reached 98.43%. The results illustrated that UAV image can achieve higher accuracy than GF-2 image in elm

收稿日期:2019-10-12;修回日期:2019-12-10.

基金项目:国家重点研发计划项目(2017YFC0506504);国家自然科学基金项目(41571105)。[ **Foundation items:** National Key Research and Development Program of China, No.2017YFC0506504; National Natural Science Foundation of China, No.41571105. ]

作者简介:陈昂(1995—),男,河南许昌人,硕士生,主要从事沙漠化遥感监测研究。E-mail: chenang0226@163.com

\*通讯作者:杨秀春(1975—),女,河北唐山人,博士,研究员,主要从事草地资源遥感研究。E-mail: yangxiuchun@caas.cn

sparse forest recognition because of its higher spatial resolution, richer texture and shape information. Object-based method had high applicability for both kinds of images, and the accuracy of three classifiers were similar. The deep learning method was more suitable for UAV image in this paper, it can effectively reduce the misclassification phenomenon in UAV image. In the future, a higher quantity and quality sample database should be constructed to further improve the accuracy of deep learning method and provide support for the management and research of elm sparse forest.

**Key words:** Elm sparse forest; UAV; object-based method; machine learning; deep learning; Hunshandake sandy land

**\*Corresponding author:** YANG Xiuchun, E-mail: yangxiuchun@caas.cn

**摘要:**榆树疏林是浑善达克沙地中一种特殊的植被类型,它对于维持区域生态系统稳定具有重要意义,在防风固沙、涵养水源、调节气候等方面发挥着重要的作用。本文利用无人机影像与GF-2影像,对高分辨率数据源中榆树疏林的两种自动识别方法进行了研究。在面向对象方法中,首先通过计算影像对象的局部方差变化率得到了最佳分割尺度;其次采用随机森林算法对初选特征的重要性进行排序,并删除无关特征;最后分别对支持向量机(SVM)、随机森林(RF)、深度神经网络(DNN)3种分类器进行参数寻优与榆树疏林提取。此外,在ENVI5.5中基于TensorFlow框架,利用U-Net构建深度学习模型对榆树疏林进行了提取,并与面向对象方法进行对比。结果显示:①通过面向对象方法过程的优化,最终的识别精度较以往研究有所提升,GF-2影像中SVM总体精度为90.14%,RF总体精度为90.57%,DNN总体精度为91.14%;无人机影像中SVM总体精度为97.70%,RF与DNN总体精度为97.42%。②深度学习方法中,GF-2影像的总体精度为91.00%,无人机影像的总体精度达到了98.43%。研究结果说明在榆树疏林提取中,无人机影像具有更高的空间分辨率,更丰富的纹理、形状等信息,能达到比GF-2影像更高的精度。面向对象方法对于2种影像都有较高的适用性;深度学习的方法在本文中更适用于无人机影像,它可以有效地减少无人机影像中的错分现象。

**关键词:**榆树疏林;无人机;面向对象;机器学习;深度学习;浑善达克沙地

## 1 引言

疏林是以乔木为优势种,稀疏分布的一种特殊的森林类型。榆树疏林是位于温带森林和典型草原之间的地带性植被,在我国浑善达克沙地广泛分布,它是沙地中重要的植物群落和顶级生态系统类型<sup>[1]</sup>,榆树疏林的退化会导致沙地面积的扩张以及沙化程度的加重。快速准确地获取榆树疏林分布情况可以为管理部门提供重要的科学依据,也有利于区域生态工程的监测和评估,保护该区脆弱的生态系统,而当前对榆树疏林的研究内容集中于生态方面,疏林位置信息获取多是依靠样地调查<sup>[2]</sup>。

传统的森林资源调查主要通过实地测量获取树冠信息,20世纪60年代开始,研究者开始利用航空影像的目视解译替代野外调查,但是这两种方法都需要大量的人力物力<sup>[3]</sup>。随着遥感技术的快速发展,卫星影像的空间分辨率已提高至亚米级,为区域尺度的森林资源调查提供了有力的数据支撑;航空遥感影像到达了厘米级,可以为样地尺度上的林分调查快速提供影像,这其中,国产GF-2因其优于1m的空间分辨率,且兼具宽覆盖、质量较高等优点在卫星影像中被广泛使用;无人机影像因其超高空

间分辨率、成本低、获取速度快等优势成为了近年来备受关注的航空数据源,而如何有效的在不同影像中提取树冠范围仍然是近年来遥感领域研究的热点。

面向对象的影像分析方法(Object-Based Image Analysis, OBIA)以分割后的对象作为基本分类单元,充分利用对象的光谱、形状、纹理等信息,相比于基于像元的传统分类方法,它能有效提高分类精度,消除“椒盐现象”,在处理高空间分辨率影像时有独特的优势。OBIA被广泛应用于树冠提取中<sup>[4-5]</sup>,也有学者利用OBIA对榆树疏林进行了识别并取得了较好的效果<sup>[6]</sup>。然而很多面向对象分类中是通过计算特征阈值的方法对树冠进行提取,这种方法虽简单易操作,但并不能综合利用各项特征,精度有限,国内外已有大量研究将OBIA与机器学习算法结合进行地物分类取得了更高的分类精度,例如随机森林(RF)、K近邻法(KNN)、决策树(DT)、支持向量机(SVM)、朴素贝叶斯(NaiveBayes)等<sup>[7-9]</sup>。此外,大部分面向对象研究中并没有对尺度寻优、特征选择、分类器调参进行综合考虑,这会对最终的精度产生较大影响。与OBIA相比,深度学习作为近年来更热门的方法已被应用于多种场景的分类与目标

检测中<sup>[10-11]</sup>,它能够比传统的分类器更准确地挖掘高空间分辨率影像中的地物分布规律,并且可以不依赖人工,自动地提取影像中的高级特征。深度学习已在生态学领域得到了广泛的应用<sup>[12-13]</sup>,但是在树冠提取研究中却鲜有报道。

本研究选取浑善达克沙地腹地、锡林浩特市南部的榆树疏林典型区为研究区域,进行了野外实地调查与无人机飞行。基于预处理后的无人机影像以及GF-2影像,分别利用面向对象方法与深度学习识别区内榆树疏林,并对不同方法得到的结果进行对比。

## 2 研究区概况、数据来源及预处理

### 2.1 研究区概况

锡林浩特市位于内蒙古自治区中部,北京市正北方,43°02' N—44°52' N, 115°13' E—117°03' E,地势南高北低,地形起伏明显,平均海拔988.5 m。研究区位于锡林浩特市南部的草地沙漠化典型区(图1),总面积约为47 km<sup>2</sup>,南北长约12 km,东西长约

4 km,平均海拔1300 m。该区属于京津风沙源治理工程区,2000年至今开展了退牧还草、飞播、人工造林等多项治沙措施,当前研究区内以固定、半固定沙丘为主,广泛分布着榆树疏林。

### 2.2 无人机数据获取及预处理

选取植被生长旺盛期(2018年7月10—13日)开展无人机航拍。航拍前设置了30个地面控制点,用于后期影像的校正,控制点经纬度及高程的测量采用全球定位系统实时动态差分(RTK)方法(水平精度<3 cm,高程精度<5 cm)。拍摄当天天气晴朗、能见度高,风速小于四级,符合无人机航拍条件,航拍采用固定翼无人机,搭载Sony A7R型可见光数码相机,重500 g,镜头焦距35 mm,像幅宽度4912像素,高度7360像素,具体飞行参数见表1。

无人机航拍共得到2452张图像,在INPHO软件中利用全自动影像匹配技术开展密集点云匹配,生成所有单个立体像对的数字表面模型(DSM),将单个DSM点云进行自动镶嵌、自动内插后,生成规则格网的数字表面模型数据。数字高程模型

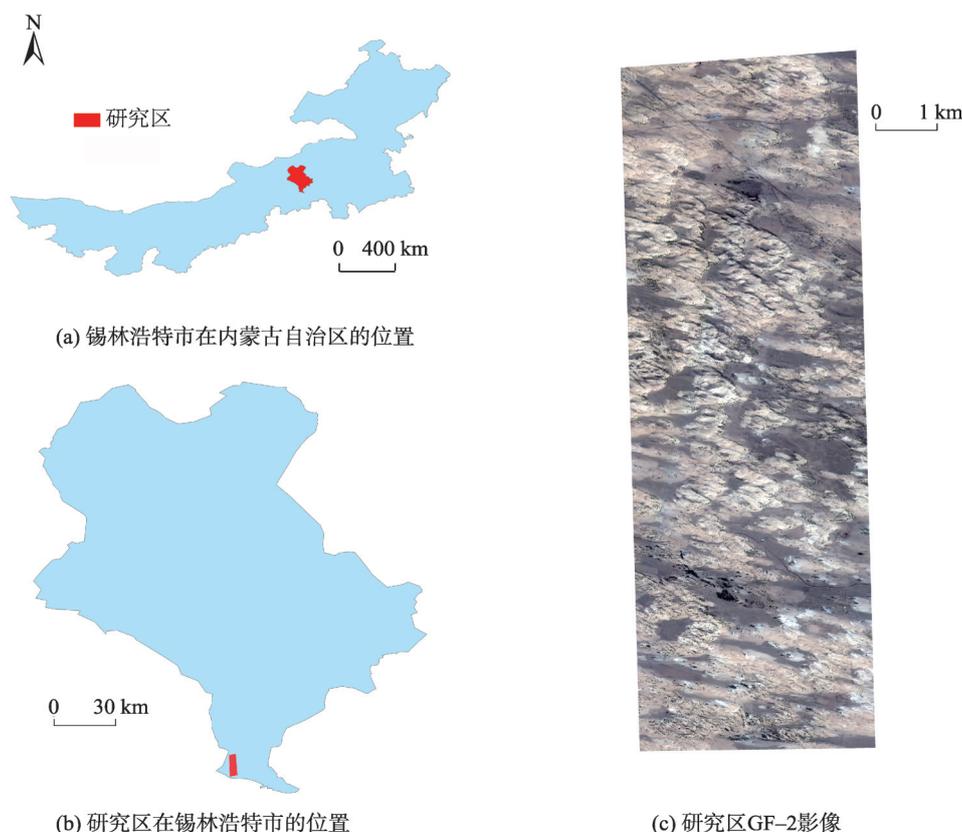


图1 锡林浩特市南部的草地沙漠化典型区

Fig. 1 Location map of study area in Hunshandake sandy land

表1 无人机飞行参数  
Tab. 1 UAV flight parameters

飞行航高/m	飞行海拔/m	飞行速度/(km/h)	航向重叠度/%	旁向重叠度/%	地面分辨率/m	相片数/张	测量面积/km <sup>2</sup>	外扩面积/km <sup>2</sup>
610	1919	60	75	65	0.1	2452	47	0.12

(DEM)直接利用空三加密成果,立体采集三维数据匹配编辑,自动拼接生成,为降低数据量,提高处理效率,DEM、DSM 格网间隔重采样至 2 m。随后在 ArcMap10.5 软件中使用栅格计算,DEM 作为减数栅格,DSM 作为被减栅格,得到冠层高度模型(CHM),通过实地考察以及后续实验中发现,2 m 分辨率的高度模型在榆树提取中不会对精度造成较大影响。根据单张航片的内外方位元素和数字高程模型DEM,纠正影像因地面起伏、飞机倾斜等因素引起的失真,把中心投影转换为垂直投影,从而得到单张像片的正射影像,并进行影像镶嵌。最终得到的数字正射影像(DOM)空间分辨率为 0.1 m,为提高后续处理效率,重采样至 0.2 m。

### 2.3 GF-2 数据获取及预处理

由于研究区在 2018 年 6—8 月份缺少 GF-2 影像,最终选取了时间较为接近且影像质量较高、云量为 0% 的 5 月 15 日 GF-2 影像,5 月已进入榆树生长期,且榆树在短期内不会出现较大的位置变化,2 种影像在时间上的差异对最终提取精度的影响在此处可以忽略。GF-2 数据预处理在 ENVI 5.3 中进行,包括正射校正、辐射定标、大气校正、影像融合、几何校正等步骤。大气校正使用了 FLAASH 模型,影像融合算法使用了 NNDiffuse Pan Sharpening,几何校正中的参考影像是高精度的无人机正射影像,最终得到了研究区 1 m 分辨率的多光谱影像。

### 2.4 验证样本选取

以无人机正射影像为参考,在 ArcMap10.5 中共选取了 700 个验证样本。在研究区内手动均匀选取了 350 个榆树样本。并生成随机点 350 个作为背景地物样本进行编辑,根据对研究区的实地考察,以及以往研究中对浑善达克沙地的分类<sup>[14]</sup>,将背景地物分为固定沙地、半固定沙地、流动沙地 3 类,删除落在榆树疏林区域的样本点,为了更加准确地判断分类精度,减少流动沙地的样本点,并手动添加了大量固定沙地样本点,这是由于榆树疏林容易与裸沙进行区分,难以与植被状况好的背景区分。最终得到了 90 个流动沙地样本,76 个半固定沙地样本,

184 个固定沙地样本。除榆树外,研究区内还存在飞播或人工种植的高大灌丛以及部分中、重度退化的草地,通过 0.2 m 分辨率的无人机影像,可以在样本选取时清晰的人工分辨出各植被类型,由于本文重点是对榆树疏林的提取,所以对背景地物的分类进行了简化,灌丛区域以及中、重度退化的草地在选取样本时根据实地经验被算作固定或半固定沙地。

## 3 研究方法

本研究基于无人机与 GF-2 影像,主要比较了面向对象方法与深度学习方法在榆树识别中的效果,具体流程可见图 2。面向对象方法中的影像分

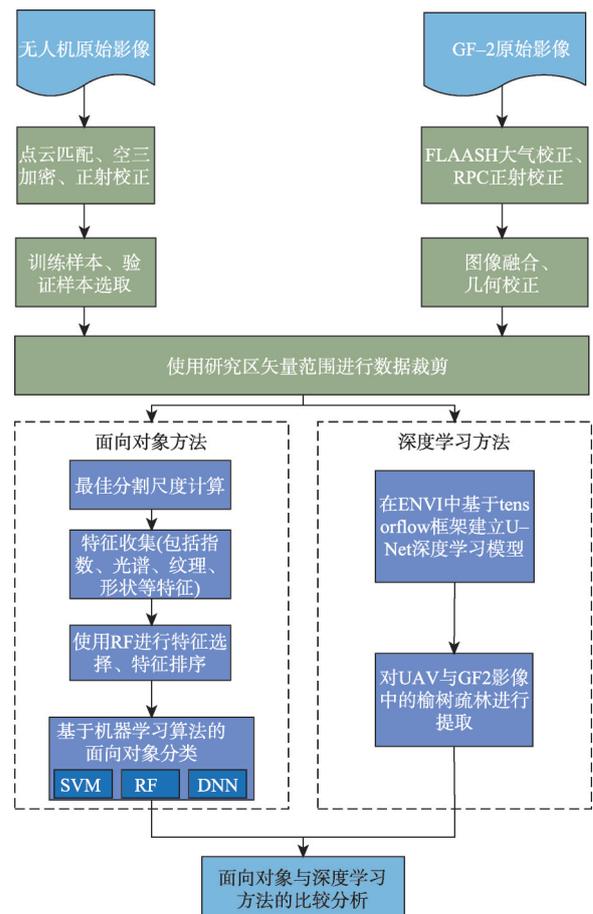


图2 研究方法流程

Fig. 2 Flow chart of research methods

割及特征收集在 eCognition 软件中完成, 分割尺度寻优在 ESP2 工具中进行, 特征排序、分类器参数寻优及影像分类利用 R 语言完成。深度学习方法在 ENVI5.5 中使用 Deeplearning 模块实现。

### 3.1 基于面向对象方法的榆树疏林提取

面向对象分类的主要过程可分为 3 部分: 影像分割、特征选择、分类, 大量研究<sup>[7,9]</sup>表明遥感影像的分割尺度、特征的数量及质量、分类器的选择都会对最终的分精度产生较大影响。本文利用无人机与高分影像结合面向对象分类方法, 探究了影像分割的最佳尺度, 对相关特征进行优选, 并对 3 种机器学习分类器与进行了比较。

#### 3.1.1 影像分割

影像分割是面向对象分类的基础, 分割后同一对象的全部像元都被赋予同一含义。研究中使用的多尺度分割 (Multi-resolution Segmentation, MRS) 是目前被广泛使用的分割方法, 它的核心算法是分形网络演化方法, 这是一种自下而上的区域合并技术, 以单个像元作为最小对象, 与相邻的像元或对象进行合并, 达到设定的异质性阈值后则停止。尺度分割的质量很大程度上依赖于尺度参数的确定。

本文使用 Drăguț 等<sup>[15]</sup>开发的 ESP2 工具确定最佳分割尺度, 该工具基于对各尺度中影像对象的局部方差 (LV) 进行计算, 并发现局部方差变化率 (ROC) 可以指示最佳分割尺度:

$$ROC = \left[ \frac{L - (L - 1)}{(L - 1)} \right] \times 100 \quad (1)$$

式中:  $L$  为目标尺度上对象层的局部方差;  $L - 1$  为更低一级尺度上对象层的局部方差, 当 ROC 值最大, 即呈现峰值时所对应的分割尺度就是最佳尺度参数。

#### 3.1.2 特征收集

针对无人机影像初步选择了 34 个特征指标, 其中包括 5 个常见的可见光植被指数: 可见光波段差异植被指数 (VDVI)、归一化绿红差异指数 (NGRDI)、归一化绿蓝差异指数 (NGBDI)、红绿比值指数 (RGRI)、过绿指数 (EXG)。计算方式如式 (2)~(6) 所示。

$$VDVI = \frac{2G - R - B}{2G + R + B} \quad (2)$$

$$NGRDI = \frac{G - R}{G + R} \quad (3)$$

$$NGBDI = \frac{G - B}{G + B} \quad (4)$$

$$RGRI = \frac{R}{G} \quad (5)$$

$$EXG = 2G - R - B \quad (6)$$

式中:  $G$  为绿波段反射率;  $R$  为红波段反射率;  $B$  为蓝波段反射率。光谱特征指标包括 RGB3 个波段的均值 (Mean) 及标准差 (Std.dev.), 以及亮度 (Brightness)、光谱最大差异 (Max.diff), 在 ENVI 5.3 中对无人机影像进行了 HLS 色彩空间转换, 转换后的影像包括色相 (H)、亮度 (L)、饱和度 (S), 并将 HLS 均值及标准差加入光谱特征。纹理特征指标包括通过灰度共生矩阵得到的同质性 (Homogeneity)、对比度 (Contrast)、非相似性 (Dissimilarity)、熵 (Entropy)、角二阶矩阵 (Ang.2nd moment)、均值 (Mean)、标准差 (stdDev)、相关性 (Correlation)。形状特征指标包括面积 (Area)、像元数量 (Number of pixels)、长宽比 (Length/width)、边界指数 (Border index)、形状指数 (Shape index)、圆度指数 (Roundness)。此外加入了 CHM 作为冠层高度特征。

针对 GF-2 影像初步选取了 26 个特征指数, 其中包括 2 个常用的植被指数: 归一化植被指数 (NDVI)、修改型土壤调节植被指数 (MSAVI), 由于近红外波段对植被变化更为敏感, GF-2 影像中不再进行可见光植被指数对比。计算方式如式 (7)~(8) 所示。

$$NDVI = \frac{NIR - R}{NIR + R} \quad (7)$$

$$MSAVI = \frac{(2NIR + 1 - \sqrt{(2NIR + 1)^2 - 8(NIR - R)})}{2} \quad (8)$$

式中:  $NIR$  表示近红外波段反射率;  $R$  表示红波段反射率。光谱特征包括 4 个波段的均值和标准差, 以及亮度 (Brightness)、光谱最大差异 (Max.diff)。纹理、形状特征与无人机影像一致, 但高分影像中不包含冠层高度特征。具体特征列表见表 2。

#### 3.1.3 特征选择

随机森林算法在近年来开始被很多研究用于特征选择中<sup>[16-17]</sup>, 本文利用随机森林实现对不同特征重要性的排序。首先将每个真实的原始特征随机打乱顺序, 添加随机的阴影特征, 得到新的特征矩阵; 再基于新的特征矩阵建立随机森林模型, 采用平均减少精度评估每个特征的重要性, 根据设定好的迭代次数  $n$ , 随机排列特征  $n$  次并进行  $n$  次打分; 在迭代中, 将每一个真实特征的重要性与最高的阴影特征重要性 (MZSA) 进行比较, 若显著低于 MZSA 则视为无关特征, 若显著高于则视为相关特征; 当为所有特征分配完重要性, 或达到设定的随机森林运行极限则该过程停止。此方法可以得到与因变量有关的所有特征, 并得到所有特征的重要

表2 面向对象分类特征列表

Tab. 2 Feature list in OBIA

特征类型	特征指标	
	无人机	GF-2
指数特征	VDVI、NGRDI、NGBDI、RGRI、EXG	NDVI、MSAVI
光谱特征	Mean red、mean green、mean blue、mean H、mean L、mean S、std.dev.red、std.dev.green、std.dev.blue、std.dev.H、std.dev.S、std.dev.L、brightness、max.diff	Mean red、mean green、mean blue、mean NIR、std.dev.red、std.dev.green、std.dev.blue、std.dev.NIR、brightness、max.diff
冠层高度特征	mean CHM	无
纹理特征	GLCM (Gray-Level Co-occurrence Matrix) homogeneity、GLCM contrast、GLCM dissimilarity、GLCM entropy、GLCM std.dev.、GLCM correlation、GLCM ang. 2nd moment、GLCM mean	
形状特征	Area、number of pixels、border index、shape index、roundness、length/width	

性得分。本文在R语言中利用Boruta包进行以上算法,共有200个样本参与了计算。

### 3.1.4 分类方法

本研究中选用了3种机器学习算法在R语言中进行面向对象分类并进行对比,分别是随机森林(RF)、支持向量机(SVM)、深度神经网络(DNN)。分类中通过对无人机影像目视解译选取300个样本,其中榆树样本80个,背景地物样本220个,包括流动沙地样本64个,固定沙地样本77个,半固定沙地样本78个。

RF是由Breiman<sup>[18]</sup>提出的一种基于CART决策树的集成学习方法,它集成众多决策树进行预测,通过各个决策树的预测值进行投票,得到最终的预测结果。在使用前对随机森林中树的个数( $n_{tree}$ )、树节点预选的变量个数( $m_{try}$ )2个重要参数进行调参,将 $n_{tree}$ 的范围设置为500~1000,步长为100,将 $m_{try}$ 的范围设置为1~20,步长为1,利用网络搜索法进行参数寻优。

SVM是建立在统计学习理论基础上的—种数据挖掘方法,能很好的处理回归问题和模式识别等诸多问题,它在解决小样本、非线性和高维模式识别问题中有许多优势<sup>[19]</sup>。在利用SVM分类前,对惩罚系数 $C$ 与 $\gamma$ 进行调参,将 $C$ 与 $\gamma$ 的值设为 $2^d$ , $C$ 的取值范围中 $d=-5,-3,\dots,15$ ; $\gamma$ 的取值范围中 $d=-15,-13,\dots,3$ ,利用网络搜索法进行参数寻优。

DNN根据层次可分为输入层、多个隐藏层、输出层,输入的特征向量通过隐含层达到输出层。研究中利用R语言接入H2O平台,利用H2O建立DNN模型进行分类。H2O平台是一个分布式可伸缩性开源机器学习平台,它在建模时结合了许多技巧,例如自动数据标准化、自动适应学习率、自动性

能优化。在本研究中DNN模型隐藏层个数设为5,每层的神经元个数为200, $epoch$ 设为800,激活函数为ReLU。

### 3.2 基于深度学习方法榆树疏林提取

深度学习是机器学习领域的分支,它可以自动提取原始影像上的低级特征进行地物识别而不依靠人工所提取的高级特征。随着深度学习在目标检测领域的快速发展,很多研究将其应用于高空间分辨率遥感影像中的车辆<sup>[20]</sup>、船舶<sup>[21]</sup>、飞机<sup>[22]</sup>等地物的识别。少量研究中利用深度学习进行了林业资源调查,例如白宇<sup>[23]</sup>利用深度学习算法识别不同地区的林地范围;罗巍等<sup>[24]</sup>利用卷积神经网络提取了无人机影像中的树冠。本研究在ENVI 5.5中使用Deep learning模块执行榆树提取,该模块基于TensorFlow框架,利用U-Net网络构建深度学习模型,U-Net是卷积神经网络的变形,它基于全卷积神经网络进行改进,利用数据增强可以减少对训练样本的需要。U-Net模型包含编码器与解码器2部分,在编码器中进行2次卷积与一次池化过程用于降低特征图维度;在解码器中经过上采样层恢复特征图原始分辨率,通过跳跃式连接将特征图传递给解码器。

对于无人机数据,在正射影像中加入CHM,得到带有冠层高度信息的4波段影像;GF-2数据为预处理后的4波段影像。在执行深度学习算法中各参数使用默认设置, $epoch$ 设为25, $number\ of\ patches\ per\ epoch$ 设为300, $number\ of\ patches\ per\ batch$ 设为4, $patch\ sampling\ rate$ 设为16。执行深度学习算法前,在研究区内选择了3个具有代表性的子区(图3),参考无人机正射影像,在ArcMap 10.5中人工选取子区内的所有榆树,最终得到训练样本共800个。

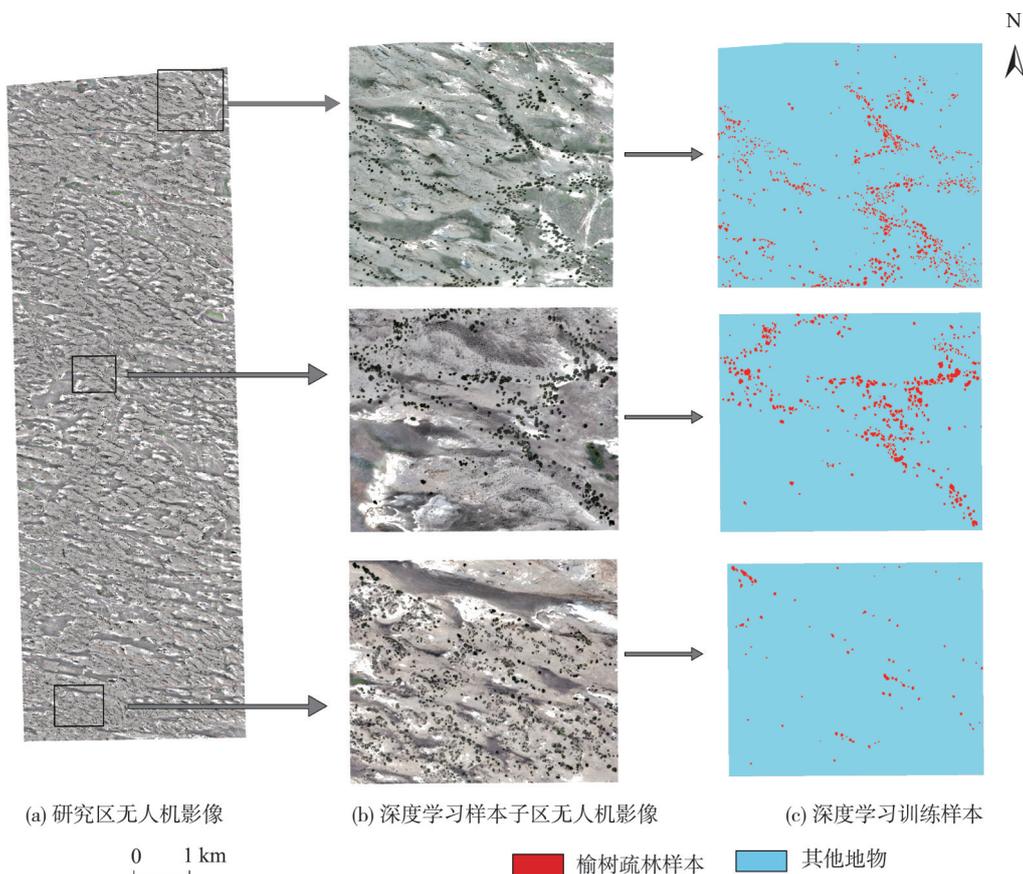


图3 深度学习训练样本

Fig. 3 Deep learning training samples

### 4 结果与分析

#### 4.1 面向对象方法结果

##### 4.1.1 最优分割尺度

本研究在 eCognition 8.9 软件中对无人机影像进行多尺度分割。经过初步的目视判别发现最佳

分割尺度大体在 40~200 之间,形状/紧致度为 0.4/0.5 的组合能得到最佳的地物分割效果,随后使用 ESP2 工具分析得到最佳尺度。此外,为得到更好的分割结果,在进行多尺度分割的过程中,将 DSM 数据作为第四波段参与分割。最终得到的影像局部方差及方差变化率如图 4,通过观察方差变化率

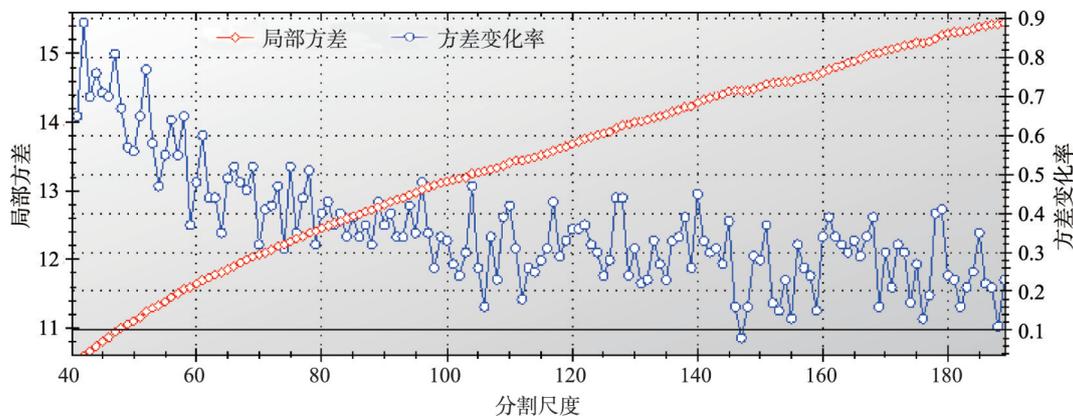


图4 无人机影像局部方差、方差变化率变化曲线

Fig. 4 LV and LV-ROC Curves of UAV Image

曲线,将52、75、96、104、117、140、185作为备选最佳尺度参数。通过对比这7种尺度下的分割效果,发现140参数下影像对象能更好的将榆树完整提取出来,没有出现明显的过分割或欠分割现象(图5)。

通过同样的方法得到GF-2影像的最佳分割尺

度为89,形状/紧致度为0.3/0.5。局部方差与方差变化率的曲线如图6所示。分割效果如图7所示。

#### 4.1.2 特征选择

利用随机森林算法得到的无人机影像特征重要性排序如图8所示,在34个特征中,没有特征被

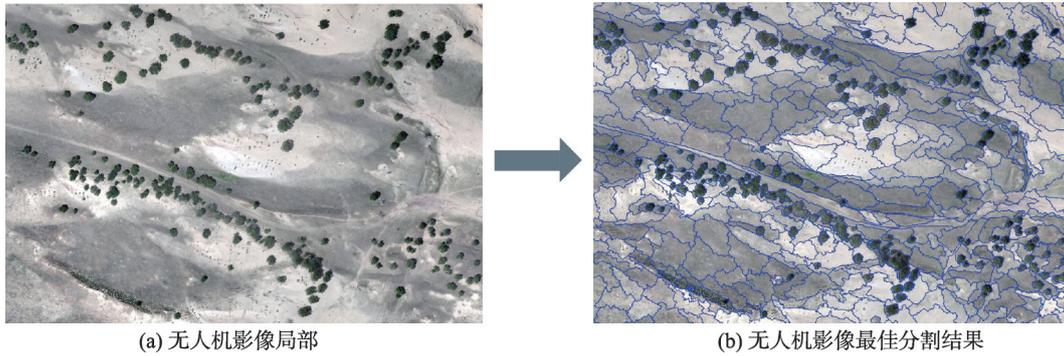


图5 无人机影像榆树疏林最佳分割效果

Fig. 5 Optimum segmentation of elm sparse forest in UAV image

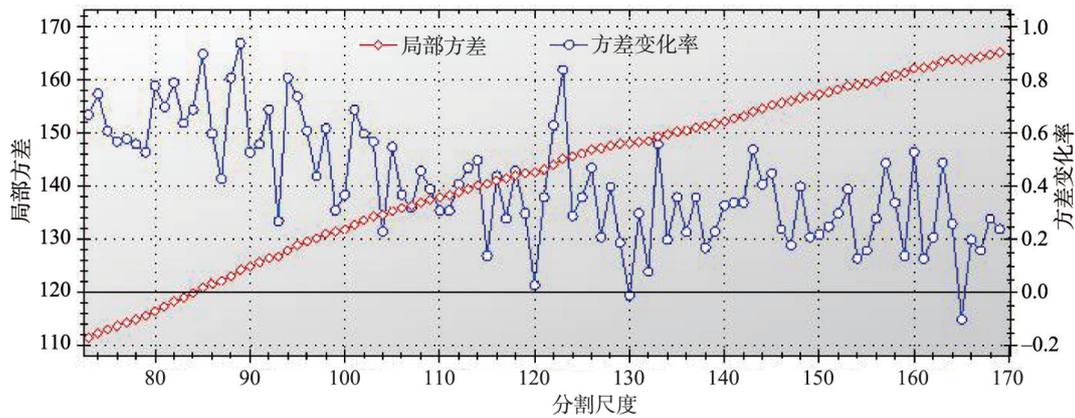


图6 GF-2影像局部方差、方差变化率变化曲线

Fig. 6 LV and LV-ROC Curves of GF-2 Image

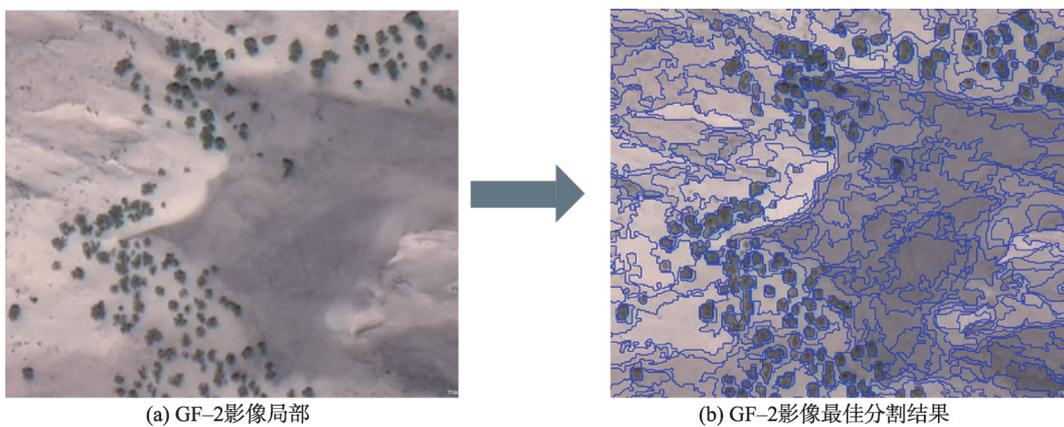


图7 GF-2影像榆树疏林最佳分割效果

Fig. 7 Optimum segmentation of elm sparse forest in GF-2 image

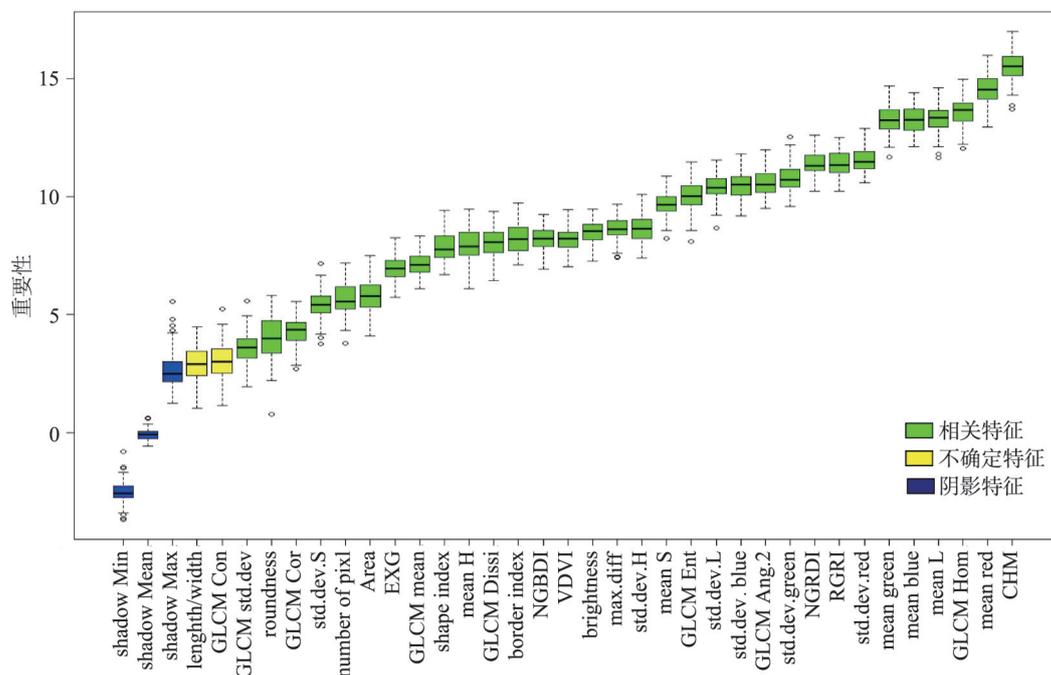


图8 无人机影像特征重要性排序

Fig. 8 Sequencing of the Importance of UAV image features

判定为无关特征, GLCM contrast、length/width 被判定为不确定特征, 在随后的面向对象分类中去掉这 2 个特征, 保留其余 32 个。通过观察特征排序可以发现 RGRDI、NGRDI 是最为有效的指数特征, 而被广泛认为<sup>[25]</sup>对植被更为敏感的 VDVI 仅仅排在第 18 位; 光谱特征中 RGB 原始波段均值以及通过 HLS 色彩空间转换得到的 Mean L (亮度均值) 是最为重要的光谱特征; 纹理特征中 GLCM homogeneity、GLCM entropy、GLCM ang. 2nd moment 较为重要; 而形状特征的重要性都较低, 可见形状特征在榆树疏林的提取中并不十分重要。CHM 被认为是最重要的特征, 冠层高度可以在榆树疏林识别中提供重要的信息。

GF-2 影像中特征的排序如图 9 所示, 所有特征被判定为相关并应用于面向对象分类中。NDVI 与 MSAVI 重要性得分相近。max.diff 与近红外波段信息被认为是最重要的光谱特征; 由于空间分辨率的降低, 纹理特征在高分影像中的重要性有所下降, 且不同纹理特征的排序发生了很大改变; 5 个形状特征重要性依然很低。

#### 4.1.3 面向对象分类结果

面向对象的分类结果精度验证如图 10 所示, 3 种分类器得到的分类结果相近。在高分影像的分类中, DNN 的精度为 91.14%, 略高于 RF 的 90.57%

与 SVM 的 90.14%; 在无人机影像分类中, RF 与 DNN 的分类精度都为 97.42%, SVM 的精度略高于两者, 达到了 97.70%。无人机影像的分类精度明显高于高分影像, 虽然高分影像中近红外波段对植被变化极为敏感, 但无人机影像的空间分辨率是高分影像的 5 倍, 拥有更加丰富的纹理、形状信息, 且无人机数据中的冠层高度模型对树冠提取极为有效。

#### 4.2 深度学习分类结果

高分二号与无人机影像的深度学习分类精度如表 3、表 4 所示, 结果显示两者精度差距较大, 高分二号影像分类总体精度为 91.00%, 无人机影像分类总体精度达到了 98.43%。通过观察两者的混淆矩阵可以发现, 高分影像中出现了大量背景地被错分为榆树疏林的现象, 这是由于在高分影像中, 较大的灌丛与榆树在光谱、纹理信息上极其相似, 所以验证样本中很多位于灌丛区域的背景地物样本被识别为榆树, 本实验中深度学习并没有较好的克服这一问题。而在处理无人机影像时, 深度学习算法的精度达到了非常高的水平, 很好地解决了榆树与灌丛的区分。

#### 4.3 面向对象与深度学习结果对比

高分影像的榆树疏林识别中, 面向对象方法的 3 种分类器都取得了较高的总体精度, 深度学习方

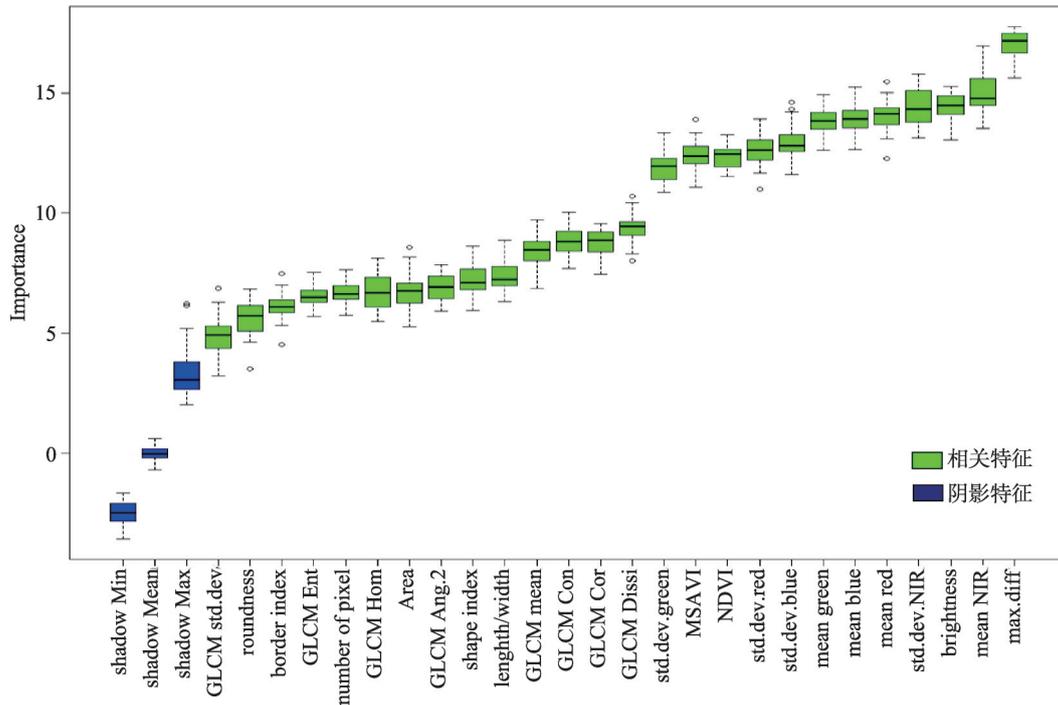


图9 GF-2影像特征重要性排序

Fig. 9 Sequencing of the Importance of GF-2 image features

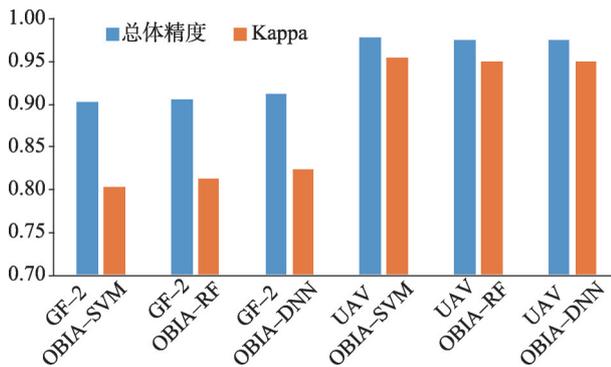


图10 面向对象方法中SVM、RF、DNN的精度比较

Fig. 10 Accuracy comparison of SVM, RF, DNN used in OBIA

表3 GF-2影像深度学习结果

类别	背景地物	榆树疏林	总计
背景地物	292	5	317
榆树疏林	58	325	383
总计	350	350	700
总体精度/%	91.00		
Kappa	0.82		

法的总体精度为91.00%，略低于DNN分类器，但制图精度最高，达到了98.57% (图11)，然而由图12可以发现，所使用的方法都不能很好的克服固定沙地

表4 UAV深度学习结果

Tab. 4 Results of UAV image using deep learning method

类别	背景地物	榆树疏林	总计
背景地物	348	9	357
榆树疏林	2	341	343
总计	350	350	700
总体精度/%	98.43		
Kappa	0.97		

背景中灌丛的影响，出现了很多灌丛被错分为榆树疏林的现象。

无人机影像的榆树疏林识别中，深度学习方法的总体精度最高，且用户精度也明显高出，达到了99.42%，DNN与SVM的制图精度最高，达到了99.71% (图11)，由图12可以发现无人机影像分类结果减小了固定沙地背景中灌丛对榆树疏林提取的影响，错分误差大大减小，尤其是深度学习算法几乎消除了背景地物的干扰。

面向对象方法在经过完整的尺度寻优、特征选择、分类器调参后，达到了较高的精度，且对于2种影像都有较高的适用性，与以往利用面向对象方法通过阈值提取榆树疏林的研究相比<sup>[6]</sup>，本文的精度提高了3%左右。在其他研究中，深度学习算法相比于传统的机器学习算法有较大优势，但在本文中

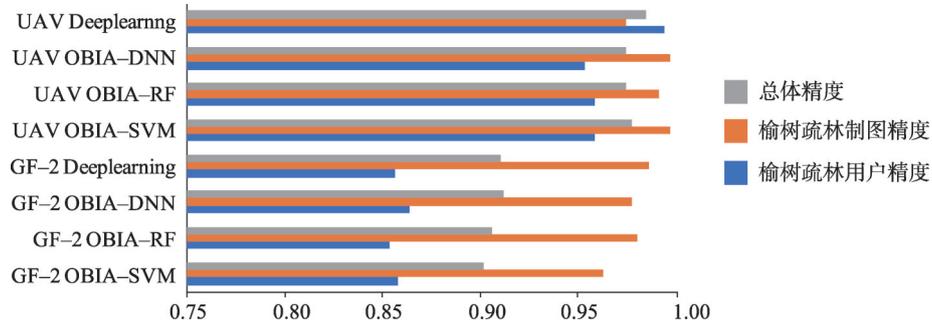


图 11 面向对象方法与深度学习方法精度对比

Fig. 11 Accuracy comparison between object-based method and deep learning method

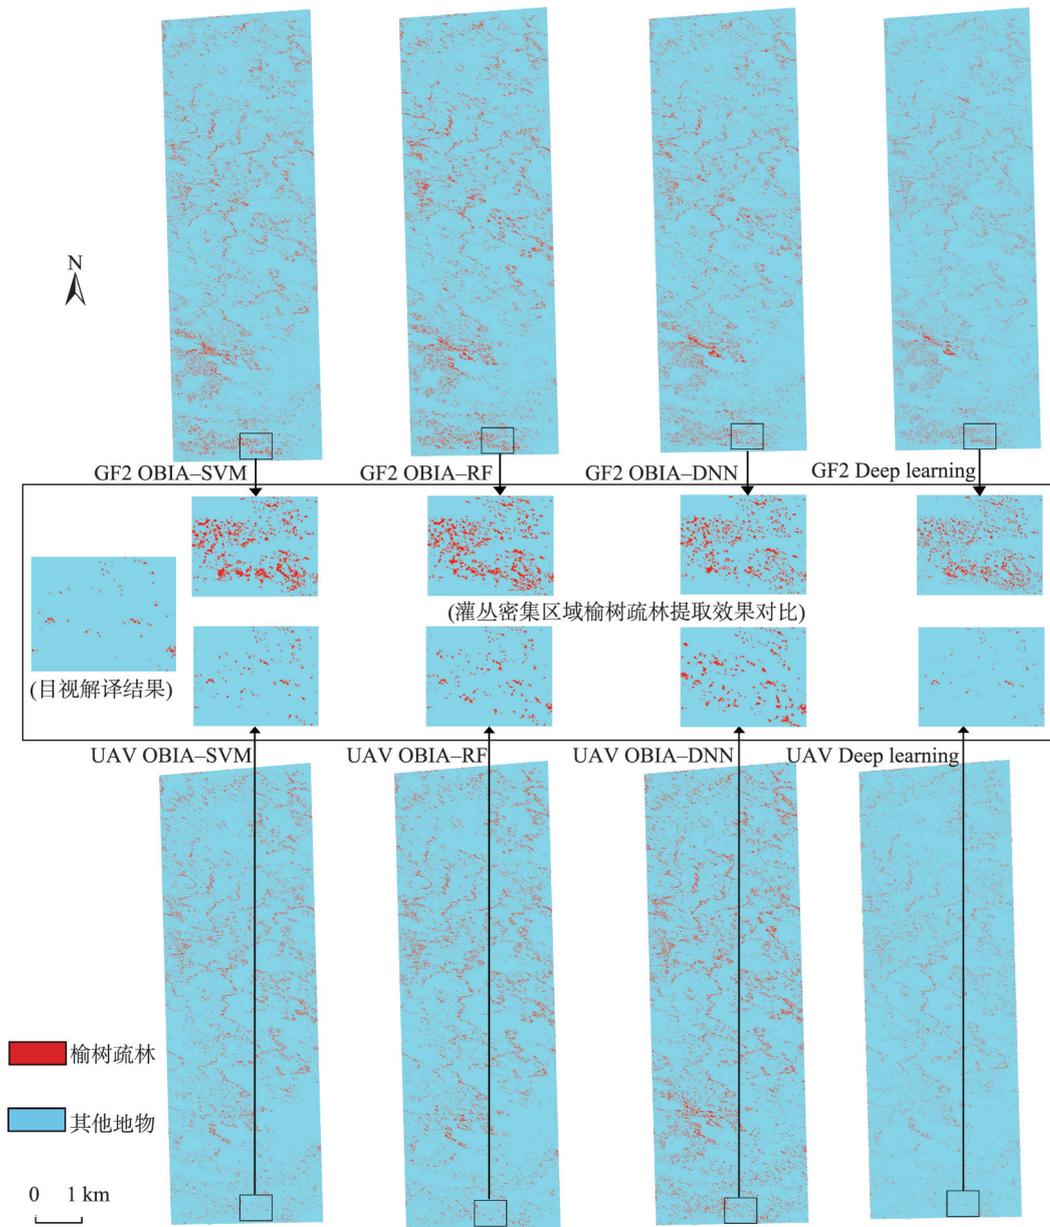


图 12 面向对象方法与深度学习方法榆树疏林提取效果对比

Fig. 12 Comparison of extraction result between OBIA and deep learning for elm sparse forest

深度学习与面向对象方法的精度相近,更适用于无人机影像,这可能与其训练样本的数量以及质量有关,传统的机器学习算法可以在小数据上能更好地工作,而为了实现高性能,深度学习需要非常大的训练数据集。此外,两种方法中榆树疏林的漏分误差都很小,各个算法都取得了很高的制图精度。

## 5 结论

本文选取浑善达克沙地腹地、锡林浩特市南部的榆树疏林典型区作为研究区域,基于无人机影像以及高分二号影像,利用面向对象方法与深度学习对区内榆树疏林识别进行了实验,以期为今后的榆树疏林研究、沙地动态监测提供有效的决策支持。主要结论如下:

(1)对面向对象方法的过程进行了优化。利用影像对象的局部方差变化率得到无人机影像的最佳分割尺度为140,GF-2影像的最佳分割尺度为89;其次,使用随机森林算法对两种影像中参与分类的特征进行了筛选与排序,无人机影像中有32个特征被判定为相关特征,CHM重要性得分最高,高分影像中的26个特征都被判定为相关特征,其中光谱最大差异被判定为最重要特征;最后使用SVM、RF、DNN3种分类器进行分类,3种方法精度相近,高分影像中DNN得到了最高精度91.14%,无人机影像中SVM方法得到了最高精度97.70%。

(2)在ENVI5.5中基于TensorFlow框架,利用U-Net深度学习模型对榆树疏林进行识别,无人机影像中榆树疏林识别的总体精度达到了98.43%,GF-2影像中的总体精度为91.00%。本文中深度学习方法在GF-2影像的应用中与面向对象方法得到的精度相近,而在无人机影像中,深度学习方法的精度最高,且非常有效的减少了背景地物的干扰。

综上,本文提出的优化后的面向对象方法能够有效的提取榆树疏林,且对无人机、GF-2两种影像都有较高的适用性,相比与以往利用GF-2影像进行榆树疏林识别的研究,提高了3%左右的精度。此外,研究中首次将深度学习方法应用于榆树疏林的识别中,它与无人机影像的结合在实验中取得了最高的精度,深度学习在地物识别领域有诸多优势,在榆树疏林提取中有较大的应用潜力,后续在进行大面积研究时应构建更高数量及质量的样本库,进一步提高精度,为榆树疏林的管理和研究提供帮助。

## 参考文献(References):

- [1] 韩东,王浩舟,郑邦友,等.基于无人机和决策树算法的榆树疏林草原植被类型划分和覆盖度生长季动态估计[J].生态学报,2018,38(18):6655-6663. [ Han D, Wang H Z, Zheng B Y, et al. Vegetation type classification and fractional vegetation coverage estimation for an open elm (*Ulmuspumila*) woodland ecosystem during a growing season based on an unmanned aerial vehicle platform coupled with decision tree algorithms[J]. *Acta Ecologica Sinica*, 2018,38(18):6655-6663. ]
- [2] 吴隐,韩东,姚雪玲,等.基于无人机高分辨率航空影像的榆树疏林空间分布格局及其地形效应[J].热带地理,2019,39(4):531-537. [ Wu Y, Han D, Yao X L, et al. Spatial pattern and landforms effects of elm (*ulmuspumila*) sparse forest based on high spatial-resolution aerial images from unmanned aerial vehicle (UAV) [J]. *Tropical Geography*, 2019,39(4):531-537. ]
- [3] Ke Y, Quackenbush L J. A review of methods for automatic individual tree-crown detection and delineation from passive remote sensing[J]. *International Journal of Remote Sensing*, 2011,32(17):4725-4747.
- [4] Boggs G S. Assessment of SPOT 5 and QuickBird remotely sensed imagery for mapping tree cover in savannas[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2010,12(4):217-224.
- [5] Cerian G, Sanchayeeta A, Luke R, et al. Application of object based classification and high resolution satellite imagery for savanna ecosystem analysis[J]. *Remote Sensing*, 2010,2(12):2748-2772.
- [6] 薛传平,高志海,孙斌,等.浑善达克沙地榆树疏林的高分辨率遥感识别方法[J].国土资源遥感,2018,30(4):74-81. [ Xue C P, Gao Z H, Sun B, et al. Research on high resolution remote sensing recognition method of elm sparse forest in Otindag sandy land[J]. *Remote Sensing for Land and Resources*, 2018,30(4):74-81. ]
- [7] Lei M, Tengyu F, Thomas B, et al. Evaluation of feature selection methods for object-based land cover mapping of unmanned aerial vehicle imagery using random forest and support vector machine classifiers[J]. *ISPRS International Journal of Geo-Information*, 2017,6(2):51-72.
- [8] 杜保佳,张晶,王宗明,等.应用 Sentinel-2A NDVI 时间序列和面向对象决策树方法的农作物分类[J].地球信息科学学报,2019,21(5):740-751. [ Du B J, Zhang J, Wang Z M, 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. ]
- [9] Li M, Lei M, Blaschke T, 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 & Geoinformation*, 2016,49:87-98.
- [10] 张鑫龙,陈秀万,李飞,等.高分辨率遥感影像的深度学习变化检测方法[J]. *测绘学报*,2017,46(8):999-1008. [ Zhang X L, Chen X W, Li F, et al. Change detection method for high resolution remote sensing images using deep learning[J]. *Acta Geodaetica et Cartographica Sinica*, 2017,46(8):999-1008. ]
- [11] 郑胤,陈权崎,章毓晋.深度学习及其在目标和行为识别中的新进展[J]. *中国图象图形学报*,2014,19(2):175-184. [ Zheng Y, Chen Q Q, Zhang Y J. Deep learning and its new progress in object and behavior recognition[J]. *Journal of Image and Graphics*, 2014,19(2):175-184. ]
- [12] 陈前,郑利娟,李娟,等.基于深度学习的高分遥感影像水体提取模型研究[J]. *地理与地理信息科学*,2019,35(4):43-49. [ Chen Q, Zheng L J, Li X J, et al. Water body extraction from high-resolution satellite remote sensing images based on deep learning[J]. *Geography and Geo-Information Science*, 2019,35(4):43-49. ]
- [13] 何海清,杜敬,陈婷,等.结合水体指数与卷积神经网络的遥感水体提取[J]. *遥感信息*, 2017,32(5):82-86. [ He H Q, Du J, Chen X Y, et al. Remote sensing image water body extraction combining NDWI with convolutional neural network[J]. *Remote Sensing Information*, 2017,32(5):82-86. ]
- [14] 闫峰,丛日春.中国沙地分类进展及编目体系[J]. *地理研究*,2015,34(3):455-465. [ Yan F, Cong R C. Study on classification progress and cataloging system of sandy land in China[J]. *Geographical Research*, 2015,34(3):455-465. ]
- [15] Dragut L, Csillik O, Eisank C, et al. Automated parameterisation for multi-scale image segmentation on multiple layers[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2014,88:119-127.
- [16] O'Connell, Jerome, Bradter U, Benton T G. Wide-area mapping of small-scale features in agricultural landscapes using airborne remote sensing[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2015,109:165-177.
- [17] 耿仁方,付波霖,蔡江涛,等.基于无人机影像和面向对象随机森林算法的岩溶湿地植被识别方法研究[J]. *地球信息科学学报*,2019,21(8):1295-1306. [ Geng R F, Fu B L, Cai J T, et al. Object-based karst wetland vegetation classification method using unmanned aerial vehicle images and random forest algorithm[J]. *Journal of Geo-information Science*, 2019,21(8):1295-1306. ]
- [18] Breiman L. Random Forests[J]. *Machine Learning*, 2001, 45(1):5-32.
- [19] 丁世飞,齐丙娟,谭红艳.支持向量机理论与算法研究综述[J]. *电子科技大学学报*,2011,40(1):2-10. [ Ding S F, Qi B J, Tan H Y. An overview on theory and algorithm of support vector machines[J]. *Journal of University of Electronic Science and Technology of China*, 2011,40(1):2-10. ]
- [20] 宋焕生,张向清,郑宝峰,等.基于深度学习方法的复杂场景下车辆目标检测[J]. *计算机应用研究*,2018,35(4):1270-1273. [ Song H S, Zhang X Q, Zheng B F, et al. Vehicle detection based on deep learning in complex scene [J]. *Application Research of Computers*, 2018,35(4):1270-1273. ]
- [21] 熊咏平,丁胜,邓春华,等.基于深度学习的复杂气象条件下海上船只检测[J]. *计算机应用*,2018,38(12):3631-3637. [ Xiong Y P, Ding S, Deng C H, et al. Ship detection under complex sea and weather conditions based on deep learning[J]. *Journal of Computer Applications*, 2018, 38(12):3631-3637. ]
- [22] 李淑敏,冯权泷,梁其椿,等.基于深度学习的国产高分遥感影像飞机目标自动检测[J]. *遥感技术与应用*,2018,33(6):1095-1102. [ Li S M, Feng Q L, Liang Q C, et al. Aircraft auto-detection in domestic high resolution remote sensing images using deep-learning[J]. *Remote Sensing Technology and Application*, 2018,33(6):1095-1102. ]
- [23] 白宇.基于深度学习的遥感图像林地识别技术的研究与应用[D].北京:北京邮电大学,2019. [ Bai Y. Research and application of forest remote recognition technichs based on deep learning[D]. Beijing: University of Posts and Telecommunications, 2019. ]
- [24] 罗巍,王东亮,夏列钢,等.一种基于深度学习的林业资源调查方法[J/OL]. *林业科技通讯*:1-9. [2019-10-02]. [ Luo W, Wang D L, Xia L G, et al. A method of forestry resources survey based on deep learning[J/OL]. *Forest Science and Technology*, 1-9. [2019-10-02]. ]
- [25] 汪小钦,王苗苗,王绍强,等.基于可见光波段无人机遥感的植被信息提取[J]. *农业工程学报*,2015,31(5):152-159. [ Wang X Q, Wang M M, Wang S Q, et al. Extraction of vegetation information from visible unmanned aerial vehicle images[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2015,31(5):152-159. ]