

融合注意力和残差网络的无人机影像树种识别

徐志扬^{1,2,3}, 陈巧^{1,2*}, 陈永富^{1,2}¹中国林业科学研究院资源信息研究所, 北京 100091;²国家林业和草原局林业遥感与信息技术重点实验室, 北京 100091;³国家林业和草原局华东调查规划院, 浙江 杭州 310019

摘要 为探索采用无人机(UAV)遥感影像进行亚热带树种识别的应用潜力,提出一种结合残差模块和有效通道注意力的网络(ECA-ResNet)对单木树冠影像数据集进行模型训练和识别。首先,利用单木分割算法提取单木树冠,构建不同尺度的 UAV 可见光影像单株树冠影像块样本数据集,并将其划分为训练数据、验证数据和独立测试集;其次,以 ResNet50 为主干网络,在瓶颈层插入有效通道注意力并调整网络结构,构建 ECA-ResNet;最后,将数据集载入预训练的 ECA-ResNet 模型,进行参数迭代训练和验证并进行独立测试,择优确定单木树冠的合适窗口大小。结果表明:ECA-ResNet 对 64×64 像素的单木树冠影像数据集中树种的识别效果更为理想,训练精度和验证精度分别达 98.98% 和 96.60%,独立测试识别精度、Kappa 系数分别达 85.61%、0.8140;ECA-ResNet 模型的训练、验证、独立测试精度分别高于 ResNet50 网络 2.63 个百分点、1.80 个百分点、5.31 个百分点。该研究结果证明卷积神经网络(CNN)能够充分提取可见光图像的空间特征,有效通道注意力能够有效提升 CNN 的单木树种识别能力。

关键词 树种识别; 残差网络; 有效通道注意力; 无人机可见光图像; 单木树冠影像块

中图分类号 S771

文献标志码 A

DOI: 10.3788/LOP212527

Tree Species Recognition Using Combined Attention and ResNet for Unmanned Aerial Vehicle Images

Xu Zhiyang^{1,2,3}, Chen Qiao^{1,2*}, Chen Yongfu^{1,2}¹Research Institute of Forest Resource Information Techniques, Chinese Academy of Forestry, Beijing 100091, China;²Key Laboratory of Forestry Remote Sensing and Information System, National Forestry and Grassland Administration, Beijing 100091, China;³East China Inventory and Planning Institute, National Forestry and Grassland Administration, Hangzhou 310019, Zhejiang, China

Abstract To explore the application potential of unmanned aerial Vehicle (UAV) remote sensing images for subtropical tree species recognition, the ECA-ResNet with residual module and effective channel attention is proposed to train and recognize single tree crown images. First, the single tree crown was extracted by single-tree segmentation algorithm. The single-tree crown image patch dataset of UAV visible image was constructed by means of clipping images with different window sizes, and they were divided into training data, validating data, and independent test dataset respectively. Second, with ResNet50 as a backbone network, by inserting effective channel attention into ResNet bottleneck and adjusting network structure, the ECA-ResNet was constructed. Then, the datasets were inputted into pretrained ECA-ResNet model for parameter training and validation iteratively, and independent test. After that, the optimum window size of single-tree crown image was determined. The results show that the ECA-ResNet gets a better recognition result for tree species in single-tree crown image patch dataset with window size of 64×64 pixel, the accuracy of training and validation of the proposed network reaches 98.98% and 96.60%, respectively. The recognition accuracy and Kappa coefficient of independent test reach 85.61% and 0.8140. The training, validation, and independent test accuracy of ECA-ResNet in this paper are 2.63 percentage points, 1.80 percentage points, and 5.31 percentage points higher than that of the ResNet50 respectively. It is proved that, convolutional neural network (CNN) can fully extract the spatial features of UAV

收稿日期: 2021-09-14; 修回日期: 2021-11-02; 录用日期: 2021-11-10; 网络首发日期: 2021-11-20

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)

通信作者: *Chengqiqo@163.com

visible images for tree species recognition, effective channel attention can effectively improve CNN' single tree species recognition capability.

Key words tree species recognition; residual network (ResNet); efficient channel attention (ECA); UAV visible image; single tree crown image patch

1 引言

树种分类识别是森林生物多样性评价、森林区划和森林资源可持续经营的重要基础性工作。以往的树种分类识别通常采用人工地面调查,该方法费时费力且精度难以保障,不适用于较大范围开展,而遥感技术为在宏观尺度上进行树种分类识别提供了强有力的手段^[1]。传统遥感以卫星、飞机等为传感器平台,并使用多光谱图像^[2-3]、高光谱图像^[4-5]、激光雷达(LiDAR)^[6-7]以及它们的组合^[8-10]进行树种分类识别,但易受气溶胶等影响和数据获取周期束缚。无人机因小巧灵活、成本低,且能够在云下低空飞行,为树种识别提供了一个新的解决方案。一些学者以无人机多光谱^[11-12]或无人机 RGB 正射影像^[13-14]为数据源,提取遥感光谱值及衍生指数、图像纹理或植被垂直特征信息,采用支持向量机、随机森林等方法进行树种分类识别,这些方法的识别精度均较为有限。

传统机器学习方法依靠人工设计特征,主观性强,在图像分类性能上具有不确定性,卷积神经网络(CNN)的出现解决了该难题,它能够自动学习多层次复杂特征,将底层特征转换为高层次的基本线条特征。2012年 AlexNet 在 ImageNet 竞赛中获得第一名,性能远超第二名,开创了近十年深度学习与卷积神经网络发展的里程碑;2014年 GoogleNet 开创性提出 Inception 结构,在网络宽度上用多路非线性映射增强模型的表达能力(相当于多个模型的 ensemble),并不断进行改进,相继引入 1×1 卷积、批归一化(BN)层、卷积核分解(factorization)、残差连接(residual connection)、深度可分离卷积等,网络性能不断得到提升;2014年 VGG 网络通过加深网络深度提高了模型泛化能力,缺点是参数多、内存占用较大;2016年 He 等^[15]实现了残差网络(ResNet),其著名的残差模块较好地解决了模型梯度爆炸和网络退化问题,其 bottleneck 1×1 卷积层能够在网络深度上降低输入维度,减少了计算量,2017年该团队实现的 ResNeXt 把残差网络的单路卷积变成结构一致的多支路多路卷积,通过对网络宽度的优化,参数量不变且效果较好;2017年 DenseNet 模型通过对之前每一层都增加一个单独的近路连接来优化梯度流,效果也较好。目前,卷积神经网络除了在网络的深度、宽度上得到研究,还朝着多支路、轻量化(如 MobileNet、SqueezeNet 等)等方向发展。此外,最近两年注意力模型(attention model)也被应用到各种深度学习任务,如 SENet(squeeze-and-excitation network)、CBAM(convolutional block

attention module)、ECA(efficient channel attention)、自注意力(self attention)等,能一定程度提升网络性能,在图像识别领域均得到了应用。

随着卷积神经网络技术的发展,其在树种分类识别方面也得以应用。Ferreira 等^[16]通过在残差网络中融入空洞卷积和数学形态学方法,提取无人机可见光图像的亚马逊棕榈树,生产者精度(PA)超过语义分割法 4.7%。欧阳光等^[17]构建 LeNet5_relu、AlexNet_mini、GoogLeNet_mini56、ResNet_mini56 和 DenseNet_BC_mini56 卷积神经网络分别对树种识别进行实验,认为后三者分别对不同的树种有最佳分类效果,DenseNet_BC_mini56 总体上为最佳模型。栗旭升等^[18]将残差网络思想融入三维卷积神经网络(3D-CNN),提出三维残差卷积神经网络(3D-RCNN),并构建树种识别模型。3D-RCNN 将模型网络从 12 层增加到 18 层后,联合高分五号高光谱数据(GF-5AHIS)和高分六号高空间分辨率数据(GF-6PMS)的北亚热带森林树种识别精度明显高于传统 3D-CNN 和支持向量机算法。林志玮等^[19]利用 DenseNet 网络对无人机光学图像树种识别进行研究,认为网络模型层数增加也会引起分类精度下降,DenseNet121 模型分类精度优于 DenseNet169 模型。戴鹏钦等^[20]利用基于 ResUNet 模型的全卷积神经网络(FCN)进行树种分类,该网络的总体精度达 97.8%。Zhang 等^[21]基于 ResUNet 模型,利用无人机图像识别多样性、高海拔生态系统的单株植物,最高精度达 91.67%。Cao 等^[22]结合 UNet 和 ResNet 构建 Res-Unet,对广西高峰林场进行树种分类,网络的总体精度达 87%。徐凤等^[23]采用残差网络 ResNet101 作为网络架构主干网络,嵌入 CBAM 到 ResNet101 的 4 个阶段卷积模块后,最高分类精度达 92.5%,超出原 ResNet101 模型 1%。

可以发现,在树种分类识别方面残差网络应用更为广泛,这源于其对图像的特征提取能力突出。然而,无人机可见光影像树种分类识别仍然具有挑战性,尤其对于中高郁闭度森林,树冠间相互关系容易对分类结果彼此产生影响。而且树冠影像不同于自然图像,超高分辨率影像在单株树冠内具有异质性,单株树冠影像从整体上看又具有重复相似性,简单应用残差网络模型识别树种时容易忽视不同通道的特征图对分类结果重要程度的差异,造成分类精度有限。此外,截至目前无人机超高空间分辨率影像树种识别中合适的单木影像窗口大小尚未可知。

为了对卷积神经网络特征图进行差异化处理以提高分类精度,本文提出一种引入 ECA 机制的残差网络

(ECA-ResNet),以残差网络 ResNet50 为主干架构深层网络,在残差瓶颈单元嵌入 ECA 模块学习不同特征图的重要性。同时,为探索卷积神经网络在无人机影像树种识别的应用潜力,以亚热带乔木林为研究对象,基于同期获取的无人机 LiDAR 数据和可见光图像提取研究区单木树冠,按照不同尺度(可变窗口大小、 32×32 像素、 64×64 像素、 96×96 像素、 128×128 像素)提取树冠的可见光图像块,其中可变窗口大小设置为提取树冠直径的 1.25 倍,生成研究区 5 类常见树种,包括杉木(*Cunninghamia lanceolata*)、马尾松(*Pinus massoniana*)、桉木(*Alnus cremastogyne*)、鹅掌楸(*Liriodendron chinense*)和其他阔叶树(other broad-leaves)的单木树冠可见光影像集,将其输入 ECA-ResNet 模型进行树种分类识别,以期利用无人机图像进行树种识别提供参考。

2 研究区与数据来源

2.1 研究区

研究区为中国林业科学研究院亚热带林业实验中心年珠实验林场($27^{\circ}30' \sim 27^{\circ}45'N$, $114^{\circ}30' \sim 114^{\circ}45'E$),位于江西省分宜县内,主要有杉木(*Cunninghamia lanceolata*)、马尾松(*Pinus massoniana*)、桉木(*Alnus cremastogyne*)、鹅掌楸(*Liriodendron chinense*)、其他阔叶树种和乔木树种。

2.2 数据来源

2019 年 6 月底,在距地表 160 m 的高空利用仿地飞行模式采集无人机遥感数据。通过在无人机上搭载激光雷达扫描仪和高清相机,高速获取了激光雷达数据和可见光遥感数据,遥感数据的采集定位精度为 15 mm。

实测样木数据一是来源于 2020 年 7 月野外调查的 15 个圆形样地内的样木数据,样地面积为 0.04 ha ($1 \text{ ha} = 10^4 \text{ m}^2$),在样地内,采用实时动态(RTK)载波相位差分技术定位和记载样地中心的位置信息,记录胸径大于等于 5 cm 的每木位置、树种、冠幅信息等;数据二是来源于 2019 年 7 月野外 RTK 精准定位(精度优于 1 m)的每木位置、树种、冠幅数据。

3 样本数据集

3.1 遥感影像预处理

需要对激光雷达点云数据进行去噪、分类和归一化处理。利用 LiDAR360 激光雷达软件首先完成去噪和分类处理任务,再应用克里金插值方法进行地面点空间插值,生成分辨率为 0.5 m 的数字高程模型(DEM),使用经去噪和分类的点云数据高程信息对 DEM 像元数值进行求差运算,得到归一化数据。最后,基于归一化点云数据,利用 LASTools 工具得到无空洞的冠层高度模型(Pit-Free CHM)。

无人机可见光数据需要使用 LiMapper 软件进行

处理,主要步骤有图片的导入、影像的对齐、密集点云的生成、DEM/数字表面模型(DSM)的生成、正射影像的生成。处理后,可见光影像数据的分辨率为 0.05 m。影像校正过程中,使用同航高和同期 LiDAR 点云冠层高度模型作为参考数据。

3.2 单木树冠分割

按照一定的算法对激光雷达点云或遥感影像进行分割运算,可以得到单木树冠。当林分郁闭度一般时,使用 LiDAR 点云提取单木树冠的效果尚可^[5,24-25]。基于 CHM 数据,采用局部最大值方法对树顶进行探测,再结合分水岭算法就能够实现对单木树冠的分割提取。但是,在森林郁闭度较高情况下,林内树冠容易彼此交叉重叠,导致难以确定树木的位置,此时采用 CHM 数据提取单木树冠的效果往往不佳。因此,可以尝试将 CHM 数据和可见光影像结合。在 LiDAR360 软件下进行 CHM 单木树冠提取调试,当高斯平滑的 sigma 值为 0.5 时分割效果最佳,此时可以提取出探测到的单木树冠矢量。同时,对可见光影像进行色彩空间变换、树冠区域颜色阈值设置以及数学形态学运算,提取出树冠区域矢量。接着,将可见光影像、CHM 单木树冠、可见光树冠区域作为输入数据,利用易康软件进行多尺度树冠提取。经多次调试,确定了分割尺度、形状因子和紧致度的最佳组合为(80, 0.8, 0.9),并据此提取出单木树冠结果。结合实测的单木数据进行检验,采用探测率(r)、准确率(p)和总体精度(F)验证单木提取精度^[26]。

3.3 样本数据集的建立、划分与增产

基于单木树冠分割提取的结果,以每棵树木的树顶为中心绘制正方形矢量框(矢量框分 5 种类型,即边长分别为可变大小、32 pixel、64 pixel、96 pixel、128 pixel,其中可变大小为分割提取的单木树冠冠幅的 1.25 倍),对可见光影像进行裁切,提取出规则的单木影像数据集。

深度学习样本数据集可以分为训练集和独立测试集。训练集用于模型训练阶段,在挑选出最优模型参数后,则用独立测试集开展独立测试以检验模型的泛化能力。将 2020 年实测的 10 个圆形样地和 2019 年高精度定位的单木数据划分为模型训练集(总数 1550 棵,其中杉木 404 棵,马尾松 344 棵,桉木 105 棵,鹅掌楸 319 棵,其他阔叶树 378 棵),将 2020 年实测的另外 5 个圆形样地划分为独立测试集(总数 132 棵,其中杉木 47 棵,马尾松 19 棵,桉木 28 棵,鹅掌楸 18 棵,其他阔叶树 20 棵)。在模型训练时,将训练集中的树木分成 5 个树种,以 7:3 的数量比例将其随机划分为训练数据和验证数据。深度学习模型一般都较为复杂,因此需要大量带标签的训练数据支持,本研究对训练数据的每个树冠图像均进行翻转(上下、左右)与旋转(90° 、 180° 和 270°)操作,使得训练集数量变为原来的 6 倍。

4 融合注意力的残差网络框架

因卷积神经网络算法在图像纹理特征提取方面的重大优势,本文基于当前图像分类性能优秀的残差网络(ResNets),结合 ECA 模块,提出一种无人机可见光图像单木树种识别框架。ECA 模块使得模型关注于单木图像最具辨别力区域,提高了单木树种识别精度。

4.1 ECA 机制

将 ECA 机制加入 CNN 模型中,能使 CNN 各通

道获得不同权重,以此可以提升 CNN 模型的性能。很多现有的方法在优化模型性能的同时也增加了网络模型的复杂度,而 ECA 模块在获取跨通道交互信息以提升模型性能的情况下,只增加了少量模型参数。如图 1 所示,ECA 模块首先在保持通道数不变的情况下对各通道进行全局平均池化(GAP),再利用权重共享原理以及大小为 k 的一维卷积运算产生通道注意力,同时它充分关注了各通道与邻近通道之间的交互。




图 1 ECA 机制块

Fig. 1 ECA mechanism block

4.2 框架结构

残差有效通道注意力(ECA-ResNet)基本单元如图 2 所示,⊕表示逐个像素加运算。基本单元由级联的卷积(Conv)、批规范化、激活、卷积、批规范化、激活、卷积、批规范化和注意力模块组成,基本单元内添加了近路连接,用来改善梯度消失与网络退化现象。

图 2 中,在具有残差瓶颈结构的两种 block 中插入注意力模块,分别构成 ECA-ResNet 基本单元的 block A 和 block B。当 block 的输入与输出通道数不同时在近路连接中加入卷积层以改变特征图维度,结构如 block A; block 的输入与输出通道数相同时近路连接可以直接相加,结构如 block B。

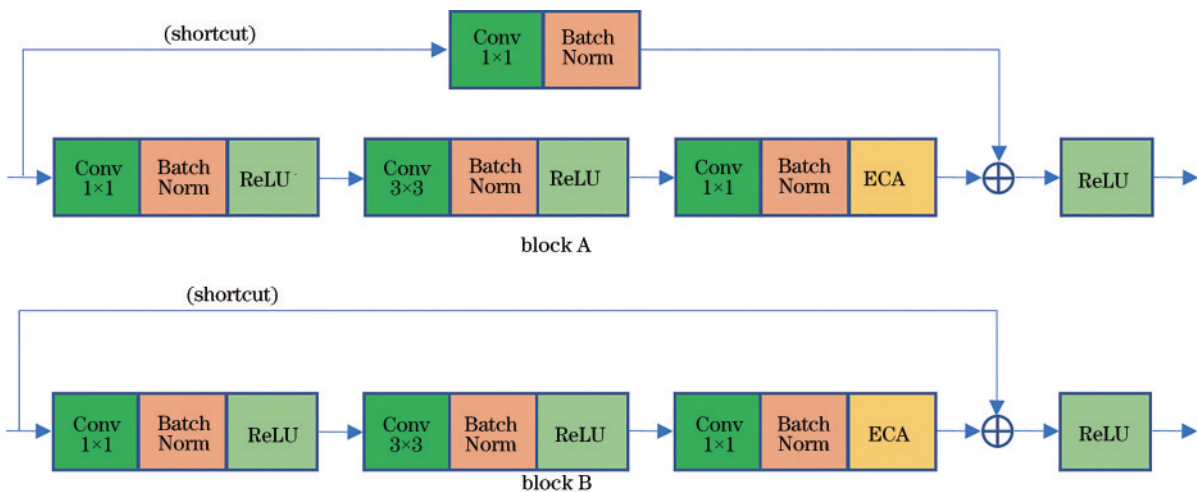


图 2 残差有效通道注意力的基本单元

Fig. 2 Basic unit of ECA-ResNet

残差有效通道注意力主干网络采用具有残差瓶颈结构的 ResNet50 模型框架,以图 2 中 block A 改变特征图维度,紧接着堆叠 2 个 block B 构成 1 组大的 block 模块,用 4 组大的 block 模块替换 ResNet50 模型中 4 个卷积网络模块,以有效提取图像高层次特征,网络框架

总体结构如图 3 所示,图中 Conv 为标准卷积,均包括卷积、批规范化、激活操作。具体来说,通过 7×7 大卷积核提取输入图像的全局信息并进行最大池化后,即经过 4 组大的 block 模块进行卷积与注意力训练,提取图像高层次特征(36 次卷积,12 次注意力训练操作),




图 3 所提网络的总体结构

Fig. 3 Overall structure of proposed network

最后通过平均池化、全连接、Softmax 函数映射输出分类结果。

4.3 模型训练与测试

利用深度学习开源框架 PyTorch 和 Python 语言编制模型训练程序。首先加载大型数据集,对残差注意力网络模型进行参数预训练,然后加载预训练参数作为初始化参数,将扩充后的训练数据输入残差注意力网络模型,将网络输出分类数量改为 5(树种数量),设置 CNN 模型输入图像大小分别为 112、32、64、96、128(分别对应可变大小窗口、 32×32 pixel、 64×64 pixel、 96×96 pixel、 128×128 pixel 的数据集)。模型训练时将数据装载到 GPU 以加速运算,模型的损失函数采用交叉熵函数,通过多轮迭代循环训练模型参数,每轮迭代后用验证数据检验识别精度,50 次迭代都无法提高识别精度到最优时终止训练并保存最优参数。为训练最优模型参数,采用不同优化器(SGD 和 Adam)以及不同初始学习率(0.01、0.001、0.0001)组合训练。训练得出最优模型参数后,使用独立测试集进行模型识别精度测试并进行结果评估。

5 实验结果与分析

5.1 单木树冠分割

单木树冠分割提取是单木树种识别的前提。对 2020 年和 2019 年实测样木数据进行单木树冠分割提取,利用 2020 年实测的 15 个圆形样地的样木数据进行单木分割精度评价。在 15 个圆形样地中,实测样木共有 473 株,剔除掉树冠被遮挡的小树、死亡树木后还有树木 399 株,单木分割后共提取出 391 株树木树冠,分割结果按 1:1,匹配的有 331 株,过分割的有 60 株,漏分割的有 68 株,单木探测率、准确率及总体精度分别为 82.96%、84.65% 及 83.80%,单木分割结果总体上

可以满足研究需求。本研究的单木探测率、准确率、总体精度与皋厦等^[25]采用的点云距离判断单木分割法相比要低,这应该与皋厦等的研究对象相对不太复杂有关,本研究区林分茂密、树种多样、垂直结构变化复杂。

5.2 单木树种识别

基于 ECA-ResNet,利用 Python 语言和 PyTorch 深度学习框架编程,分别载入模型的训练数据和验证数据,设置批次大小为 32。卷积层初始化参数使用大型数据集预训练权重和偏置结果,使用不同优化器和初始学习率的组合训练 CNN 模型,并利用独立测试集进行检验。结果表明,初始学习率设置为 0.001 时,模型能够取得不错的效果,在 SGD 优化器下,单木树冠影像块大小为 64×64 像素时,模型训练和独立测试后能够获得较优的识别结果。表 1 列出了 ECA-ResNet 模型在不同大小单木影像块下的训练和独立测试最优结果。可以看出:在基于不同单木树冠影像块的方案 I、III、IV、V 下,模型训练后均能取得较为不错的精度和 Kappa 系数,损失值也达到低值;独立测试集下,方案 III 的精度和 Kappa 系数最优,方案 IV、V、I 的精度和 Kappa 系数依次降低;方案 II 下,模型训练和独立测试的相关值表现均较差。这种结果与单木树冠影像窗口所捕获的树冠对象有关,方案 II 的单木树冠影像窗口大小为 32×32 pixel,图像分辨率为 0.05 m,因此实际大小仅为 $1.6 \text{ m} \times 1.6 \text{ m}$,而研究区各树种单木树冠的直径分布(非树冠交叉重叠部分,由于树冠茂密,交叉重叠部分不计入)是杉木、鹅掌楸、马尾松在 3.0 m,桉木在 2.8 m,其他阔叶树在 3.0~6.0 m,方案 II 的样本绝大部分都在单木树冠内,不含树冠边缘信息等,因此神经网络提取到的高层次特征较少,模型训练、验证和独立测试精度均有限;而方案 III 的单木树冠影像窗口大小为 64×64 pixel,实际大小为 $3.2 \text{ m} \times 3.2 \text{ m}$,大部

表 1 不同窗口大小单木影像块下模型训练与独立测试结果

Table 1 Training and independent test results of the model in single-tree crown image with different patch sizes

Scheme	Optimizer	Training data			Validation data			Independent test data	
		Accuracy /%	Kappa	Loss	Accuracy /%	Kappa	Loss	Accuracy /%	Kappa
I(variable size)	SGD	97.98	0.9638	0.0973	95.73	0.9449	0.1929	77.27	0.7056
II(32×32 pixel)	SGD	93.25	0.9131	0.2711	86.75	0.8293	0.4920	68.18	0.5966
III(64×64 pixel)	SGD	98.98	0.9869	0.1012	96.60	0.9595	0.1678	85.61	0.8140
IV(96×96 pixel)	SGD	97.98	0.9769	0.0553	95.14	0.9388	0.1838	81.82	0.7629
V(128×128 pixel)	Adam	95.19	0.9381	0.2000	96.15	0.9505	0.1453	79.55	0.7332

分略大于单木树冠直径,其样本含有树冠内部和边缘特征等,加入ECA模块后网络卷积运算能够聚焦到更为有用的信息上,网络结构调整使得信息传递更为高效,故神经网络能提取到更多的单木树冠纹理和树冠间边缘特征,模型训练、验证和独立测试均能取得一定效果;而方案IV和V的单木树冠影像窗口逐渐变大,实际大小分别为4.8 m×4.8 m和6.4 m×6.4 m,样本内除了含有一个样本树种外,还容易混合进一些其他树种,对神经网络提取高层次特征产生不利影响;方案I的单木树冠影像窗口大小可变,虽然能够获得较为理想的单木树冠图像样本,但是由于模型训练时需要将图像变换到统一尺度,图像像素值发生不同程度改变,

也影响了神经网络的特征提取。因此,在160 m航高、0.05 m空间分辨率条件下,模型对64×64像素单木树冠影像块数据集能够取得较优的识别效果。

将识别效果较优的64×64 pixel独立测试数据集代入模型中进行树种识别,将识别结果与地面实测的真实树种生成混淆矩阵,结果如表2所示,其中PA为生产者精度,UA为用户精度。可以发现,其他阔叶树误识别最严重,这是因为研究区其他阔叶树的树木种类多,树冠的形态、颜色与纹理又复杂多样,而在提取影像卷积层高层次特征时,从多种类的其他阔叶树提取的特征多样,提取的部分特征与本文其余4个树种的特征相似。

表2 独立测试数据集的混淆矩阵
Table 2 Confusion matrix of independent test dataset

Recognized species	Ground true species				
	<i>Alnus</i>	Other broad-leaves	<i>Cunninghamia</i>	<i>Liriodendron</i>	<i>Pinus</i>
<i>Alnus</i>	26	1	0	0	0
Other broad-leaves	0	18	4	2	2
<i>Cunninghamia</i>	1	3	38	1	1
<i>Liriodendron</i>	0	0	1	15	0
<i>Pinus</i>	2	0	1	0	16
PA / %	89.66	81.82	86.36	83.33	84.21
UA / %	96.30	69.23	86.36	93.75	84.21

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,结果如图4(a)~(e)所示。利用识别效果较优64×64 pixel窗口的最优模型对5个样地进行识别,结果如图4(f)~(j)所示,分别与图4(a)~(e)对应。其中,图4(a)~(e)标示出实测的单木树种及位置,图4(f)~(j)中用方形框表示误识别的单木树冠块,标注的树种名是树种的标签类别。不难发现:图4(f)中三株杉木被误识别为其他阔叶树;图4(g)中一株杉木被误识别为鹅掌楸,另一

株杉木被误识别为马尾松,一株桉木也被误识别为马尾松;图4(h)中三株桉木中两株被误识别为其他阔叶树,一株被误识别为杉木;图4(i)中树种识别错误稍多,这与样地内树木较多、树种多样、垂直结构复杂、特征提取难度大有关;图4(j)中两株桉木分别被误识别为杉木和马尾松。可以发现,图4(f)、(g)、(h)、(j)林层结构相对单一,树种识别结果较为理想,而图4(i)林层结构较为复杂,树种识别结果仍然难以理想化。

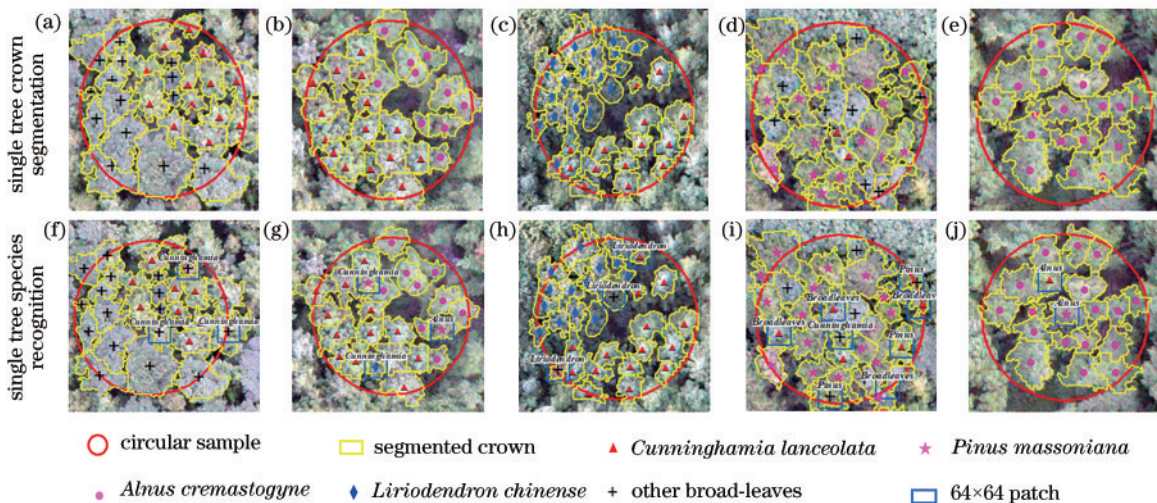


图4 5个测试圆形样地单木树冠分割与树种识别结果

Fig. 4 Results of single tree crown segmentation and recognition in five test circular samples

5.3 结果分析

5.3.1 模型性能对比

为衡量模型性能,验证改进模型精度,对识别效果较优的 64×64 pixel 窗口的单木树冠数据集,分别输入 VGG16、ResNet18、ResNet34 等 10 个卷积神经网络与所提 ECA-ResNet 进行对比,调整模型输出类别数,采用与改进模型一致的训练与独立验证方法,结果如表 3 所示。在对比的 10 个卷积神经网络中,从 ResNet18、ResNet34、ResNet50、ResNet101、ResNet152 这 5 个残差网络的训练结果看,ResNet50 效果更优,随着网络加深,模型验证和独立测试精度反而下降,这表明单木树冠无人机可见光影像特征并不是与网络深度成正相关,网络越深效果不一定越优;同时,对比 ResNet50 与 resnext50_32x4d 发现,加大网络宽度后,模型验证和独立测试精度也下降,表明了网络宽

度的加深对单木树冠影像特征提取识别没有明显效果;将 ResNet50 与 VGG16、densenet121 模型的训练与测试结果相比,后二者亦没有明显优势;对比 MobileNetV2 和 SqueezeNet 这 2 个轻量型网络发现,模型训练、验证和测试结果均难以达其他卷积神经网络的分类效果,可见它们并不能有效提取单木树冠影像特征;由此可见,针对于该单木树冠小数据集,ResNet50 网络在训练和独立测试方面表现更为优异。因此,本文以 ResNet50 为主干网络进行模型改进,改进后的 ECA-ResNet 模型的训练、验证、独立测试精度分别高于 ResNet50 网络 2.63 个百分点、1.80 个百分点、5.31 个百分点,进一步表明了对于单木树冠小数据集,ECA 模块的加入和卷积模块结构的调整增强了神经网络的特征表达能力,提高了分类精度。

表 3 不同模型的性能对比 (64×64 像素单木树冠影像块数据集)

Table 3 Performance comparison of different models (single tree crown image clip dataset with 64×64 pixel)

Network	Training data			Validation data			Independent test data	
	Accuracy / %	Kappa	Loss	Accuracy / %	Kappa	Loss	Accuracy / %	Kappa
VGG16	95.38	0.9405	0.1783	94.23	0.9258	0.2090	75.00	0.6804
ResNet18	94.36	0.9251	0.1529	93.80	0.9203	0.3176	77.27	0.7036
ResNet34	95.84	0.9464	0.2126	93.80	0.9201	0.2722	79.55	0.7356
ResNet50	96.35	0.9442	0.1505	94.80	0.9301	0.2024	80.30	0.7452
ResNet101	96.69	0.9602	0.1278	94.44	0.9284	0.2348	69.70	0.6130
ResNet152	96.41	0.9567	0.1229	94.87	0.9339	0.2264	65.91	0.5641
resnext50_32x4d	96.77	0.9583	0.0999	94.44	0.9285	0.1845	72.73	0.6501
densenet121	96.40	0.9536	0.1544	93.16	0.9119	0.2911	73.48	0.6557
MobileNetV2	86.41	0.8254	0.4771	88.89	0.8571	0.3599	65.91	0.5555
SqueezeNet	84.01	0.7939	0.5726	86.75	0.8286	0.4139	68.94	0.5948
ECA-ResNet	98.98	0.9869	0.1012	96.60	0.9595	0.1678	85.61	0.8140

5.3.2 消融分析

为验证加入有效通道注意力模块和调整 ResNet50 卷积网络模块结构的有效性,对加入有效通道注意力模块前后、调整网络模块结构前后进行组合,在构建的 64×64 pixel 单木树冠影像块数据集上进行

消融分析,以模型训练精度、验证精度、独立测试精度、速度、浮点运算数(FLOPs)和参数数量为评价指标。其中,调整前指 ResNet50 卷积网络模块的 [3, 4, 6, 3] 配置结构,调整后指本文的 [3, 3, 3, 3] 配置结构,结果如表 4 所示。

表 4 卷积神经网络模型改进前后的性能分析

Table 4 Performance comparison of CNN model before and after improvement

Scheme	Operation	ECA	Training accuracy / %	Validation accuracy / %	Test accuracy / %	FLOPs / Gbit	Parameter	Speed / (frame · s ⁻¹)
I(ResNet50)	Before reduced		96.35	94.80	80.30	3.827	23518277	4.59
II	Before reduced	✓	96.57	94.51	83.09	3.832	23518325	4.99
III(ECA-ResNet)	After reduced	✓	98.98	96.60	85.61	3.015	19886697	5.45

对比方案 I、II 在残差瓶颈结构中插入有效通道注意力模块后可见,模型训练与验证精度维持在调整前的水平,而独立测试精度提升 2.79 个百分点,速度提升 8.71%,代价是 FLOPs 消耗高出 0.13%,模型参数量仅有少量增加,这表明有效通道注意力能够充分关

注单木树冠最具辨别力的区域,提取更多有效的树冠特征信息,以较小的代价提升网络性能。对比方案 II、III 卷积网络模块结构调整前后可见,卷积模块配置从 [3, 4, 6, 3] 调整为 [3, 3, 3, 3] 后,模型训练、验证与独立测试精度分别提升了 2.41 个百分点、2.09 个百分点、

2.52个百分点,速度进一步提升9.22%,FLOPs下降21.32%,参数量也减少15.44%,这表明ECA-ResNet的[3,3,3,3]网络配置能够有效提取单株树冠的小目标特征,降低模型参数量和计算量,提高预测效率。综合分析表4,所提ECA-ResNet模型以较低的FLOPs和参数量获得了较好的模型分类精度和速度,单木树种模型训练、验证、独立测试精度分别高出改进前ResNet50的2.63个百分点、1.80个百分点、5.31个百分点,体现了所提方法的优越性。

6 结 论

为探索无人机可见光图像树种识别能力,在残差瓶颈结构中引入有效通道注意力模块,以ResNet50为主干网络调整网络结构,构建ECA-ResNet网络。通过无人机激光雷达数据与可见光图像结合进行单木探测分割树冠,并按照5个不同尺度提取单木树冠块数据集,使用ECA-ResNet网络进行训练和独立测试。结果表明:ECA-ResNet能够有效提取单木树冠纹理特征用于树种识别,对 64×64 像素裁切窗口的单木树冠识别精度最高;ECA-ResNet模型训练、验证、独立测试精度分别高于ResNet50网络2.63个百分点、1.80个百分点、5.31个百分点,更高于大多数卷积神经网络分类方法。因此,所提ECA-ResNet具有一定的准确率,能够为无人机可见光图像的树种识别提供一定参考。

但是,可以看到的是,所提ECA-ResNet的测试结果尚不太理想,具有较大的提升空间,其中研究区林分茂密、树冠彼此相连是影响树种识别网络模型测试结果的重要因素,因此,下一步应重点研究在这种中高郁闭度林分条件下提高树种识别网络模型的应用能力的内容,如引入多模型集成学习方法提高模型泛化能力等,以更好地服务于行业实际应用。

参 考 文 献

- [1] Fassnacht F E, Latifi H, Stereńczak K, et al. Review of studies on tree species classification from remotely sensed data[J]. *Remote Sensing of Environment*, 2016, 186: 64-87.
- [2] Immitzer M, Atzberger C, Koukal T. Tree species classification with random forest using very high spatial resolution 8-band WorldView-2 satellite data[J]. *Remote Sensing*, 2012, 4(9): 2661-2693.
- [3] 任冲,鞠洪波,张怀清,等.多源数据林地类型的精细分类方法[J]. *林业科学*, 2016, 52(6): 54-65.
Ren C, Ju H B, Zhang H Q, et al. Multi-source data for forest land type precise classification[J]. *Scientia Silvae Sinicae*, 2016, 52(6): 54-65.
- [4] Maschler J, Atzberger C, Immitzer M. Individual tree crown segmentation and classification of 13 tree species using airborne hyperspectral data[J]. *Remote Sensing*, 2018, 10(8): 1218-1246.
- [5] 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.
- [6] Blomley R, Hovi A, Weinmann M, et al. Tree species classification using within crown localization of waveform LiDAR attributes[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2017, 133: 142-156.
- [7] Nguyen H M, Demir B, Dalponte M. A weighted SVM-based approach to tree species classification at individual tree crown level using LiDAR data[J]. *Remote Sensing*, 2019, 11(24): 2948-2965.
- [8] Shen X, Cao L. Tree-species classification in subtropical forests using airborne hyperspectral and LiDAR data[J]. *Remote Sensing*, 2017, 9(11): 1180-1203.
- [9] Axelsson A, Lindberg E, Olsson H. Exploring multispectral ALS data for tree species classification[J]. *Remote Sensing*, 2018, 10(3): 183-197.
- [10] Marrs J, Ni-Meister W. Machine learning techniques for tree species classification using Co-registered LiDAR and hyperspectral data[J]. *Remote Sensing*, 2019, 11(7): 819-836.
- [11] Gini R, Passoni D, Pinto L, et al. Use of Unmanned Aerial Systems for multispectral survey and tree classification: a test in a park area of northern Italy[J]. *European Journal of Remote Sensing*, 2014, 47(1): 251-269.
- [12] Mishra N, Mainali K, Shrestha B, et al. Species-level vegetation mapping in a Himalayan treeline ecotone using unmanned aerial system (UAS) imagery[J]. *ISPRS International Journal of Geo-Information*, 2018, 7(11): 445-460.
- [13] Apostol B, Petrilă M, Lorent A, et al. Species discrimination and individual tree detection for predicting main dendrometric characteristics in mixed temperate forests by use of airborne laser scanning and ultra-high-resolution imagery[J]. *Science of the Total Environment*, 2020, 698: 134074.
- [14] Xu Z, Shen X, Cao L, et al. Tree species classification using UAS-based digital aerial photogrammetry point clouds and multispectral imageries in subtropical natural forests[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2020, 92: 102173.
- [15] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [16] 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.
- [17] 欧阳光,荆林海,阎世杰,等.基于卷积神经网络的高分遥感影像单木树种分类[J]. *激光与光电子学进展*, 2021, 58(2): 0228002.
Ouyang G, Jing L H, Yan S J, et al. Classification of

- individual tree species in high-resolution remote sensing imagery based on convolution neural network[J]. *Laser & Optoelectronics Progress*, 2021, 58(2): 0228002.
- [18] 栗旭升, 陈冬花, 刘赛赛, 等. 基于改进 3D-CNN 的多源遥感数据树种识别[J]. *激光与光电子学进展*, 2020, 57(24): 242804.
Li X S, Chen D H, Liu S S, et al. Tree-species identification of multisource remote-sensing data using improved 3D-CNN[J]. *Laser & Optoelectronics Progress*, 2020, 57(24): 242804.
- [19] 林志玮, 丁启禄, 黄嘉航, 等. 基于 DenseNet 的无人机光学图像树种分类研究[J]. *遥感技术与应用*, 2019, 34(4): 704-711.
Lin Z W, Ding Q L, Huang J H, et al. Study on tree species classification of UAV optical image based on DenseNet[J]. *Remote Sensing Technology and Application*, 2019, 34(4): 704-711.
- [20] 戴鹏钦, 丁丽霞, 刘丽娟, 等. 基于 FCN 的无人机可见光影像树种分类[J]. *激光与光电子学进展*, 2020, 57(10): 101001.
Dai P Q, Ding L X, Liu L J, et al. Tree species identification based on FCN using the visible images obtained from an unmanned aerial vehicle[J]. *Laser & Optoelectronics Progress*, 2020, 57(10): 101001.
- [21] 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.
- [22] 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.
- [23] 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 F, Miao Z, Ye Q L. End-to-end remote sensing image classification framework based on convolutional block attention module[J]. *Journal of Forestry Engineering*, 2020, 5(4): 133-138.
- [24] 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.
- [25] 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 S, Shen X, Dai J S, 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.
- [26] Zhang B, Zhao L, Zhang X L. Three-dimensional convolutional neural network model for tree species classification using airborne hyperspectral images[J]. *Remote Sensing of Environment*, 2020, 247: 111938.