

CNN影像输入尺寸和分辨率对川西针叶林植被分类精度的影响

石伟博¹, 廖小罕^{2,3,4}, 王绍强^{1,5,6}, 岳焕印^{2,3,4}, 王东亮^{2,3}

1. 中国地质大学(武汉) 地理与信息工程学院 区域生态过程与环境演变实验室, 武汉 430074;

2. 中国科学院地理科学与资源研究所 资源与环境信息系统国家重点实验室, 北京 100101;

3. 中国科学院无人机应用与管控研究中心, 北京 100101;

4. 中国民航局 低空地理信息与航路重点实验室, 北京 100101;

5. 中国科学院地理科学与资源研究所 生态系统网络观测与模拟重点实验室, 北京 100101;

6. 中国科学院大学 资源与环境学院, 北京 100049

摘要: 川西亚高山针叶林位于中国西南地区, 受多云、多雨、多雾的影响, 难以通过卫星影像进行植被分类的研究。为了解决这一难题, 本研究选取川西亚高山针叶林的典型区域王朗自然保护区作为研究区, 使用多旋翼无人机获取研究区域北部高分辨率RGB影像, 结合卷积神经网络进行植被分类; 为进一步挖掘卷积神经网络在无人机遥感影像上的潜力, 选择语义分割方法(U-Net)进行分类, 并根据不同分辨率的无人机影像和不同尺寸下的样本集构建植被分类模型, 建立森林指纹库。结果表明: (1) 结合无人机可见光影像和CNN模型进行分类能够获得高精度分类结果。在空间分辨率为5 cm, 尺寸为256×256像素的情况下达到最优, 总体精度为93.21%, Kappa系数为0.90; (2) 选择合适的尺寸大小能够提高模型的分类精度。在5 cm的空间分辨率下, 尺寸为128×128像素的模型总体精度为82.30%, Kappa系数为0.76; 尺寸为256×256像素的模型总体精度为93.21%, Kappa系数为0.90; (3) 超高空间分辨率的升高对模型精度的提升是有限的。当空间分辨率从10 cm升到5 cm时, 模型的总体精度提高了0.02, Kappa系数提高了0.03, 模型的分类精度并没有明显提升。(4) 对于区域内代表性不足的植被类型来说, 受空间分辨率和尺寸大小的影响要远高于区域内优势树种, 特别是空间分辨率的影响最大。在20 cm的空间分辨率下落叶灌木的生产者精度和用户精度均低于70%。综上, 利用无人机高分辨率RGB影像结合CNN模型对川西亚高山针叶林的植被分类能够取得高精度分类结果, 本研究可为该区域植被分类提供一种自动、准确的方法。

关键词: 无人机RGB影像, 卷积神经网络, 川西亚高山针叶林, 植被分类, 输入尺寸, 空间分辨率

中图分类号: P23/P2

引用格式: 石伟博, 廖小罕, 王绍强, 岳焕印, 王东亮. 2023. CNN影像输入尺寸和分辨率对川西针叶林植被分类精度的影响. 遥感学报, 27(11): 2640–2652

Shi W B, Liao X H, Wang S Q, Yue H Y and Wang D L. 2023. Effects of image input size and resolution by CNN on the classification accuracy for coniferous forest vegetation in western Sichuan. National Remote Sensing Bulletin, 27(11): 2640–2652 [DOI: 10.11834/jrs.20221868]

1 引言

森林作为地球上十分重要的生态系统, 具有生物多样性保护、固碳释氧、气候调节、水源涵养、水土保持、环境净化等生态功能(廖亮林等, 2016; Iverson等, 2018; 朱万泽等, 2021), 对区

域内乃至全球的生态多样性、碳循环等有很大的贡献。川西亚高山针叶林作为我国第二大林区(西南林区)的主体(杜志等, 2014), 是长江上游重要的生态屏障, 在区域气候调节、水源涵养和生物多样性保育等方面具有不可替代的作用和地位(刘庆等, 2001)。就森林生态系统而言, 了

收稿日期: 2022-01-04; 预印本: 2022-07-13

基金项目: 中国科学院战略性先导科技专项(编号:XDA19050501); 中国地质大学(武汉)科研启动基金(编号:162301192642)

第一作者简介: 石伟博, 研究方向为无人机遥感。E-mail: shiweibo@cug.edu.cn

通信作者简介: 廖小罕, 研究方向为无人机遥感与管控技术。E-mail: liaoxh@igsnr.ac.cn

解森林植被分布对于森林的可持续管理十分重要。过去,为了获取植被的分布情况,往往采取实地调查的方式。这种方法耗时耗力,成本也很高,对于西南林区而言,由于其复杂的地形条件,还会有一定的安全隐患。随着遥感技术的不断进步,遥感已经成为获取森林植被分布的重要手段之一,在林业中得到广泛的应用(Fassnacht 等, 2016)。传统的卫星数据,如 Landsat、SPOT 系列等卫星影像,由于其空间分辨率较低,无法提供足够的空间细节,往往只用作大范围植被制图。高分卫星数据,如 IKONOS、QuickBird、WorldView 等卫星影像,能提供米级甚至亚米级的遥感数据,但面临着时效性差、成本高等问题,同时受制于西南林区多云多雨多雾的气候特点,导致卫星有效观测时间更短,获得高质量、多时空的遥感影像数据难度更大。

近年来随着无人机和遥感器技术的不断发展,无人机的续航时间不断提升,搭载能力越来越强,无人机已经成为一种新型的遥感观测平台,被广泛应用于各个领域(Colomina 和 Molina, 2014; 廖小罕 等, 2016; Pajares, 2015; Maes 和 Steppe, 2019)。无人机的主要优势就在于高频次、迅捷(廖小罕 等, 2019),可以用一种相对较近的方式观察地物,能够灵活、方便、快捷的获取遥感数据。此外,相较于卫星平台,无人机往往在云层下面进行观测,所以无人机遥感数据不需要进行过多的大气校正;由于无人机对于起降场地要求不高,能够适应林业复杂的地理环境,可以获得高时间、高空间分辨率的林业影像数据,对森林资源的调查和监测提供了强有力的技术支撑(曹忠, 2016; 刘清旺 等, 2017),无人机遥感技术已经应用到林火与病虫害监测(何诚 等, 2014; 黄华毅 等, 2021)、森林结构参数估测(王娟 等, 2022; 王越 等, 2022)、森林植被观测(Zheng 等, 2021)与分类(Zhang 等, 2020b; Hao 等, 2021)、树种多样性监测(Xu 等, 2021)等方面。

随着深度学习的兴起,特别是卷积神经网络 CNN(Convolutional Neural Networks)的兴起,在计算机视觉和模式识别上取得了较大进展,越来越多的研究者使用新兴的平台和技术进行森林植被研究(Kattenborn 等, 2021)。Zhang 等(2020a)使用机载高光谱数据对南方人工林林场植被进行分类,利用改进的 3D-CNN 分类模型实现了大面

积、高精度的树种分类;Trier 等(2018)使用机载激光扫描和高光谱数据,结合深度神经网络对挪威森林中的 3 个优势树种进行分类制图,精度达 87%。然而,高光谱载荷设备昂贵,飞行成本较高,并且高光谱遥感数据往往需要专业的人员进行影像处理,门槛较高,难以在林业研究中进行普及。

随着消费级无人机的兴起,林业研究者能够以低成本的代价获取超高空间分辨率的 RGB 影像数据,这对于林业研究有着非常重大的意义。RGB 影像数据不依赖于复杂的传感器,不需要专业的校准和数据预处理,节约了影像处理时间和减少数据成本,并且能够广泛的应用在国内外林业工作中(Natesan 等, 2019; 林志玮 等, 2019; 戴鹏钦等, 2020)。Natesan 等(2019)等使用消费级无人机获取加拿大安大略省保护林的 RGB 影像,使用 CNN 对白松、红松两种优势树种进行分类,精度可达 80%;林志玮 等(2019)使用无人机光学图像结合 DenseNet 卷积神经网络模型对 12 个树种进行分类,模型精度达到 87.54%。然而在这些研究中大多只考虑了森林的物种多样性,大部分的实验地点和研究区域往往倾向于良好的生态条件,如地势较为平坦、林内物种复杂度较低、种内年龄组数量较少、距道路较近等,没有考虑到森林内复杂的生态条件,人为干扰因素较多。并且由于无人机影像的获取与处理有着自身的特殊性,研究主要集中在树种分类的精度上,但对于空间分辨率与影像裁剪尺寸上的研究尚不多见。

基于此,本研究选取地形条件复杂、种内年龄组差异较大、人迹罕至、高原高山生态环境的川西亚针叶林为研究区域,拟使用无人机获取典型区域的高分辨率 RGB 影像,结合多类语义分割方法(U-Net)对实验区进行植被分类,构建不同分辨率和裁剪尺寸的样本集,并建立基于多个样本集的森林指纹库;通过模型构建和精度比较,分析讨论无人机影像的空间分辨率和裁剪尺寸对 CNN 模型精度的影响,以期为川西亚针叶林的植被监测研究提供科学依据。

2 研究区域概况

研究区域位于中国四川省平武县王朗国家级自然保护区(103°55'E—104°10'E, 32°49'N—33°02'N)(图1)。王朗自然保护区位于青藏高原与四川盆地

两大地貌单元的交汇地段，地处横断山脉北缘的川西高山峡谷地区，其原始森林是川西北地区保存最完好的一片（顾人和，2005）。保护区属于丹巴—松潘半湿润气候，海拔高度为2300—4980 m，

气候有明显的垂直地带性，年平均温度2.5℃—2.9℃，最低温-17.8℃，最高温26.2℃，年降雨量859.9 mm。




图1 研究区域概况

Fig. 1 Overview of the study area

该研究区域地处岷山北部野生大熊猫核心栖息地，是北京大学和中国科学院植物研究所主持共建的监测样地，于2020年加入“中国森林生物多样性监测网络（CForBio）”；其远离道路和人为因素干扰，生态环境复杂，种内年龄组差异较大，属于高山高原地区，区域内地形起伏较大，高差达100多米。根据样地清查数据显示，研究区域内以针叶树、落叶乔木、落叶灌木、藤本为主，其中针叶树中以岷江冷杉（*Abies faxoniana*）为优势树种，林中伴随着紫果云杉（*Picea purpurea*）与方枝柏（*Sabina saltuaria*）；落叶乔木主要以川西樱桃（*Cerasus trichostoma*）、红桦（*Betula albosinensis* Burk）、紫华卫矛（*Euonymus porphyreus* Loes）为主；落叶灌木主要有紫萼山梅花（*Philadelphus purpurascens*）、陕甘花楸（*Sorbus koehneana* Schneid）、红脉忍冬

（*Lonicera nervosa* Maxim）等为主；藤本主要以猕猴桃藤山柳（*Clematoclethra actinidioides* Maxim）为主。由于原始森林内部情况复杂，难以在无人机影像上进行一一对比，因此本研究综合考虑了野外实地调查结果和植被树冠特征，将森林植被分类为岷江冷杉、落叶乔木、落叶灌木、其他植被。其中，其他植被主要指研究区内面积所占比例很小的林窗、藤本、枯木等植被。由于保护区为国家级自然保护区，同时也是大熊猫栖息地之一，人迹罕至，除却河流、裸石外无复杂地物，所以标记其他类型植被时人为误差较小。

3 数据来源与研究方法

3.1 数据来源

无人机影像是于2020年06月15日下午使用

DJI 大疆 Mavic 2 无人机在王朗自然保护区进行飞行获取。该无人机是消费级无人机, 小巧轻便, 不到 1 kg, 便于携带, 搭载 1 英寸 CMOS 相机, 具有障碍物感知能力, 适合在森林中进行无人机 RGB 影像的获取。由于样地内地形起伏较大, 为了保障无人机飞行时的安全, 还能够获取较高质量的超高分辨率 RGB 影像, 飞行高度设置为距起降地 300 m, 旁向重叠率 80%, 航向重叠率 80%, 飞行时天气整体良好, 空中无云。本研究对样地进行了两次飞行, 6 月 15 日中午飞行一次, 下午飞行一次; 6 月 16 日下午又对样地进行一次飞行, 并以相同飞行参数对相邻样地进行拍摄。因为 15 日中午阳光强烈, 无人机原始航拍照片过曝严重, 导致飞行数据无法使用; 而下午飞行时阳光较弱, 数据质量无明显阴影效果; 所以最终选择 15 日下午的飞行影像进行样本标注, 而 16 日拍摄的两组影像则作为未训练的影像。后续将获取到的原始航拍影像等信息导入到专业拼图软件 Pix4D Mapper, 经过影像质量检查、影像数据自动匹配、点云处理等操作后, 生成 DSM 和空间分辨率为 5 cm 的 25 hm² 正射影像。

3.2 训练样本的选取及制作

训练卷积神经网络模型的前提条件之一就是

要制作训练样本。本研究区域位于王朗自然保护区北部, 海拔 3000 多米, 远离道路, 无法进入实地与无人机影像上树木进行一一比对。基于无人机高分影像、树冠特征与野外调查数据, 选取正射影像中典型区域作为感兴趣区, 使用 ArcGIS Pro 软件将图斑标记为岷江冷杉、落叶乔木、落叶灌木, 其他植被。

由于无人机正射影像尺寸较大, 难以直接进行训练, 所以要先进行影像裁剪。为研究不同尺寸下影像裁剪对分类精度的影响, 对无人机 RGB 影像选择三种尺寸进行裁剪, 分别是 128×128、256×256、512×512 像素, 在野外对应 6.4 m、12.8 m、25.6 m 的样地距离; 在设置步长时, 本研究选择步长等于裁剪尺寸的一半, 保证样本之间有 50% 的重叠, 步长分别为 64、128、256 像素。为了研究不同空间分辨率下的无人机影像与深度学习模型之间的精度关系, 对 5 cm 的正射影像进行重采样到 10 cm、15 cm、20 cm, 以最优裁剪尺寸进行分割。样本集的部分样本如图 2 所示。样本集均通过数据增强的方式来扩充样本数量, 这样可以在增强样本量的同时降低数据拟合的风险; 最后将样本集中的 90% 用作训练集, 进行模型的训练和拟合, 取 10% 作为验证集进行验证。




图 2 样地内植被类型展示

Fig. 2 Demonstration of vegetation types in the sample plots

3.2 研究方法

3.2.1 U-Net 网络模型

U-Net 网络模型由 Ronneberger 等 (2015) 提出, 是一种端到端网络模型结构, 沿用了编码器—解码器结构和跳跃网络的特点, 使得模型能够将高层语义信息和浅层特征进行融合, 充分利用上下文信息和细节信息, 使得模型在较小的训练集

上, 也能得到更为准确的特征图。

U-Net 网络模型主要包括收缩路径和扩展路径。收缩路径主要用于提取图像的上下文特征, 有 4 个区块, 每个区块有两个 3×3 的卷积层和一个 2×2 的池化层组成, 其中卷积层使用修正线性单元 ReLU (Rectified Linear Unit) 作为激活函数。池化层使得图像经过每一个区块后图像的尺寸减少了一半, 而卷积层则使得特征通道增加了一倍。扩

展路径主要将上下文信息映射到原始尺度, 同样也有4个区块。每个区域先通过一个上采样的卷积层, 再进行特征拼接后, 最后通过两个3×3的卷积层和激活函数(ReLU), 每个区块都使得图像的尺寸扩大一倍, 特征通道减少一倍, 同时连接了收缩网络的特征信息。最后, 通过1×1的卷积操作将全部的特征向量映射到所设定的类别上。

3.2.2 ResNet-34

ResNet-34 是 ResNet 残差网络的一种网络结构, 是由 He 等 (2016) 提出, 主要参考了 VGG19 网络, 通过短路机制加入了残差单元, 使得深度网络收敛速度加快, 解决了深度网络的退化问题。ResNet-34 网络是指具有 34 层结构的 ResNet 网络

结构, 先采用 7×7 尺寸, 通道 64 的卷积核进行卷积处理, 再进行最大池化操作, 然后构造了由 4 个不同残差模块组成的 32 层的卷积残差结构, 最后使用平均池化和全连接层输出结果。

本研究将 ResNet34 与 U-Net 网络模型进行结合, 使用 ResNet34 作为 U-Net 模型的骨架模型, 能够有效的利用卷积网络模型的深度优势, 提升模型的精度。由于研究区内岷江冷杉为优势树种, 落叶灌木样本较少, 所以出现样本分布不均的情况。为了缓解这种情况, 本研究使用加权分类交叉熵作为损失函数, 使用随机梯度下降算法作为分类器的优化算法, 每次迭代训练的样本数目为 8, 模型训练的 epoch 设置为 100, 并且当模型不在改进时, 将终止模型训练。模型架构如图 3 所示。




图3 基于ResNet34骨架结构的U-Net模型
Fig. 3 U-Net model based on ResNet34 backbone

3.2.3 精度评价

为了分析尺寸大小、空间分辨率对CNN模型精度的影响, 本研究基于生产者精度PA (Producer's Accuracy)、用户精度UA (User's Accuracy)、总体精度OA (Overall Accuracy) 和 Kappa 系数 (Kappa Coefficient) 来对模型进行精度评价。计算公式如下:

$$PA = \frac{m_i}{C_i} \quad (1)$$

$$UA = \frac{m_i}{G_i} \quad (2)$$

$$OA = \frac{\sum_{i=1}^n m_i}{N} \quad (3)$$

$$Kappa = \frac{N \times \sum_{i=1}^n m_i \sum_{i=1}^n - \sum_{i=1}^n (G_i \times C_i)}{N^2 - \sum_{i=1}^n (G_i \times C_i)} \quad (4)$$

式中, m_i 为第 i 类的分类正确样本数; C_i 为第 i 类的分类像元总数; G_i 为第 i 类的真实像元总数; N 为分类像元总数。

4 结果与分析

4.1 模型训练情况

无论是在训练集还是验证集上, 每个模型的损失值都随着批处理的不断增加而不断收敛。使用 128×128 像素的模型在验证集上模型精度最差, 使用 256×256 像素的模型精度最高。在空间分辨率的研究中, 均选择最优裁剪尺寸 256×256 像素来裁剪影像。使用空间分辨率 5 cm 和 10 cm 的模型都能达到高精度水平, 使用空间分辨率 20 cm 的模型精度最差。模型训练的情况如图 4 所示。




图4 不同裁剪尺寸和不同分辨率的模型训练结果

Fig. 4 Training results of models with different crop sizes and different resolutions

4.2 模型训练结果

基于不同裁剪尺寸和不同分辨率的植被模型分类情况见表1和表2。由表1可见：表现最好的模型是在5 cm空间分辨率下使用256×256像素进行训练的模型，总体精度达93.21%，Kappa系数为0.90；在使用不同裁剪尺寸建立的深度学习模型中，128×128像素的模型效果最差，总体精度为82.30%，Kappa系数为0.76；使用512×512像素的深度学习模型效果比使用256×256像素的深度学习模型效果差一些，总体精度为88.89%，Kappa系数为0.84。在不同尺寸的深度学习模型中，对于覆盖范围大的植被类型，如岷江冷杉，无论是生产者精度上，还是用户精度上变化不大，生产者精度从最高95.74%下降到88.42%，用户精度从最高94.13%下降到88.62%；而对于覆盖范围较少的植被类型来说，精度则相差较大，如落叶灌木，用户精度从最高91.00%下降到79.17%。

表1 基于不同裁剪尺寸大小的植被模型精度对比

Table 1 Accuracy comparison of vegetation model based on different pixel tile sizes

类别 Type	128×128 像素		256×256 像素		512×512 像素	
	PA/%	UA/%	PA/%	UA/%	PA/%	UA/%
岷江冷杉 <i>Abies faxoniana</i>	88.42	91.60	95.74	94.13	95.06	88.62
落叶乔木 Deciduous tree	82.45	80.80	92.23	94.18	83.50	87.89
落叶灌木 Deciduous shrub	91.35	79.17	95.79	91.00	91.58	88.78
其他植被 Other lands	70.14	77.69	90.58	92.37	85.28	89.77
总体精度/% Overall accuracy	82.30		93.21		88.89	
Kappa 系数 Kappa coefficient	0.76		0.90		0.84	

注：所有模型是在5 cm空间分辨率下的无人机影像上进行测试。

由表2可见，在不同空间分辨率的深度学习模型中，模型精度最差的是空间分辨率为20 cm的深

深度学习模型，总体精度为72.20%，Kappa系数为0.61。空间分辨率为15 cm的深度学习模型效果一般，总体精度为80.52%，Kappa系数为0.72；空间分辨率为10 cm的深度学习模型效果良好，总体精度为90.17%，Kappa系数为0.89。对于覆盖范围大的植被类型而言，生产者精度和用户精度在较高的空间分辨率模型中相差不高，但在低空间分辨率模型中则有下降的趋势，如岷江冷杉在空间分辨率为5 cm和10 cm的深度学习模型中生产者精度

和用户精度均在90%以上，但在20 cm的深度学习模型中，岷江冷杉生产者精度为87.43%，用户精度为76.31%。而覆盖范围低的植被类型在低分辨率的深度学习模型中生产者精度和用户精度下降的更快，如落叶灌木在10 cm空间分辨率的模型下，生产者精度为89.11%，用户精度为87.38%，而在15 cm的深度学习模型中生产者精度为72.12%，用户精度为79.79%。

表2 基于不同空间分辨率的植被模型精度对比

Table 2 Accuracy comparison of vegetation model based on different spatial resolutions

类别	5 cm		10 cm		15 cm		20 cm	
	PA/%	UA/%	PA/%	UA/%	PA/%	UA/%	PA/%	UA/%
岷江冷杉	95.74	94.13	94.17	93.13	91.64	81.96	87.43	76.31
落叶乔木	92.23	94.18	86.98	90.27	78.42	78.01	65.31	66.67
落叶灌木	95.79	91.00	89.11	87.38	72.12	79.79	68.93	69.61
其他植被	90.58	92.37	90.20	89.94	73.33	80.49	61.82	71.15
总体精度/%	93.21		90.90		80.52		72.20	
Kappa系数	0.90		0.87		0.72		0.61	

注：所有模型是在256×256像素下的样本集进行测试。

4.3 模型应用

为了验证模型的适用性和可迁移性，本研究选择16日拍摄的两幅无人机RGB影像作为研究对象，使用256×256像素下5 cm空间分辨率的最优模型进行分类。其中，对同一样地进行飞行拍摄得到的无人机影像局部放大图为图5（a）所示，图5（b）是模型检测后的分类图。由图5（a）可见岷江冷杉由于其生长周期不同，种间年龄差异较大，树冠呈现出不同的颜色差异，出现“同物异谱”的现象。从图5（b）可见：各植被类别边界清晰，碎图斑较少，能够把绝大部分岷江冷杉识别出，岷江冷杉的冠层形态较好；落叶乔木和落叶灌木整体识别良好，部分区域出现漏识。黄框标注的树木为岷江冷杉，模型能够准确识别，但对于特复杂的树木边缘识别能力较弱；红框标注的树木为落叶乔木，模型将其误识为其他植被；整体分类效果不错，能够较为准确的识别出各种植被类型（图5（a））。

对周边样地的无人机可见光影像局部放大图为图5（c）所示，图5（d）是模型检测后的分类图。图5（c）中黄框标注的为岷江冷杉，模型误识为其他类别；红框标注的为落叶乔木，模型误

识为落叶灌木。从图5（d）中，能看到岷江冷杉的分类效果较好，只有少量的漏分错分，而落叶乔木和落叶灌木分类效果一般。但从总体来看，主要植被类型都能够正确的进行分类，分类精度较好；不过分类结果中出现“椒盐现象”，存在不少碎图斑，边缘效应明显。

5 讨论

5.1 模型整体表现

虽然本研究区域生态条件复杂，远离道路，地形起伏较大，但在仅使用无人机高分辨率RGB影像的情况下，通过使用U-Net语义分割模型，结合ResNet残差网络在复杂生态条件下对川西亚高山针叶林植被进行分类得到较高的精度；并通过该模型对不同区域的植被检测获得了不错的分类效果，证明了模型具有一定的可移植性。Zhang等（2021）使用深度学习和无人机高分影像对杭州城市森林进行分类，得到较高的分类精度；Zhang等（2020a）使用3D卷积神经网络处理机载高光谱数据，对南方国有林场进行大范围的树种分类，在50 ha内取得了93.14%的分类精度。然而他们的研究对象生态环境简单，森林异质性低，没有考虑

到原始森林的复杂性，并且后者使用的机载高光谱数据虽然覆盖范围广，能够获得大面积的树种

信息，但是数据获取成本高，难以进行大面积推广。

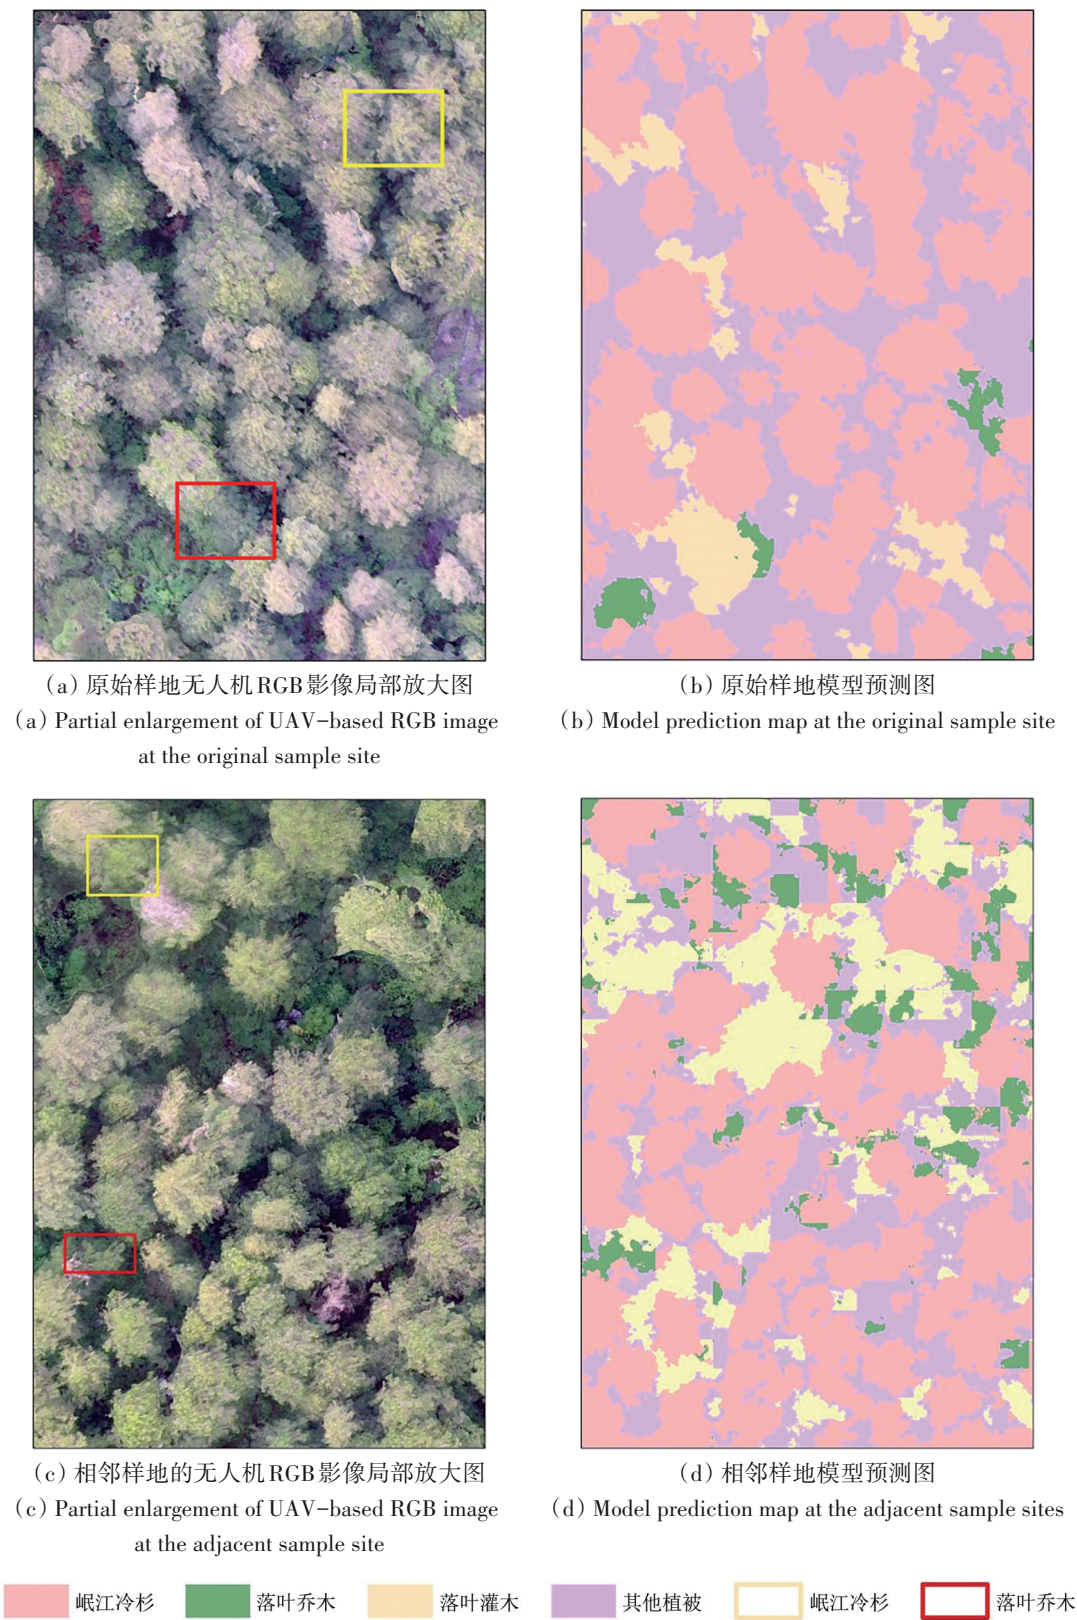


图5 样地影像与模型预测图对比

Fig. 5 Comparison of sample site images and model prediction maps

本研究使用消费级无人机对原始森林进行影像获取,建立了高山暗针叶林森林指纹库。指纹库内包含一个树种、2个植被类型,不同空间分辨率、不同尺寸的无人机可见光影像数据。这些数据具有高度异质性的特点,因为研究区域包括不同的植被类型,并且具有不同的年龄结构,如岷江冷杉一年生枝淡黄褐色或淡褐色,二、三年生则呈淡黄灰色或黄灰色,这就导致了岷江冷杉的冠层在同一时期会有不同的颜色,使得同一物种在无人机可见光影像上有不同的光谱特征,这种特征也在图5(a)和图5(c)中有所展示,增加数据的异质性的同时也增加了分类难度。该结果也表明,使用卷积神经网络模型能够有效的解决“同物异谱”的分类问题。

由于样地内部没有通讯信号,使用RTK获取样地内坐标信息进行地形校正较困难,使得拼接好的无人机影像在部分起伏较大的区域出现轻微变形和空洞情况,但使用高空间分辨率的无人机影像结合卷积神经网络模型仍然取得了较好的分类结果,这与Schiefer等(2020)和贾莉等(2022)的研究情况一致。Schiefer等(2020)在研究德国温带森林时表示,对比RGB影像,使用RGB+DSM数据仅能略微提高分类精度,他认为这可能是因为高度信息以阴影和光照差异的形式已经包含在RGB影像中。贾莉等(2022)使用Landsat 8 OLI 30 m影像,结合GDEM_V2 30m地形数据,也发现对森林地类精细的划分下地形校正未能提高U-Net分类器的分类精度。由于地形起伏所造成的影像差异可能以其他的方式学习到模型中,这也充分说明了卷积神经网络模型在森林起伏环境下的泛化能力。本研究充分利用了卷积神经网络中端到端的学习能力,结合使用消费级无人机获取的可见光影像,验证了CNN能够在复杂的森林生态条件下进行川西亚高山针叶林植被分类的潜力。

5.2 卷积神经网络模型

随着深度学习的不断发展,大量的研究表明CNN优于浅层机器学习方法,能够非常有效的从遥感图像中提取广泛的植被特征,甚至能够提高我们对于植被遥感信号的理解(Kattenborn等,2021)。这是因为CNN通过大量的输入数据,在不同的空间尺度上进行连续变化,学习图像的空间特征,如边缘信息,纹理信息等抽象信息,从而能够准

确的描述目标的类别和数量。

对于高光谱数据来说,由于其数据高纬度的特性,多用于3D-CNN模型进行处理;而对于可见光数据,大多使用二维CNN模型进行处理。而U-Net模型是一种端到端的学习方法,不需要过多的预处理步骤,在小训练集的情况下也能够得到不错的分类效果,同时考虑到研究区植被郁闭度较高、具有复杂的生态条件和地形情况,所以选取了U-Net模型进行植被分类。

植被指数作为地表植被状况最有效度量之一,随着无人机可见光影像的不断发展,无人机可见光指数也越多越多的被提及和使用(汪小钦等,2015)。戴鹏钦等(2020)使用融合VDVI和ExG-ExR两种植被指数的FCN方法提高了无人机影像的树种分类精度,然而更复杂的模型也需要更多的数据预处理步骤和模型处理时间。由于本研究主要讨论空间分辨率和裁剪尺寸对深度学习模型分类精度的影响,所以并没有添加可见光植被指数进行模型实验。

5.3 尺寸大小

由表1可见选择合适的裁剪尺寸大小能够提高模型的分类精度。尺寸为256×256像素的训练模型与尺寸为128×128像素、512×512像素的训练模型相比,模型总体精度高10.91%、4.32%,Kappa系数高0.14、0.06。尺寸为128×128像素的模型精度最低,而尺寸为256×256像素的模型精度比512×512像素的模型精度略微提升,这可能是因为较大的尺寸能够增加CNN的视野,使得模型获得更多的空间上下文信息,从而提高模型的准确性;而过大的尺寸大小可能会影响映射输出的空间粒度,从而降低模型的学习能力。

在尺寸模型中,岷江冷杉的生产者精度和用户精度都在88%以上,落叶乔木在256×256像素的模型与512×512像素的模型中精度较高,在128×128像素的模型中精度最低,PA为82.45%,UA为80.80%;落叶灌木和其他植被在128×128像素的模型中精度最低。对于覆盖范围大的植被类型来说,尺寸大小对于训练模型的精度影响不大;然而对于植被覆盖范围小的植被类型来说,特别是落叶灌木,尺寸的大小对模型的精度影响很大,这可能与分类目标的覆盖度和尺寸有关。因为低覆盖度的植被在小切片上容易丢失上下文信息,

并且由于落叶灌木的分布比较零散,更加剧了这一现象。而岷江冷杉为研究样地的优势树种,并且树冠直径适中,在实际距离为 6.4 m、12.8 m 和 25.6 m 的尺寸下获得不错的分类精度;落叶乔木树冠则比岷江冷杉较大,在低尺寸下的分类精度则一般,在较大尺寸下分类精度得到明显提高。所以,我们在进行图像裁剪时,要根据待分类目标的尺寸大小和覆盖度选取合适的裁剪尺寸,这会更好的发挥 CNN 的模型能力,提高分类精度。

5.4 空间分辨率

由表 2 发现随着空间分辨率的升高,训练模型的分类精度逐渐提升。当空间分辨率从 5 cm 降到 20 cm 时,模型的总体精度从 93.21% 降到 72.20%, Kappa 系数从 0.90 降到 0.61,各类别的分类精度都呈现大幅度降低的情况。这可能是较高的空间分辨率能够提供更多的空间特征,如纹理信息、边缘信息等,低分辨率使得模型无法获得更多的深度信息,导致模型效果变差。林志玮等(2019)对比不同航拍高度的影像分类结果,也发现随着航拍高度的上升,分类的正确率呈现下降的趋势。

在 15 cm 空间分辨率的模型中,落叶灌木精度最低,PA 为 72.12%,UA 为 79.79%;落叶乔木 PA 为 78.42%,UA 为 78.01%;而在 20 cm 空间分辨率的模型中,落叶乔木精度最低,PA 为 65.31%,UA 为 66.67%,落叶灌木的 PA 为 68.93%,UA 为 69.61%,这是因为在丢失了较多的空间细节后,落叶乔木与岷江冷杉容易混淆,导致分类精度降低。然而,从整个模型精度走势来看,落叶灌木受分辨率影响最大,在低分辨率模型中分类精度一直呈现较低的状态。




图6 空间分辨率模型的精度趋势

Fig. 6 Accuracy trend of spatial resolution model

在空间分辨率模型中,较高分辨率的模型之间精度相差不大。当空间分辨率从 10 cm 升高到 5 cm 时,总体精度从 90.90% 提高到 93.21%, Kappa 系数从 0.87 提高到 0.90,模型的分类精度并没有明显提升。这说明当空间分辨率到一定精度时,地物的类内差异性和类间变异性达到一个平衡,模型精度的提高受空间分辨率的影响会变低。我们可以这样认为,影像的空间分辨率要根据待分类地物的特征和类别数量进行选择;盲目追求过高的空间分辨率并不一定能带来模型分类精度上的提升,反而会降低无人机的作业效率,要求更高的存储空间,增加更多的模型计算。这些发现更加强调了,与卫星影像和机载数据相比,无人机获取的高分影像数据结合 CNN 在林业树种精细识别和分类方面能够有巨大的应用空间和潜力。

6 结 论

本研究使用消费级无人机对复杂生态场景下的川西亚高山针叶林获取可见光影像数据,建立不同分辨率、不同裁剪尺寸下的森林指纹库;并基于卷积神经网络构建深度学习模型进行植被分类,对比了不同分辨率和不同尺寸下的分类精度,并且对不同情况下的分类结果进行了分析,主要结论如下:

(1) 结合无人机可见光影像和 U-Net 模型进行复杂生态场景下的川西亚高山针叶林植被分类,在 5 cm 分辨率和 256×256 像素的尺寸下获得总体精度 93.21%, Kappa 系数为 0.90 的高精度分类结果。本研究也证明了该模型在复杂生态场景下的适应性和可移植性,同时也放宽了森林数据获取的质量要求,有利于森林树种影像的获取和森林指纹库的建立与共享。

(2) 根据待分类目标的尺寸大小和覆盖度选取合适的裁剪尺寸,能够让卷积神经网络获得更多的上下文信息,提高分类精度。低覆盖度和较小尺寸的植被类别在小尺寸的模型上精度较低。

(3) 随着空间分辨率的升高,训练模型的分类精度逐渐提升,但当在空间分辨率达到一定程度时,模型的分类精度并没有明显的提升。因此,模型的空间分辨率要根据待分类地物的类内差异性、类间变异性及类别数量进行选择,盲目追求

过高的空间分辨率是不可取的。

(4) 对于区域内代表性不足的植被类型来说,受空间分辨率和尺寸大小的影响要远高于区域内优势树种,特别是空间分辨率的影响最大。

本研究证明了在复杂的生态环境下,使用卷积神经网络对高空间分辨率的无人机可见光影像进行川西亚高山针叶林植被分类是有效可行的,并且研究了不同尺寸和不同空间分辨率下对模型精度的影响,给林业工作者对森林植被分类与识别的研究进行提供借鉴。同时,建立了以川西亚高山针叶林为研究对象的森林指纹库,能够满足不同尺度下的森林研究,这点对于植被分类,尤其是在区域性的森林研究有着重大的意义。在未来的研究中,要更加考虑研究区域的物候性特征,收集多季节影像增加模型的泛化能力;还要应该进一步考虑种间类型的差异,进行实地考察搜集复杂环境下的落叶乔木树种信息,细化植被分类的类别。

参考文献(References)

- Cao Z. 2016. Present situation and forecast on forest investigation and monitoring by unmanned aerial vehicle. *Forestry Construction*, (6): 1-5 (曹忠. 2016. 低空无人机森林资源调查与监测应用现状与展望. *林业建设*, (6): 1-5)
- Colomina I and Molina P. 2014. Unmanned aerial systems for photogrammetry and remote sensing: a review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 92: 79-97 [DOI: 10.1016/j.isprsjprs.2014.02.013]
- Dai P Q, Ding L X, Liu L J, Dong L F and Huang Y T. 2020. Tree species identification based on FCN using the visible images obtained from an unmanned aerial vehicle. *Laser and Optoelectronics Progress*, 57(10): 101001 (戴鹏钦, 丁丽霞, 刘丽娟, 董落凡, 黄依婷. 2020. 基于FCN的无人机可见光影像树种分类. *激光与光电子学进展*, 57(10): 101001) [DOI: 10.3788/LOP57.101001]
- Du Z, Gan S S and Hu J. 2014. Characteristics and protection strategy of forest resources in the alpine region of southwest China. *Forest Resources Management*, (Z1): 27-31 (杜志, 甘世书, 胡觉. 2014. 西南高山林区森林资源特点及保护利用对策探讨. *林业资源管理*, (Z1): 27-31) [DOI: 10.13466/j.cnki.lyzygl.2014.S0.007]
- Fassnacht F E, Latifi H, Stereńczak K, Modzelewska A, Lefsky M, Waser L T, Straub C and Ghosh A. 2016. Review of studies on tree species classification from remotely sensed data. *Remote Sensing of Environment*, 186: 64-87 [DOI: 10.1016/j.rse.2016.08.013]
- Gu R H. 2005. Analysis and estimation for the landscapes of the nature as the Wanglang national preserve. *Journal of Biology*, 22(3): 1-4 (顾人和. 2005. 王朗自然保护区的大自然景观类型分析与评价. *生物学杂志*, 22(3): 1-4) [DOI: 10.3969/j.issn.2095-1736.2005.03.001]
- Hao Z B, Lin L L, Post C J, Mikhailova E A, Li M H, Chen Y, Yu K Y and Liu J. 2021. Automated tree-crown and height detection in a young forest plantation using mask region-based convolutional neural network (Mask R-CNN). *ISPRS Journal of Photogrammetry and Remote Sensing*, 178: 112-123 [DOI: 10.1016/j.isprsjprs.2021.06.003]
- He C, Zhang S Y and Yao S R. 2014. Forest fires locating technology based on rotor UAV. *Bulletin of Surveying and Mapping*, (12): 24-27 (何诚, 张思玉, 姚树人. 2014. 旋翼无人机林火点定位技术研究. *测绘通报*, (12): 24-27) [DOI: 10.13474/j.cnki.11-2246.2014.0389]
- He K M, Zhang X Y, Ren S Q and Sun J. 2016. Deep residual learning for image recognition//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE: 770-778 [DOI: 10.1109/CVPR.2016.90]
- Huang H Y, Ma X H, Hu L L, Huang Y H and Huang H H. 2021. The preliminary application of the combination of Fast R-CNN deep learning and UAV remote sensing in the monitoring of pine wilt disease. *Journal of Environmental Entomology*, 43(5): 1295-1303 (黄华毅, 马晓航, 扈丽丽, 黄咏槐, 黄焕华. 2021. Fast R-CNN深度学习和无人机遥感相结合在松材线虫病监测中的初步应用研究. *环境昆虫学报*, 43(5): 1295-1303) [DOI: 10.3969/j.issn.1674-0858.2021.05.26]
- Iverson L R, Perera A H, Pastur G M and Peterson U. 2018. Ecosystem services from forest landscapes: where we are and where we go//Perera A H, Peterson U, Martínez Pastur G and Iverson L R, eds. *Ecosystem Services from Forest Landscapes*. Cham: Springer: 249-258 [DOI: 10.1007/978-3-319-74515-2_9]
- Jia L, Zheng K, Tang P and Huo L Z. 2022. Topographic correction effect on classification accuracy for deep neural network classifier—A case study of the U-Net model. *National Remote Sensing Bulletin*, 26(4): 698-710 (贾莉, 郑柯, 唐嫔, 霍连志. 2022. 地形校正对U-Net深度神经网络分类器分类精度的影响. *遥感学报*, 26(4): 698-710) [DOI: 10.11834/jrs.20229322]
- Kattenborn T, Leitloff J, Schiefer F and Hinz S. 2021. Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 173: 24-49 [DOI: 10.1016/j.isprsjprs.2020.12.010]
- Liao L L, Zhou L, Wang S Q and Wang X Q. 2016. Carbon sequestration potential of biomass carbon pool for new afforestation in China during 2005-2013. *Acta Geographica Sinica*, 71(11): 1939-1947 (廖亮林, 周蕾, 王绍强, 汪小钦. 2016. 2005-2013年中国新增造林植被生物量碳库固碳潜力分析. *地理学报*, 71(11): 1939-1947) [DOI: 10.11821/dlxb201611006]
- Liao X H, Xiao Q and Zhang H. 2019. UAV remote sensing: popularization and expand application development trend. *Journal of Remote Sensing*, 23(6): 1046-1052 (廖小罕, 肖青, 张颢. 2019. 无人机遥感: 大众化与拓展应用发展趋势. *遥感学报*, 23(6): 1046-1052) [DOI: 10.11834/jrs.20199422]
- Liao X H, Zhou C H, Su F Z, Lu H Y, Yue H Y and Gou J P. 2016. The mass innovation era of UAV remote sensing. *Journal of Geo-Infor-*

- mation Science, 18(11): 1439-1447 (廖小罕, 周成虎, 苏奋振, 卢海英, 岳焕印, 缙吉平. 2016. 无人机遥感众创时代. 地球信息科学学报, 18(11): 1439-1447) [DOI: 10.3724/SP.J.1047.2016.01439]
- Lin Z W, Ding Q L, Huang J H, Tu W H, Hu D and Liu J F. 2019. Study on tree species classification of UAV optical image based on DenseNet. Remote Sensing Technology and Application, 34(4): 704-711 (林志玮, 丁启禄, 黄嘉航, 涂伟豪, 胡典, 刘金福. 2019. 基于 DenseNet 的无人机光学图像树种分类研究. 遥感技术与应用, 34(4): 704-711) [DOI: 10.11873/j.issn.1004-0323.2019.4.0704]
- Liu Q, Wu Y and He H. 2001. Ecological problems of subalpine coniferous forest in the southwest of China. World Sci-Tech R and D, 23(2): 63-69 (刘庆, 吴彦, 何海. 2001. 中国西南亚高山针叶林的生态学问题. 世界科技研究与发展, 23(2): 63-69) [DOI: 10.3969/j.issn.1006-6055.2001.02.016]
- Liu Q W, Li S M, Li Z Y, Fu L Y and Hu K L. 2017. Review on the applications of UAV-Based LiDAR and photogrammetry in forestry. Scientia Silvae Sinicae, 53(7): 134-148 (刘清旺, 李世明, 李增元, 符利勇, 胡凯龙. 2017. 无人机激光雷达与摄影测量林业应用研究进展. 林业科学, 53(7): 134-148) [DOI: 10.11707/j.1001-7488.20170714]
- Maes W H and Steppe K. 2019. Perspectives for remote sensing with unmanned aerial vehicles in precision agriculture. Trends in Plant Science, 24(2): 152-164 [DOI: 10.1016/j.tplants.2018.11.007]
- Natesan S, Armenakis C and Vepakomma U. 2019. Resnet-based tree species classification using uav images. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLII-2-W13: 475-481 [DOI: 10.5194/isprs-archives-XLII-2-W13-475-2019]
- Pajares G. 2015. Overview and current status of remote sensing applications based on unmanned aerial vehicles (UAVs). Photogrammetric Engineering and Remote Sensing, 81(4): 281-330 [DOI: 10.14358/Pers.81.4.281]
- Ronneberger O, Fischer P and Brox T. 2015. U-Net: convolutional networks for biomedical image segmentation//18th International Conference on Medical Image Computing and Computer-Assisted Intervention. Munich: Springer: 234-241 [DOI: 10.1007/978-3-319-24574-4_28]
- Schiefer F, Kattenborn T, Frick A, Frey J, Schall P, Koch B and Schmidtlein S. 2020. Mapping forest tree species in high resolution UAV-based RGB-imagery by means of convolutional neural networks. ISPRS Journal of Photogrammetry and Remote Sensing, 170: 205-215 [DOI: 10.1016/j.isprsjprs.2020.10.015]
- Trier Ø D, Salberg A B, Kermit M, Rudjord Ø, Gobakken T, Næsset E and Aarsten D. 2018. Tree species classification in Norway from airborne hyperspectral and airborne laser scanning data. European Journal of Remote Sensing, 51(1): 336-351 [DOI: 10.1080/22797254.2018.1434424]
- Wang J, Zhang C, Chen Q, Li H Y, Peng X, Bai M X, Xu Z Y, Liu H D and Chen Y F. 2022. The method of extracting information of cunninghamia lanceolata crown combined with RGB and LiDAR based on UAV. Journal of Southwest Forestry University (Natural Sciences), 42(1): 133-141 (王娟, 张超, 陈巧, 李华玉, 彭希, 白明雄, 徐志扬, 刘浩栋, 陈永富. 2022. 结合无人机可见光和激光雷达数据的杉木树冠信息提取. 西南林业大学学报(自然科学), 42(1): 133-141) [DOI: 10.11929/j.swfu.202101013]
- Wang X Q, Wang M M, Wang S Q and Wu Y D. 2015. Extraction of vegetation information from visible unmanned aerial vehicle images. Transactions of the Chinese Society of Agricultural Engineering, 31(5): 152-159 (汪小钦, 王苗苗, 王绍强, 吴云东. 2015. 基于可见光波段无人机遥感的植被信息提取. 农业工程学报, 31(5): 152-159) [DOI: 10.3969/j.issn.1002-6819.2015.05.022]
- Wang Y, He C, Liu B L and Li S S. 2022. Single wood parameters extraction and DBH model construction based on UAV tilt photography technology. Journal of Southwest Forestry University, 42(1): 166-173 (王越, 何诚, 刘柏良, 李双双. 2022. 基于无人机倾斜摄影技术的单木参数提取及胸径模型构建. 西南林业大学学报, 42(1): 166-173) [DOI: 10.11929/j.swfu.202009047]
- Xu Y, Zhang C L, Jiang R J, Wang Z F, Zhu M C and Shen G C. 2021. UAV-based hyperspectral images and monitoring of canopy tree diversity. Biodiversity Science, 29(5): 647-660 [DOI: 10.17520/biods.2021013]
- Zhang B, Zhao L and Zhang X L. 2020a. Three-dimensional convolutional neural network model for tree species classification using airborne hyperspectral images. Remote Sensing of Environment, 247: 111938 [DOI: 10.1016/j.rse.2020.111938]
- Zhang C, Atkinson P M, George C, Wen Z F, Diazgranados M and Gerard F. 2020b. Identifying and mapping individual plants in a highly diverse high-elevation ecosystem using UAV imagery and deep learning. ISPRS Journal of Photogrammetry and Remote Sensing, 169: 280-291 [DOI: 10.1016/j.isprsjprs.2020.09.025]
- Zhang C, Xia K, Feng H L, Yang Y H and Du X C. 2021. Tree species classification using deep learning and RGB optical images obtained by an unmanned aerial vehicle. Journal of Forestry Research, 32(5): 1879-1888 [DOI: 10.1007/s11676-020-01245-0]
- Zheng J P, Fu H H, Li W J, Wu W Z, Yu L, Yuan S, Tao W Y W, Pang T K and Kanniah K D. 2021. Growing status observation for oil palm trees using Unmanned Aerial Vehicle (UAV) images. ISPRS Journal of Photogrammetry and Remote Sensing, 173: 95-121 [DOI: 10.1016/j.isprsjprs.2021.01.008]
- Zhu W Z, Sheng Z L, Shu S M, Wang W W and Li X. 2021. Comprehensive evaluation of ecological function restoration of the natural secondary forests in a subalpine region of western Sichuan. Chinese Journal of Applied and Environmental Biology, 27(3): 694-704 (朱万泽, 盛哲良, 舒树森, 王文武, 李霞. 2021. 川西高山天然次生林生态功能恢复综合评价. 应用与环境生物学报, 27(3): 694-704) [DOI: 10.19675/j.cnki.1006-687x.2021.02029]

Effects of image input size and resolution by CNN on the classification accuracy for coniferous forest vegetation in western Sichuan

SHI Weibo¹, LIAO Xiaohan^{2,3,4}, WANG Shaoqiang^{1,5,6}, YUE Huanyin^{2,3,4}, WANG Dongliang^{2,3}

1. China University of Geosciences (Wuhan), School of Geography and Information Engineering, Laboratory of Regional Ecological Processes and Environmental Evolution, Wuhan 430074, China;

2. Institute of Geographic Sciences and Natural Resources Research, Chinese Academy of Sciences, State Key Laboratory of Resources and Environmental Information System, Beijing 100101, China;

3. Research Center for UAV Applications and regulation, Chinese Academy of Sciences, Beijing 100101, China;

4. Key Laboratory of Low Altitude Geographic Information and Air Route, Civil Aviation Administration of China, Beijing 100101, China;

5. Institute of Geographic Sciences and Natural Resources Research, Chinese Academy of Sciences, Key Laboratory of Ecosystem Network Observation and Modeling, Beijing 100101, China;

6. University of Chinese Academy of Sciences, College of Resources and Environment, Beijing 100049, China

Abstract: The subalpine coniferous forest in west Sichuan is located in southwest China, which is affected by cloudy, rainy, and foggy conditions. Thus, conducting vegetation classification in the area by using satellite images is difficult. (Objective) Therefore, this work selects Wanglang Nature Reserve, which is a typical area of subalpine coniferous forest in western Sichuan, as the study area. A multi-rotor UAV is used to acquire high-resolution RGB images of the northern part of the study area, and it is combined with a convolutional neural network model for vegetation classification. (Method) This study selects the semantic segmentation method (U-Net) for classification, constructs vegetation classification models based on UAV images of different spatial resolutions and sample sets under different tile sizes, and establishes a forest fingerprint library to further explore the potential of convolutional neural networks on UAV remote sensing images. (Result) (1) The combination of UAV visible images and convolutional neural network model for classification can obtain classification results of high accuracy, which reached the optimum at a spatial resolution of 5 cm and a size of 256×256. The overall accuracy was 93.21%, and the kappa coefficient was 0.90. (2) The increase in ultrahigh spatial resolution had limited improvement on the model accuracy. When the spatial resolution was increased from 10 cm to 5 cm, the overall accuracy of the model improved by 0.02 and the Kappa coefficient improved by 0.03, and the classification accuracy of the model did not improve significantly. (3) Choosing the appropriate size can improve the classification accuracy of the model. Under the spatial resolution of 5 cm, the overall accuracy of the model with the size of 128×128 was 82.30% and the kappa coefficient was 0.76, and the overall accuracy of the model with the size of 256×256 was 93.21% and the kappa coefficient was 0.90. (4) For the vegetation types that were underrepresented in the region, the influence of spatial resolution and tile size was much higher than that of the dominant tree species, especially the influence of spatial resolution was the highest. The producer and user accuracies for deciduous shrubs at a spatial resolution of 20 cm were below 70%. (Conclusion) This study shows that vegetation classification of subalpine coniferous forests in western Sichuan using UAV high-resolution RGB images combined with convolutional neural networks can achieve high-precision classification results. The effects of UAV spatial resolution and tile sizes on the accuracy of convolutional neural network models are explored, which further details the potential of convolutional neural networks on UAV high-resolution RGB images to provide an automatic and accurate research method for vegetation classification in this region.

Key words: UAV RGB imagery, Convolutional Neural Network(CNN), subalpine coniferous forest in western Sichuan, vegetation classification, tile size, spatial resolution

Supported by Strategic Priority Research Program of Chinese Academy of Sciences (No. XDA19050501); Scientific Research Foundation of China University of Geosciences (No. 162301192642)