

doi:10.6041/j.issn.1000-1298.2022.03.020

# LiDAR 单木分割辅助的无人机影像 CNN + EL 树种识别

徐志扬<sup>1,2</sup> 陈 巧<sup>1,3</sup> 陈永富<sup>1,3</sup>

(1. 中国林业科学研究院资源信息研究所, 北京 100091; 2. 国家林业和草原局华东调查规划院, 杭州 310019;

3. 国家林业和草原局林业遥感与信息技术重点实验室, 北京 100091)

**摘要:** 为研究激光雷达单木分割辅助条件下无人机可见光图像树种识别应用潜力, 提出联合卷积神经网络(CNN)和集成学习(EL)的树种识别方法。首先利用同期无人机激光雷达数据和可见光影像数据进行单木树冠探测并制作单木树冠影像数据集; 其次引入 ResNet50 网络并结合引入有效通道注意力机制、替换膨胀卷积、调整卷积模块层数搭建出 4 个卷积神经网络, 使用 ImageNet 大型数据集进行模型预训练, 加载预训练参数进行模型初始化并利用制作的单木树冠影像数据集训练出 5 个不同的分类模型; 最后通过相对多数投票法建立集成模型。实验结果表明, 单木探测总体精度达到 83.80%, 集成学习的训练精度、验证精度、独立测试精度分别达到了 99.15%、98.34% 和 90.15%, 较 ResNet50 网络提高了 4.23、3.04、9.09 个百分点, 独立测试精度较随机森林分类最优结果高 32.31 个百分点。激光雷达单木分割辅助条件下利用卷积神经网络和集成学习策略能够充分提取无人机图像特征用于树种识别。

**关键词:** 树种识别; 无人机影像; 无人机激光雷达; 卷积神经网络; 集成学习

中图分类号: S771

文献标识码: A

文章编号: 1000-1298(2022)03-0197-09

OSID: 

## Tree Species Recognition Based on Unmanned Aerial Vehicle Image with LiDAR Individual Tree Segmentation Aided

XU Zhiyang<sup>1,2</sup> CHEN Qiao<sup>1,3</sup> CHEN Yongfu<sup>1,3</sup>(1. Research Institute of Forest Resource Information Techniques, Chinese Academy of Forestry, Beijing 100091, China  
2. East China Inventory and Planning Institute, National Forestry and Grassland Administration, Hangzhou 310019, China3. Key Laboratory of Forestry Remote Sensing and Information System,  
National Forestry and Grassland Administration, Beijing 100091, China)

**Abstract:** In order to study the application potential of tree species recognition based on unmanned aerial vehicle (UAV) visible image with LiDAR individual tree segmentation aided, a tree species recognition method combined with convolutional neural network and ensemble learning was proposed. Firstly, individual trees were detected by means of individual tree segmentation of simultaneous UAV – LiDAR point clouds and multiscale segmentation of UAV visible image, and then individual tree canopy image datasets was sliced from UAV visible image. Secondly, ResNet50 convolutional neural network was introduced, meanwhile, a ECA – ResNet50 network was built by using ResNet50 as the backbone network framework and inserting the effective channel attention (ECA) mechanism model to residual bottleneck module, and then a ECA – ResNet50 – Dialate network was built by replacing normal  $3 \times 3$  convolution of residual module with dilated convolution, and ECA – ResNet – mini and ECA – ResNet – mini – Dialate network were built by adjusting the convolution layer number of convolutional modules in the end. The pre-trained model parameters, which were pre-trained by using ImageNet datasets, were loaded to initialize the five network models, after that five recognition models were trained by using the individual tree canopy image datasets. Finally, the five convolutional neural network models were ensembled by the relative majority voting method. The experimental results showed that the overall accuracy of individual tree detection was 83.80%, and the training, verification and independent test

收稿日期: 2021-10-10 修回日期: 2021-12-07

基金项目: 中央级公益性科研院所基本科研业务费专项资金项目(CAFYBB2018SZ008)

作者简介: 徐志扬(1981—), 男, 博士生, 国家林业和草原局华东调查规划院高级工程师, 主要从事林业信息技术研究, E-mail: xzy483@163.com

通信作者: 陈巧(1977—), 女, 副研究员, 博士, 主要从事林业遥感与森林三维可视化研究, E-mail: Chengqiqo@163.com

accuracy of ensemble learning reached 99.15%, 98.34% and 90.15%, respectively, which were 4.23, 3.04 and 9.09 percentage points higher than that of ResNet50 network, and the independent test accuracy was still 32.31 percentage points higher than the traditional optimal result of random forest classification. The combination of convolutional neural network and ensemble learning strategy could fully extract UAV visible image features for tree species recognition with LiDAR individual tree segmentation aided.

**Key words:** tree species recognition; unmanned aerial vehicle image; UAV-LiDAR; convolutional neural network; ensemble learning

## 0 引言

树种分类识别是森林资源经营管理、生物多样性监测评价的重要工作基础。采用遥感手段进行区域尺度的树种分类与制图一直是树种分类识别的热门研究内容<sup>[1-2]</sup>,它通常以航空或航天遥感获得的多光谱、高光谱以及激光雷达(Light detection and ranging,LiDAR)为数据源,使用单一数据源或者他们的各种组合变量及纹理特征<sup>[3-5]</sup>,再用机器学习方法如支持向量机(Support vector machine,SVM)、随机森林(Random forest,RF)等建立分类模型以完成树种分类识别<sup>[6-7]</sup>,这为宏观尺度的树种信息获取提供了重要方法,但是该类遥感数据易受气溶胶等影响和数据获取周期束缚,难以满足森林经营单位级的小范围、高精度、高时效性森林信息获取需求。无人机(Unmanned aerial vehicle,UAV)因其小巧灵活且能够在云下低空飞行,为森林经营单位级森林信息获取提供了一个重要解决方案。通过在无人机上搭载多光谱设备、数码相机或者激光雷达扫描仪,可以及时获得超高分辨率遥感数据,一些学者提取其光谱(或波段值)以及植被指数、纹理特征、树冠三维结构特征并结合机器学习方法进行了树种信息提取研究<sup>[8-9]</sup>,特征变量提取过程复杂,提取精度也较为有限。

近年来,深度学习尤其是卷积神经网络(Convolutional neural network,CNN)因其优秀的层次化特征自动提取能力和较高的识别精度使得其在树种分类识别中也得以应用。卷积神经网络如VGG、GoogLeNet等随着网络层数加深易出现资源消耗大、模型过拟合、梯度消失与爆炸等问题,HE等<sup>[10]</sup>提出的残差网络(Residual network,ResNet)较好地解决了卷积神经网络模型梯度爆炸和网络退化问题,研究表明它成为了一种分类效果较好的卷积神经网络模型<sup>[11-13]</sup>。ResNet50模型是残差网络中一个较为成功的模型,然而,小样本数据集下单个网络模型训练精度和泛化能力难以充分保障,而集成学习策略为模型精度和泛化能力改善提供了可能性<sup>[7,14-18]</sup>,较多实践证明了集成学习模型优于单个分类模型。

为了有效提取卷积神经网络特征信息和充分发挥集成学习模型优势以提高分类精度,引入ResNet50卷积神经网络用于树种分类识别,拟将有效通道注意力机制(Efficient channel attention,ECA)融入ResNet50网络的瓶颈模块,搭建改进的ECA-ResNet50网络,同时以膨胀卷积代替ECA-ResNet50网络瓶颈模块 $3 \times 3$ 正常卷积,搭建改进的ECA-ResNet50-Dialate网络,然后以ResNet50为主干架构,将ECA-ResNet50、ECA-ResNet50-Dialate的卷积模块配置(3,4,6,3)修改为(3,3,3,3),搭建ECA-ResNet-mini、ECA-ResNet-mini-Dialate 2个网络,最后以ResNet50网络和搭建的4个卷积神经网络为基分类器,采用相对多数投票法建立集成学习模型。

虽然一些学者进行了无人机遥感数据树种分类识别的相关研究<sup>[8-9,12]</sup>,但大多存在研究对象相对简单、分类精度不高的缺陷,或者仅停留在林分尺度,而截至目前应用无人机遥感数据进行高郁闭度林分内单木树种的高精度识别研究并不多见。为了研究高郁闭度条件下无人机多源遥感数据协同用于树种分类识别能力,本文拟以亚热带乔木林为研究对象,基于同期获取的无人机激光雷达数据和可见光图像提取研究区单木树冠,为便于卷积神经网络有效提取树冠局部与全局特征,以略大于完整单株树冠的窗口尺寸96像素×96像素提取研究区5类乔木林分主要树种:杉木(*Cunninghamia lanceolata*)、马尾松(*Pinus massoniana*)、桤木(*Alnus cremastogyne*)、鹅掌楸(*Liriodendron chinense*)、其他阔叶树(other broad-leaves)的单木树冠可见光影像集,利用提出的卷积神经网络和集成学习模型进行树种分类识别模型训练和独立测试,以期为综合利用无人机多源遥感进行较为复杂的高郁闭度林分树种识别提供参考。

## 1 材料与方法

### 1.1 研究区概况与数据来源

#### 1.1.1 研究区概况

研究区位于江西省分宜县内中国林业科学研究院亚热带林业实验中心年珠实验林场(27°30'~

27°45'N, 114°30' ~ 114°45'E), 地貌属低山丘陵, 海拔 220 ~ 1 092 m, 土壤为黄红壤, 年均气温 16.8 ℃, 日最高气温 39.9 ℃, 最低气温 -8.3 ℃, 年降雨量为 1 950.9 mm, 集中在 3—6 月, 无霜期 252 d。研究区内乔木林郁闭度 0.7 以上, 主要类型为杉木林 (*Cunninghamia lanceolata*)、马尾松林 (*Pinus massoniana*)、桤木林 (*Alnus cremastogyne*)、鹅掌楸林 (*Liriodendron chinense*)、其他阔叶林 (other broad-leaves)。阔叶林中主要树种有: 樟树 (*Cinnamomum camphora*)、大叶锥栗 (*Castanea henryi*)、钩锥 (*Castanopsis tibetana*)、甜槠 (*Castanopsis eyrei*)、苦槠 (*Castanopsis sclerophylla*)、木荷 (*Schima superba*)、刨花润楠 (*Machilus pauhui*) 等。

### 1.1.2 数据来源

无人机搭载 RIEGL VUX-1LR 型激光雷达传感器通过近红外(波长 1 550 nm)激光束和旋转镜 330°视场角快速扫描实现激光雷达数据的高速获取, 搭载 Sony ILCE-6000 型微单相机采集可见光数据, 使用动态后处理 (Post processed kinematic, PPK) 定位技术实现高定位精度 15 mm, 数据采集于 2019 年 6 月底, 采用仿地飞行模式, 以地形表面为基准设置相对高度, 在 160 m 高度上采集激光雷达数据和可见光图像。

由于 2019 年开展生物量遥感估测调查的圆形样地绝大部分为杉木林, 为避免不均衡样本模型训练时产生分类偏差, 于 2020 年 7 月重新调查完成 15 个面积为 0.04 hm<sup>2</sup> 的乔木林圆形样地, 且各树种数量相对均衡, 采用实时动态 (Real-time kinematic, RTK) 载波相位差分技术定位并记录样地中心点坐标, 记录胸径 5 cm 以上树木的每木相对位置、树种、胸径、树高、枝下高、林木分级、枯死原因、东西南北向冠幅等。考虑到研究区内无明显的森林经营活动, 也无速生树种生长, 而且按照亚热带常见针叶、阔叶树种的生长速率来看, 2019 年 6 月底至 2020 年 7 月各样木的位置、树冠尺寸均无明显差异, 因此, 2020 年 7 月调查的单木样本可以与 2019 年 6 月底的无人机遥感数据匹配用于树种分类。

此外, 收集 2019 年 7 月通过无人机冠层监测到的野外 RTK 定位(精度小于 1 m)的实测单木位置、树种、胸径、树高、冠幅等数据。

## 1.2 研究方法

### 1.2.1 遥感数据预处理

利用数字绿土 LiDAR360 软件进行激光雷达点云数据预处理, 首先去噪、分类, 然后用 Kriging 法对地面点插值得到 0.5 m 的数字高程模型 (DEM), 将去噪分类后的点云高程减去对应 DEM 像元值完成点

云归一化, 利用 LASTools 开源工具对归一化后的点云生成无孔洞的冠层高度模型 (Pit-Free CHM)<sup>[19]</sup>。

可见光图像处理使用数字绿土 LiMapper 软件进行。主要处理流程包括导入图像、影像对齐、生成密集匹配点云、生成 DEM/DSM 和生成正射影像(空间分辨率 0.05 m)。

以同期、相同航高下的激光雷达生成的冠层高度模型为参考基准, 对可见光图像进行校正。

### 1.2.2 深度学习样本

#### 1.2.2.1 单木树冠分割

单木树冠分割是采用一定算法将点云或者遥感影像分割为多个部分, 每个部分被认为是一株树木。相关研究表明, 中低郁闭度林分能够采用 LiDAR 点云数据有效提取单木树冠<sup>[20~21]</sup>, 常用方法是利用 CHM 图像进行局部最大值法探测标记树顶再结合标记控制分水岭法分割单木, 而在高郁闭林分条件下, 因单木树顶难以确定且树冠重叠, 直接进行 CHM 单木分割容易导致树木过分割或欠分割。本研究将 CHM 和可见光图像二者结合, 首先通过调试优选 CHM 单木分割参数, 设置高斯平滑 sigma 参数为 0.5, 采用标记控制分水岭法提取探测的单木位置与树冠矢量图形; 然后通过对可见光图像进行 HSV 变换与颜色阈值设置、形态学开闭运算等提取树冠区域; 最后结合可见光图像、CHM 分割单株树冠矢量图形、树冠区域, 设置分割尺度、形状因子、紧致度为 80、0.8、0.9, 利用 eCognition 软件进行多尺度分割<sup>[22]</sup>, 得到分割结果, 并根据地面实测数据进行单木分割结果检验。为验证单木树冠探测精度, 利用地理信息系统 (Geographic information system, GIS) 将 CHM 和可见光图像叠加显示, 对比 LiDAR 树顶探测结果与地面样地单木位置, 参考相关研究采用探测率( $r$ )、正确率( $p$ )和总体精度( $F$ )验证精度<sup>[23]</sup>。为满足分类样本数量需求, 对过分割或欠分割树冠进行手动调整。

#### 1.2.2.2 样本库构建

深度学习需要大量带标签的训练数据样本支持, 以避免因模型过于复杂而数据量太少出现过拟合的问题。以 2020 年调查的 10 个圆形样地和 2019 年 RTK 实测定位的单木数据为训练集(总数 1 550 个, 其中杉木 404 个, 马尾松 344 个, 桤木 105 个, 鹅掌楸 319 个, 其他阔叶树 378 个), 以 2020 年调查的其余 5 个圆形样地为独立测试集(总数 132 个, 其中杉木 47 个, 马尾松 17 个, 桤木 29 个, 鹅掌楸 17 个, 其他阔叶树 22 个)。卷积神经网络需要输入规则图像, 本文基于单木树冠分割结果, 以树顶为中心、按照 96 像素 × 96 像素制作正方形矢量框, 裁切可

见光图像得到规则的单株树冠影像块,以树种名称和探测单木树顶编号组合区别命名并制作单木树冠影像数据集。

### 1.2.2.3 数据集划分与数据增广

将训练集的1550个单木树冠影像块分5个树种按照7:3随机划分为训练数据(总数1082个,其中杉木282个,马尾松240个,桤木73个,鹅掌楸223个,其他阔叶树264个)和验证数据(总数468个,其中杉木122个,马尾松104个,桤木32个,鹅掌楸96个,其他阔叶树114个),再对训练数据的单木树种遥感影像进行90°旋转、180°旋转、270°旋转、上下翻转、左右翻转等操作使得各树种样本数量变为原来的6倍。

单木树冠图像生成与数据集划分、数据增广均通过编写Python脚本实现批处理。

### 1.2.3 卷积神经网络

#### 1.2.3.1 相关理论

##### (1) 有效通道注意力机制

相关研究表明通道注意力机制在提升卷积神经网络性能方面具有较大潜力,它将特征提取时所有通道同等对待转为分别赋予不同权重,大多数现有方法在致力于复杂注意力模块以改善模型性能的同时也带来了模型复杂性的增加,而有效通道注意力(Efficient channel attention, ECA)则在仅增加少量模型参数条件下还能够提升模型性能,既避免了挤压和激励网络(SENet)的维度缩减,又有效捕获了跨通道交互<sup>[24]</sup>。有效通道注意力机制核心工作原理是在不降低维度情况下逐通道平均池化后ECA模块利用权重共享、尺寸为k的一维卷积生成通道注意来学习特征,并考虑每个通道及其k个邻近来捕获本地跨通道交互。

##### (2) 扩张卷积

随着卷积神经网络中网络深度增加,下采样会逐渐降低特征图的空间分辨率造成信息丢失。为减少该不利影响,充分提取图像全局信息,本文在网络卷积层引入空洞卷积(Atrous convolutions)<sup>[25]</sup>,尝试以空洞卷积代替普通卷积,以实现在不增加算法复杂度的条件下增大卷积感受野,从而提高网络捕捉特征信息的能力<sup>[26]</sup>。

##### (3) 瓶颈残差学习

瓶颈残差学习模块的基本单元如图1所示,图中⊕表示逐像素相加,基本单元由三次级联的卷积批规范化、激活组成,它在原始卷积神经网络上增加近路连接,使原始输入能够传输到网络顶层,从而使 $\varphi(x)$ 的网络学习任务变为输入输出间的 $F(x)$ 残差学习。而反向传播时,通过近路连接可直接将网络

顶层信息传输到底层,能够有效缓解梯度消失与网络退化问题。

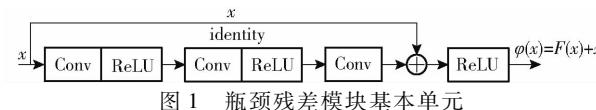


图1 瓶颈残差模块基本单元

Fig. 1 Basic unit of bottleneck residual block

#### 1.2.3.2 网络框架结构

鉴于残差神经网络具有改善梯度消失和网络退化的能力,本研究引入采用瓶颈残差单元搭建的ResNet50卷积神经网络模型,保留ReLU激活函数和softmax函数分类,并以ResNet50为主干网络,通过在瓶颈残差模块基本单元的第3个卷积批规范化后插入有效通道注意力模块(图2)搭建新的卷积神经网络ECA-ResNet50,再对瓶颈残差模块基本单元的第2个卷积操作(正常卷积)替换为膨胀率为2的扩张卷积以搭建卷积神经网络ECA-ResNet50-Dilate,然后对ECA-ResNet50和ECA-ResNet50-Dilate的4个卷积模块的瓶颈残差单元数(3,4,6,3)分别调整为(3,3,3,3)以构建ECA-ResNet-mini和ECA-ResNet-mini-Dilate卷积神经网络模型,ResNet50及搭建的4个卷积神经网络框架结构配置见表1。为方便表述,将ResNet50、ECA-ResNet50、ECA-ResNet50-Dilate、ECA-ResNet-mini、ECA-ResNet-mini-Dilate依次称为Model I、Model II、Model III、Model IV和Model V。

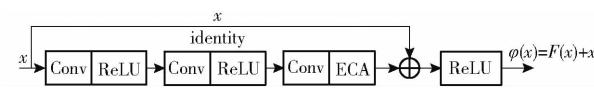


图2 瓶颈残差有效通道注意力基本单元

Fig. 2 Basic unit of bottleneck residual ECA block

#### 1.2.4 集成学习树种识别框架

集成学习(Ensemble learning, EL)一般用某种策略将训练所得的“个体学习器”结合,如果个体学习器是同种类型,此时个体学习器可以称为基学习器<sup>[15-16]</sup>。集成学习通过多个基分类器以集成方式完成学习任务,能够实现分类器之间的优势互补,从而获得比单一分类器更为显著优越的泛化性能。本文提出的基于卷积神经网络的集成学习树种识别框架如图3所示,通过Model I、Model II、Model III、Model IV和Model V这5种CNN模型的训练学习提取树冠图像特征进行树种初分类,将它们作为基分类器,然后通过相对多数投票法建立集成学习模型。

#### 1.2.5 卷积神经网络模型训练与测试

(1) 预训练参数: Model I 使用大型数据集ImageNet预训练的模型参数, Model II、Model III、Model IV 和 Model V 通过重新训练大型数据集产生预训练模型参数。

表1 卷积神经网络框架的结构配置

Tab. 1 Parameters configuration of convolutional neural network frameworks

网络层	瓶颈残差模块单元	Model I	Model II	Model III		Model IV	Model V	
Conv1				$7 \times 7, 64$ stride 为 2				
				$3 \times 3$ max pool, stride 为 2				
	$1 \times 1, 64$							
Conv2_x	$3 \times 3, 64$	$\times 3$	$\times 3$	$\times 3$	dilation 为 2	$\times 3$	$\times 3$	dilation 为 2
	$1 \times 1, 256$			ECA	ECA	ECA	ECA	ECA
	$1 \times 1, 128$							
Conv3_x	$3 \times 3, 128$	$\times 4$	$\times 4$	$\times 4$	dilation 为 2	$\times 3$	$\times 3$	dilation 为 2
	$1 \times 1, 512$			ECA	ECA	ECA	ECA	ECA
	$1 \times 1, 256$							
Conv4_x	$3 \times 3, 256$	$\times 6$	$\times 6$	$\times 6$	dilation 为 2	$\times 3$	$\times 3$	dilation 为 2
	$1 \times 1, 1024$			ECA	ECA	ECA	ECA	ECA
	$1 \times 1, 512$							
Conv5_x	$3 \times 3, 512$	$\times 3$	$\times 3$	$\times 3$	dilation 为 2	$\times 3$	$\times 3$	dilation 为 2
	$1 \times 1, 2048$			ECA	ECA	ECA	ECA	ECA
output				average pool, fc, softmax				

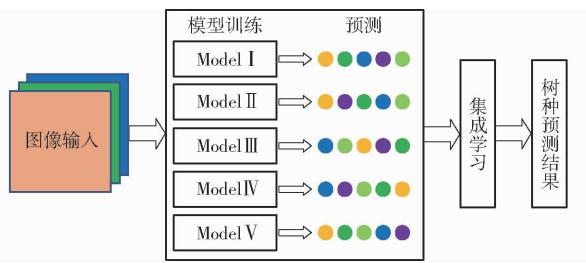


图3 集成学习框架结构

Fig. 3 Structure of ensembled learning model

(2) 模型训练: 基于 Python 编程语言和 PyTorch 深度学习框架, 使用 GPU 加速模型训练。通过加载预训练参数作为网络初始化参数, 设置批量大小为 32, 将扩充后的本研究树冠图像训练数据分别输入 5 个卷积神经网络模型, 调整网络输出类别数为树种类别数 5, 同时修改网络输入图像为 224, 通过多次迭代循环训练模型参数, 每次迭代后向网络模型输入验证数据检验模型拟合效果, 当验证数据连续多次迭代损失函数不再显著降低且迭代 50 次以上时, 保存模型参数并中断迭代训练。模型训练时, 使用交叉熵损失函数计算损失值 (loss), 尝试不同学习率参数 (0.01、0.001、0.0001) 分别调优训练出 5 个不同最优模型。

训练过程中, 分别采用随机梯度下降法 (Stochastic gradient descent, SGD) 和自适应矩估计 (Adaptive moment estimation, Adam) 进行模型训练, 使用 SGD 优化时设置动量为 0.9、学习率衰减值 0.01 以优化性能, 实验表明, 虽然 Adam 优化器收敛较快, 但结果不如 SGD 优化器理想, 因此, 使用 SGD 优化算法更新网络权重参数。

(3) 模型测试: 模型训练结束后, 输入独立的测

试集数据进行测试, 根据网络模型预测识别结果, 通过一定指标进行评估分析。

## 2 实验结果分析

### 2.1 单木分割

对 2020 年调查样地的样木和 2019 年高精度定位的样木进行单木树冠分割。利用 2020 年调查的 15 个圆形样地对单木分割结果进行精度评价。15 个圆形样地共调查 473 株样木, 剔除掉濒死木、枯死木和树冠被大树遮挡的小树后共有 399 株树木, 共分割出树冠 391 个, 1:1 正确分割的树冠 331 个, 漏检 66 株, 过分割 60 株, 单木探测率  $r$  达到 82.96%, 正确率  $p$  达到 84.65%, 总体精度  $F$  达到 83.80%, 总体来看分割精度能满足树种识别要求。

与皋厦等<sup>[23]</sup>采用点云距离判断单木分割法进行 LiDAR 单木分割 (探测率 85.7%, 正确率 96.0%, 总体精度 90.9%) 相比, 本文结果要低, 这与研究对象林分特征直接相关, 皋厦等研究林分相对不太复杂, 而本研究区内亚热带阔叶树树冠彼此交叉相连、多株树木相邻且高度不一以及杉木多株簇生等对单木分割结果均会造成很大影响。

### 2.2 树种识别分析

#### 2.2.1 卷积神经网络模型集成前后对比

使用 Model I、II、III、IV、V 这 5 种卷积神经网络模型分别在单木树冠影像数据集进行模型训练, 加载大型数据集上预训练的模型权重和偏置参数对卷积层参数初始化, 采用不同初始学习率 (0.01、0.001、0.0001) 进行模型训练, 训练结束后用独立测试集对模型进行测试检验。实验表明初始学习率设置为 0.001 较为合理, 结果如表 2 所示。由表 2

可知,5种网络模型训练时均取得了理想效果,训练、验证正确率均达到95%以上。Model II、III、IV、V较改进前的Model I均有一定提升,这表明了Model II加入有效通道注意力模块使得模型关注于各树种最具辨别力特征的能力增强,Model III用扩

张卷积代替普通卷积使得卷积网络特征图分辨率不变而感受野扩大,提取到了树冠图像深层次全局语义特征,Model IV、V对Model II、III卷积模块结构进行调整也取得了相当的效果,显示出该网络层数配置适用于本研究树冠图像识别。

表2 卷积神经网络模型训练、验证与独立测试结果

Tab. 2 Results of convolutional neural networks model training and validating and independent test

模型	模型训练			验证			独立测试	
	正确率/%	Kappa系数	损失值	正确率/%	Kappa系数	损失值	正确率/%	Kappa系数
I	94.92	0.9284	0.1230	95.30	0.9490	0.1723	81.06	0.7496
II	97.04	0.9619	0.1065	95.72	0.9535	0.1577	85.61	0.8120
III	96.46	0.9461	0.1381	95.94	0.9565	0.1481	84.09	0.7903
IV	96.95	0.9619	0.1122	96.79	0.9590	0.1653	84.09	0.7903
V	96.58	0.9560	0.1195	95.73	0.9490	0.1553	83.33	0.7831
Ensemble learning	99.15	0.9890		98.34	0.9762		90.15	0.8712

图4、5表示模型训练过程中正确率、损失值的变化情况,损失值随模型不断迭代呈下降趋势,直至验证数据损失值在随后50轮迭代循环中收敛而不再下降后结束循环训练。由图5模型训练损失值下降情况可以看出,Model I经典网络模型训练能够很快收敛,Model II、III收敛时间略长,Model IV、V收敛时间更长,这与预训练模型参数有关,经典网络模型的预训练模型参数更加通用,适用于各种数据集的加载训练,能够快速收敛并保持稳定。但是,Model II、III、IV、V模型训练收敛后也较为稳定。此外,从图4亦可以看出,虽然Model II、III、IV、V的模型训练耗费了一些时间,但他们取得了优于

Model I经典模型的正确率,这些都为集成学习模型奠定了前提。

以本文训练的5种卷积神经网络模型作为基分类器,在单木树冠影像数据集上进行预测,再采用相对多数投票法进行集成学习输出二次预测结果,集成学习正确率见表2。比较表2的集成学习与卷积神经网络模型的训练和验证精度可发现,集成分类器训练和验证精度分别达到99.15%和98.34%,优于单独的卷积神经网络模型,较其训练、验证平均正确率分别提高2.76、2.44个百分点,较ResNet50网络提高4.23、3.04个百分点。这表明了集成学习模型能够一定程度提高模型训练正确率。

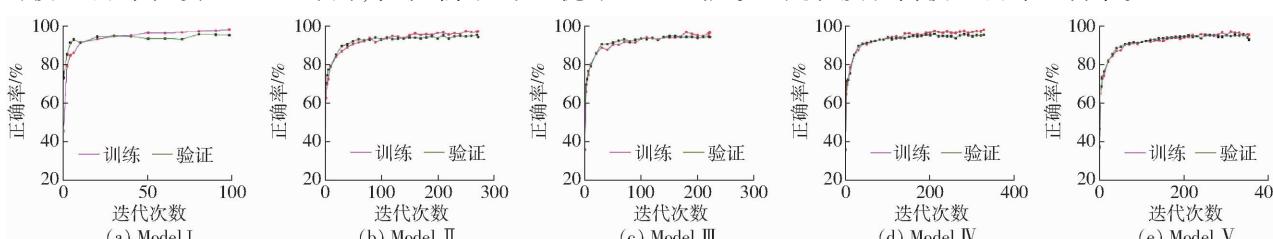


图4 不同卷积神经网络训练正确率曲线

Fig. 4 Training accuracy curves of different convolutional neural networks

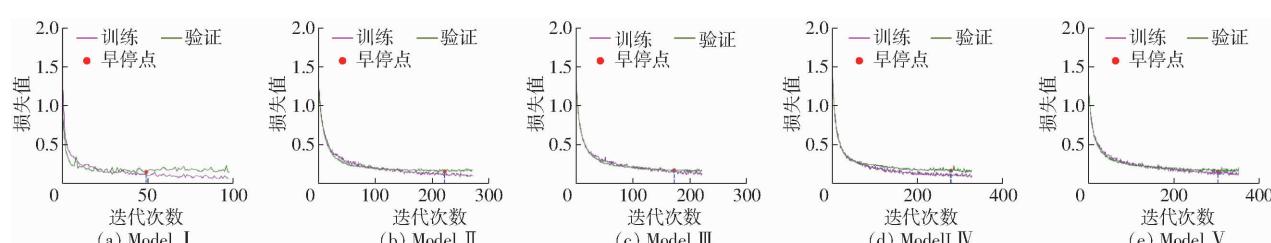


图5 不同卷积神经网络训练损失值曲线

Fig. 5 Training loss curves of different convolutional neural networks

将独立测试数据集代入卷积神经网络和集成学习框架进行树种识别,独立测试结果见表2,可见集成后测试集正确率达到90.15%,较基分类器(单独

卷积神经网络)的独立测试正确率均有明显改善,较测试正确率最高的Model II还提升4.54个百分点,较ResNet50网络提高9.09个百分点。由此可

见,采用集成策略对卷积神经网络模型预测正确率有一定提升。

将集成学习识别结果与地面实测的真实树种生成混淆矩阵,结果见表3。由表3可知,其他阔叶树、马尾松识别用户精度低,误识别较为严重,引起该现象可能原因主要有:一是研究区内其他阔叶树树种多、树冠形态、颜色与纹理复杂多样引起卷积层提取的类内高层次特征多样造成误识别;二是马尾松林林层结构复杂,垂直结构上虽然马尾松占优势但其与其他树种交错,且马尾松树冠稀疏,造成马尾松树冠影像与其他树种相似,易造成误识别。

表3 测试数据集混淆矩阵

Tab. 3 Confusion matrix of independent test dataset

识别树种	地面真实树种				
	桤木	其他阔叶树	杉木	鹅掌楸	马尾松
桤木	26	1	0	0	0
其他阔叶树	0	19	3	1	1
杉木	0	1	44	1	1
鹅掌楸	0	1	0	15	0
马尾松	3	0	0	0	15
生产者精度/%	89.66	86.36	93.62	88.24	88.24
用户精度/%	96.30	79.17	93.62	93.75	83.33

将5个独立测试圆形样地的单木树冠分割矢量结果与可见光影像叠加,结果见图6a~6e,利用单木树冠影像数据集训练出的最优模型对测试集样本进行单木识别,5个样地的识别结果见图6f~6j,分别与图6a~6e对应。其中,图6a~6e符号化的是实测的单木树种及位置,图6f~6j符号化的是预测单木树种,用蓝色方形框表示误识别的单木树冠块。不难发现,图6f中3株杉木被误识别为其他阔叶树、1株其他阔叶树被误识别为鹅掌楸,这应该与其

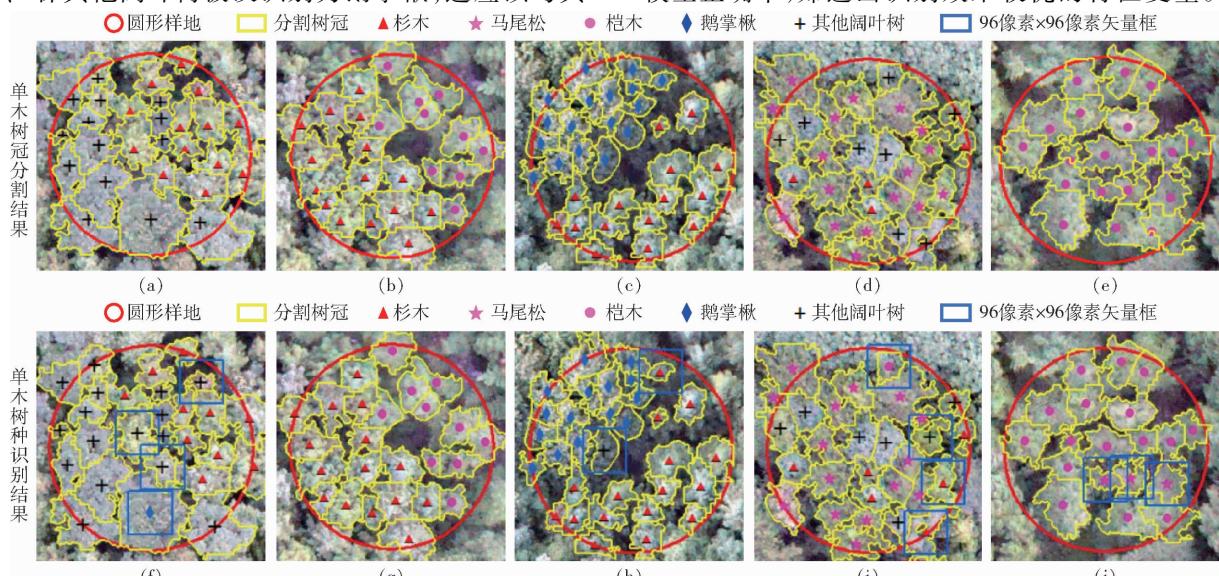


图6 5个测试圆形样地单木树冠分割与树种识别结果

Fig. 6 Results of single tree crown segmentation and single tree species recognition in five test circular samples

他阔叶树形态多样、纹理复杂易与杉木等树冠影像高层次特征相似有关,由图6h可知,2株桤木中1株被误识别为其他阔叶树、1株被误识别为杉木,而图6i中2株其他阔叶树中1株被误识别为桤木、1株被误识别为杉木,2株马尾松中1株被误识别为其他阔叶树、1株被误识别为杉木,这与该样地马尾松林内各树种混交严重、树冠交叉重叠、提取的树冠影像高层次特征复杂多样有关,图6j中3株桤木被误识别为马尾松,这可能为部分桤木树冠影像与马尾松单木树冠影像样本相似造成。总体来看,除少量单木树冠误识别外,总体识别结果基本理想。

## 2.2.2 与其他机器学习方法比较

基于单木树冠分割结果提取训练数据和测试数据的可见光和激光雷达变量,可见光变量共提取25个,包括单木树冠的各波段均值、标准差、亮度以及GLCM、GLDV纹理特征、几何特征。GLCM纹理特征包括均值、方差、信息熵、角二阶矩、相关性、异质性、对比度和同质性8个参数;GLDV纹理特征包括均值、角二阶矩、相关性、信息熵4个参数;几何特征主要提取面积、长宽比、形状指数、紧致度、密度和不对称性等特征。激光雷达变量共提取98个,包括首次回波和所有回波高度和强度的均值、最小值、最大值、标准差、方差、变异系数、峰度、偏度和分位数等。

为避免大量特征冗余引起的过拟合、低泛化问题,有必要对特征变量进行特征选择,筛选出贡献度较大的特征变量以进行树种分类识别。特征选择一般有过滤法、包装法、嵌入法3种形式,本文以嵌入法利用随机森林对特征重要性进行评估排序,计算模型正确率,筛选出识别效果较优的特征变量。特

征筛选后,可见光保留蓝光波段标准差、红光波段均值、GLCM 相关性等 13 个变量,激光雷达保留 99% 强度百分位数、75% 强度百分位数、40% 累积强度百分位数等 30 个变量,可见光和激光雷达变量结合共保留 15 个特征变量。

相关研究表明,利用优选的特征进行分类能够有效提高精度<sup>[27]</sup>。基于筛选后的特征变量,分别与不同数据源变量(可见光、LiDAR、可见光与 LiDAR 组合)、随机森林(Random forest, RF)和支持向量机(Support vector machine, SVM)分类器进行组合,以训练集训练模型,以独立的测试集对模型进行检验。各组合方案及独立测试集检验结果见表 4,可见光与激光雷达变量筛选后随机森林分类的独立测试最高精度为 57.84%。通过与表 2 比较可以发现,卷

表 4 其他模型训练组合方案与测试集检验

Tab. 4 Different combinations of other model training and test results

方案	数据源	分类器	总体精度/%	Kappa 系数
I	可见光	RF	47.06	0.3275
II	可见光	SVM	52.94	0.4660
III	LiDAR	RF	51.96	0.4496
IV	LiDAR	SVM	39.22	0.2247
V	可见光 + LiDAR	RF	57.84	0.5294
VI	可见光 + LiDAR	SVM	53.92	0.4620

注:①可见光变量特征筛选后含有:蓝光波段标准差、红光波段均值、GLCM 自相关、GLDV 均值、GLDV 熵、GLCM 反差、GLDV 反差、亮度、GLCM 均值、蓝光波段均值、红光波段标准差、GLCM 同质性、GLCM 差异性。②LiDAR 变量特征筛选后含有:99% 强度百分位数、75% 强度百分位数、40% 累积强度百分位数、60% 强度百分位数、50% 强度百分位数、20% 累积强度百分位数、60% 累积强度百分位数、高度均值、30% 高度百分位数、强度峰度、最小强度、30% 累积强度百分位数、70% 强度百分位数、25% 累积强度百分位数、密度变量 5、70% 累积强度百分位数、30% 累积强度百分位数、密度变量 9、25% 高度百分位数、10% 高度百分位数、5% 高度百分位数、10% 累积高度百分位数、50% 累积强度百分位数、25% 累积高度百分位数、40% 强度百分位数、25% 强度百分位数、高度偏斜度、强度均值、10% 累积强度百分位数、99% 累积强度百分位数。③可见光与 LiDAR 组合变量特征筛选后含有:红光波段标准差、GLCM 同质性、GLDV 熵、30% 高度百分位数、10% 高度百分位数、25% 累积高度百分位数、蓝光波段标准差、30% 累积高度百分位数、亮度、25% 高度百分位数、5% 高度百分位数、40% 累积强度百分位数、30% 累积强度百分位数、70% 累积强度百分位数、10% 累积强度百分位数。

积神经网络模型和集成学习取得了较其他机器学习方法更为明显的树种识别效果,独立测试集的总体精度高出 32.31 个百分点。由此可见,采用手动提取图像特征进行分类识别的方法难以基于实际识别任务做自适应调整,而基于卷积神经网络和集成学习的方法能够自动提取图像高层次特征,有利于高郁闭度条件下无人机影像的树种识别。

### 3 结论

(1) 提出了基于卷积神经网络和集成学习策略来解决激光雷达单木分割辅助条件下的无人机影像单木树种识别问题。利用无人机激光雷达数据和可见光数据二者结合进行单木树冠探测,按照 96 像素 × 96 像素裁切单木树冠制作单木树冠影像数据集,引入 ResNet50 网络并结合引入有效通道注意力、膨胀卷积、调整卷积模块层数改进搭建其他 4 个网络,以该 5 个卷积神经网络为基分类器采用相对多数投票法集成学习。结果表明,本文提出的方法相较于变量提取结合其他机器学习分类识别方法的正确率有较大提升,独立测试集总体正确率高出 32.31 个百分点,改进搭建的 4 个卷积神经网络模型训练正确率和泛化效果均优于 ResNet50 网络,采用集成策略进一步提高了模型训练正确率,训练和验证正确率分别达到 99.15% 和 98.34%,优于单独的卷积神经网络模型且较他们的训练、验证平均正确率分别提高 2.76、2.44 个百分点,较 ResNet50 网络提高 4.23、3.04 个百分点,树种识别泛化能力进一步增强,独立测试集正确率达到 90.15%,较最高的 Model II 还提升 4.54 个百分点,较 ResNet50 网络提高 9.09 个百分点,这些为今后无人机可见光图像树种识别研究提供了技术思路。

(2) 使用 5 个卷积神经网络模型有效增强了特征提取能力,不可避免加大了计算量,降低了分类识别速度。使用相对多数投票法进行集成学习相对简单实用,但忽视了各卷积神经网络提取图像特征的权重差异,图像识别泛化能力有待提高。因此,应合理筛选卷积神经网络特征,完善集成学习方法,进一步提高模型运行效能和泛化能力。

### 参 考 文 献

- [1] TUOMINEN S, NÄSI R, HONKAVAARA E, et al. Assessment of classifiers and remote sensing features of hyperspectral imagery and stereo-photogrammetric point clouds for recognition of tree species in a forest area of high species diversity [J]. Remote Sensing, 2018, 10(5): 714–741.
- [2] 王雅慧,陈尔学,郭颖,等.高分辨率多光谱遥感影像森林类型分类深度 U-net 优化方法[J].林业科学,2020,33(1): 11–18.
- WANG Yahui, CHEN Erxue, GUO Ying, et al. Deep U-net optimization method for forest type classification with high resolution multispectral remote sensing images[J]. Forest Research, 2020, 33(1): 11–18. (in Chinese)
- [3] FERREIRA M P, WAGNER F H, ARAGÃO L E O C, et al. Tree species classification in tropical forests using visible to shortwave infrared WorldView-3 images and texture analysis[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2019,

- 149(1):119–131.
- [4] CROSS M, SCAMBOS T, PACIFICI F, et al. Classification of tropical forest tree species using meter-scale image data [J]. *Remote Sensing*, 2019, 11(12):1411–1428.
- [5] WESSEL M, BRANDMEIER M, TIEDE D. Evaluation of different machine learning algorithms for scalable classification of tree types and tree species based on Sentinel-2 data [J]. *Remote Sensing*, 2018, 10(9):1419–1439.
- [6] BALLANTI L, BLESIUS L, HINES E, et al. Tree species classification using hyperspectral imagery: a comparison of two classifiers [J]. *Remote Sensing*, 2016, 8(6):445–462.
- [7] KUKUNDA C B, DUQUE L J, GONZÁLEZ F E, et al. Ensemble classification of individual *Pinus* crowns from multispectral satellite imagery and airborne LiDAR [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2018, 65:12–23.
- [8] SOTHE C, DALPONTE M, ALMEIDA C M, et al. Tree species classification in a highly diverse subtropical forest integrating UAV-based photogrammetric point cloud and hyperspectral data [J]. *Remote Sensing*, 2019, 11(11):1338–1361.
- [9] CAO J J, LENG W C, LIU K, et al. Object-based mangrove species classification using unmanned aerial vehicle hyperspectral images and digital surface models [J]. *Remote Sensing*, 2018, 10(2):89–108.
- [10] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016:770–778.
- [11] ZHANG C, ATKINSON P M, GEORGE C, et al. Identifying and mapping individual plants in a highly diverse high-elevation ecosystem using UAV imagery and deep learning [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2020, 169:280–291.
- [12] CAO K L, ZHANG X L. An improved res-unet model for tree species classification using airborne high-resolution images [J]. *Remote Sensing*, 2020, 12(7):1128–1144.
- [13] 徐风, 苗哲, 业巧林. 基于卷积注意力模块的端到端遥感图像分类 [J]. *林业工程学报*, 2020, 5(4):133–138.  
XU Feng, MIAO Zhe, YE Qiaolin. End-to-end remote sensing image classification framework based on convolutional block attention module [J]. *Journal of Forestry Engineering*, 2020, 5(4):133–138. (in Chinese)
- [14] 冯海林, 胡明越, 杨垠晖, 等. 基于树木整体图像和集成迁移学习的树种识别 [J]. *农业机械学报*, 2019, 50(8):235–242, 279.  
FENG Hailin, HU Mingyue, YANG Yinhui, et al. Tree species recognition based on overall tree image and ensemble of transfer learning [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2019, 50(8):235–242, 279. (in Chinese)
- [15] 袁培森, 杨承林, 宋玉红, 等. 基于 Stacking 集成学习的水稻表型组学实体分类研究 [J]. *农业机械学报*, 2019, 50(11):144–152.  
YUAN Peisen, YANG Chenglin, SONG Yuhong, et al. Classification of rice phenomics entities based on Stacking ensemble learning [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2019, 50(11):144–152. (in Chinese)
- [16] 余东行, 张保明, 赵传, 等. 联合卷积神经网络与集成学习的遥感影像场景分类 [J]. *遥感学报*, 2020, 24(6):717–727.  
YU Donghang, ZHANG Baoming, ZHAO Chuan, et al. Scene classification of remote sensing image using ensemble convolutional neural network [J]. *Journal of Remote Sensing*, 2020, 24(6):717–727. (in Chinese)
- [17] 张猛, 林辉, 龙湘仁. 采用全卷积神经网络与 Stacking 算法的湿地分类方法 [J]. *农业工程学报*, 2020, 36(24):257–264.  
ZHANG Meng, LIN Hui, LONG Xiangren. Wetland classification method using fully convolutional neural network and Stacking algorithm [J]. *Transactions of the CSAE*, 2020, 36(24):257–264. (in Chinese)
- [18] 张宏鸣, 陈丽君, 刘雯, 等. 基于 Stacking 集成学习的夏玉米覆盖度估测模型研究 [J]. *农业机械学报*, 2021, 52(7):195–202.  
ZHANG Hongming, CHEN Lijun, LIU Wen, et al. Estimation of summer corn fractional vegetation coverage based on Stacking ensemble learning [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2021, 52(7):195–202. (in Chinese)
- [19] CHEN C F, WANG Y F, LI Y Y, et al. Robust and parameter-free algorithm for constructing pit-free canopy height models [J]. *ISPRS International Journal of Geo-Information*, 2017, 6(7):219–231.
- [20] ZHAO D, PANG Y, LIU L J, et al. Individual tree classification using airborne LiDAR and hyperspectral data in a natural mixed forest of Northeast China [J]. *Forests*, 2020, 11(3):303–321.
- [21] YANG Q L, SU Y J, JIN S C, et al. The influence of vegetation characteristics on individual tree segmentation methods with airborne LiDAR data [J]. *Remote Sensing*, 2019, 11(23):2880–2897.
- [22] 孙振峰, 张晓丽, 李霓雯. 机载与星载高分遥感影像单木树冠分割方法与适宜性对比 [J]. *北京林业大学学报*, 2019, 41(11):66–75.  
SUN Zhenfeng, ZHANG Xiaoli, LI Niwen. Comparison of individual tree crown extraction method and suitability of airborne and spaceborne high-resolution remote sensing images [J]. *Journal of Beijing Forestry University*, 2019, 41(11):66–75. (in Chinese)
- [23] 皋厦, 申鑫, 代劲松, 等. 结合 LiDAR 单木分割和高光谱特征提取的城市森林树种分类 [J]. *遥感技术与应用*, 2018, 33(6):1073–1083.  
GAO Sha, SHEN Xin, DAI Jingsong, et al. Tree species classification in urban forests based on LiDAR point cloud segmentation and hyperspectral metrics extraction [J]. *Remote Sensing Technology and Application*, 2018, 33(6):1073–1083. (in Chinese)
- [24] WANG Q, WU B, ZHU P. ECA – Net: efficient channel attention for deep convolutional neural networks [C] // CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2020.
- [25] FERREIRA M P, ALMEIDA D R A, PAPA D A, et al. Individual tree detection and species classification of Amazonian palms using UAV images and deep learning [J]. *Forest Ecology and Management*, 2020, 475:118397–118407.
- [26] 张祥东, 王腾军, 朱劭俊, 等. 基于扩张卷积注意力神经网络的高光谱图像分类 [J]. *光学学报*, 2021, 41(3):0310001.  
ZHANG Xiangdong, WANG Tengjun, ZHU Shaojun, et al. Hyperspectral image classification based on dilated convolutional attention neural network [J]. *Acta Optica Sinica*, 2021, 41(3):0310001. (in Chinese)
- [27] LIU L X, COOPS N C, AVEN N W, et al. Mapping urban tree species using integrated airborne hyperspectral and LiDAR remote sensing data [J]. *Remote Sensing of Environment*, 2017, 200:170–182.