

doi: 10.6046/zrzyyg.2022018

引用格式: 金远航,徐茂林,郑佳媛. 基于改进 YOLOv4 - tiny 的无人机影像枯死树木检测算法[J]. 自然资源遥感,2023,35(1):90-98. (Jin Y H,Xu M L,Zheng J Y. A dead tree detection algorithm based on improved YOLOv4 - tiny for UAV images[J]. Remote Sensing for Natural Resources,2023,35(1):90-98.)

基于改进 YOLOv4 - tiny 的无人机影像枯死树木检测算法

金远航, 徐茂林, 郑佳媛

(辽宁科技大学土木工程学院, 鞍山 114051)

摘要: 针对目前枯死树木检测主要依赖人工实地勘察,容易受到森林地形限制、勘察效率低、易发生危险等问题,提出一种引进注意力机制及空间金字塔池化的 YOLOv4 - tiny 枯死树木检测算法。首先,该方法在模型的 Backbone 部分后引入空间金字塔池化(spatial pyramid pooling, SPP)结构,融合局部和全局特征,丰富模型的特征表达能力;其次,使用 ELU 替换模型中原激活函数 LeakyReLU,使得激活函数单侧饱和,能够更好地收敛,提升模型鲁棒性;最后,将注意力机制 ECANet 引入模型中,加强网络对图像中重要信息的学习,提升网络的性能。实验利用无人机采集辽南某风景区山林的树木影像,并使用不同模型对其中枯死树木进行检测。通过实验结果表明,改进算法检测精度达到 93.25%,相比于 YOLOv4 - tiny, YOLOv4, SSD 和文献[8]算法,精度分别提升 9.58%, 12.57%, 10.54% 和 4.87%,能够较好地实现对于枯死树木的检测。

关键词: 枯死树木; YOLOv4 - tiny; 注意力机制; SPP; ELU 激活函数

中图法分类号: TP 751 **文献标志码:** A **文章编号:** 2097 - 035X(2023)01 - 0090 - 09

0 引言

枯死树木对于林业生产和生态环境具有较大程度的影响,对森林的可持续发展造成了制约。如果发生外来有害物种入侵等问题,便可能会出现森林植物大量死亡的情况,对环境经济造成损失,因此,对枯死树木的检测是十分必要的^[1]。但是目前枯死树木检测主要依赖人工实地勘察,由于森林中地形的多样性,实地勘察会受到各种各样的限制,同时还易发生危险,导致勘察效率低,因此,传统的人工检测手段已远不能满足日益严峻的枯死树木检测的需要。

近年来,随着机器学习技术的突飞猛进^[2],森林树木的自动化检测方面有了一定的进展,使得机器学习手段代替人工勘察逐渐成为可能^[3]。研究者们利用随机森林、支持向量机等方法结合遥感技术对树木检测进行了诸多尝试。Kamińska 等^[4]使用 ALS 和彩色红外图像,结合 ALS 数据中的强度和结构变量以及来自航空影像的光谱信息,采用随机森林方法进行枯死树木分类。Manandhar 等^[5]利用线性支持向量机对特征进行标准化和降维,并利用

标准化特征空间分布的局部最大检测算法对棕榈树进行检测。宋以宁等^[6]基于枯死树木的颜色特征,提取可能为枯死树木的超像素区域,利用支持向量机对提取的超像素进行分类,从而检测出图像中的枯死树,其检测结果与人工检测结果的交并比均值大于 58%。尽管此类基于对象的树木检测方法能较好地体现树木整体特性,并通过融入机器学习算法提高树木检测准确率。但是,基于机器学习的方法对于影像中不同的场景需要事先人为指定要提取的特征以及限定对应的参数,在没有相关先验知识的条件下很难进行单棵树木的准确检测。

在其中的深度学习方面,大量以卷积神经网络为基础的目标检测算法被应用于树木检测当中。Culman 等^[7]使用卷积神经网络检测加那利群岛的凤凰树,目标区域人工标注的树木中 86% 的样本能被正确检测;王新彦等^[8]通过通道多尺度变化和分辨率融合模块对 YOLOv4 - tiny 网络进行优化,并对草坪树木进行检测,平均精度均值达到 80.59%。但上述实验中所使用网络较为简单,特征提取不够充分导致检测结果不是十分理想。Yu 等^[9]使用 YOLOv4 对感染松材线虫病的树木进行早期检测,检测准确率达到 57.07% ~ 63.55%。上述网络虽

收稿日期: 2022 - 01 - 12; 修订日期: 2022 - 05 - 19

基金项目: 国家重点研发计划项目“金属非金属矿山重大灾害治灾机理及防控技术研究”(编号: 2016YFC0801600)资助。

第一作者: 金远航(1997 -),男,硕士研究生,主要研究方向为深度学习、图像处理、摄影测量与遥感。Email: yhj2@126.com。

通信作者: 徐茂林(1964 -),男,硕士,教授,主要研究方向为摄影测量与遥感。Email: xml1964@163.com。

然检测效果较好,但检测速度较慢,同时容易出现误检的情况。

针对上述方法中的需要先验知识、检测精度低、检测速度慢等问题,结合模型结构特征,本文提出一种引入注意力机制及空间金字塔池化的 YOLOv4 -

tiny 枯死树木检测方法,在保证检测速度的前提下提升了检测精度。

1 技术方法

本文的枯死树木检测流程见图 1。




图 1 枯死树木检测技术流程图

Fig. 1 Flow chart of dead tree detection technology

1.1 YOLOv4 - tiny 算法

YOLOv4 - tiny^[10] 网络是在 YOLOv4^[11] 网络基础上设计的,其使用 CSPDarknet53 - tiny 网络作为主干特征提取网络替代 YOLOv4 模型中的 CSPDarknet - 53 网络,网络参数少,具有更快的检测速度。CSPDarknet53 - tiny 网络使用了跨级网络中的 CSP-Block 模块,将特征映射分为 2 部分,并通过跨级残差边缘将 2 部分合并,使得梯度流能够在 2 个不同的网络路径上传播,增强了梯度信息的相关性差异,提高卷积网络的学习能力。在特征加强部分,YOLOv4 - tiny 模型只采用了 1 个特征金字塔结构^[12],并未像 YOLOv4 模型中进行下采样。尽管这样能够提升目标检测的速度,但会使特征信息提取不足,从而导致检测准确率下降。最后,YOLOv4 - tiny 分别使用 2 种不同比例的特征图预测检测结果。

1.2 SPP 模块

空间金字塔池化 (spatial pyramid pooling, SPP)^[13] 能够把局部特征和全局特征进行融合,以达到丰富特征表达能力的目的。SPP 结构有 3 个重要特点: ①SPP 结构能对任意尺寸的输入产生指定大小的输出; ②相比于普通池化层仅有一个窗口尺度,SPP 结构能对输入图像在多个尺度上进行池化,对物体的扭曲有较好的鲁棒性; ③SPP 结构输入灵活,能够对任意尺度提取的特征图进行池化,其结构如图 2 所示。本文将 SPP 结构加入到 YOLOv4 - tiny 模型中,从主干网络 CSPDarknet53 - Tiny 输出以后加入 SPP 结构,再经过 3 × 3 卷积层。




图 2 固定尺寸输出的 SPP 结构

Fig. 2 SPP structure with fixed size output

1.3 ELU 激活函数

在多层神经网络中,上层节点的输出与下层节点的输入间存在一个非线性函数关系,该函数称为激活函数。YOLOv4 - tiny 网络中采用 LeakyReLU 作为激活函数,其函数表达如下:

$$LeakyReLU(x) = \begin{cases} x & x \geq 0 \\ ax & \text{其他} \end{cases}, \quad (1)$$

式中: x 为输入图像的特征; a 为一个很小的常数。从式中能够看出,当 $x \geq 0$ 时,LeakyReLU 的导数为常数 1,即在该范围内梯度不衰减,能够有效缓解梯度消失问题,但是当 $x < 0$ 时,有了负数的输出,导致其非线性程度减弱。

因此,本文选用更优的 ELU^[14] 激活函数代替

YOLOv4 - tiny 网络中的 LeakyReLU 函数,其函数表达式如下:

$$ELU(x) = \begin{cases} x & x > 0 \\ \alpha(e^x - 1) & x \leq 0 \end{cases}, \quad (2)$$

式中: x 为输入图像的特征; α 为可调参数,其控制 ELU 负值部分何时饱和。由式(2)能够看出,ELU 在 $x \leq 0$ 时是指数函数,其为单侧饱和,能够更好的收敛。图 3 为激活函数 LeakyReLU 与 ELU 的对比图,从图中能够看出,在负区间,ELU 与 LeakyReLU 相比对噪声更加鲁棒,收敛速度更快。




图 3 激活函数 LeakyReLU 与 ELU 对比
Fig. 3 Comparison between activation function LeakyReLU and ELU

1.4 注意力机制 ECA

卷积神经网络中的注意力机制是一种提升网络性能的网络资源分配方法,其主要通过将更多的算力集中在更重要的问题处理上,以减少网络训练对于算力的需要。随着网络层数的加深和参数数量的增多,网络的表达能力会变好,但同时会造成网络信息过载的问题。因此,在不改变网络深度和信息量的情况下,添加注意力机制能够让网络更加关注重要信息,减少无用信息的影响,以提高网络的性能。因此,本文在 2 次特征输出及上采样后加入注意力机制模块,进而加强网络对重要信息的学习,获得更好的检测效果。

ECANet^[15]是在 SENet^[16]基础上进行修改,其具体结构如图 4 所示,在不降低维度的情况下输入特征图 X 进行全部通道全局平均池化后,ECA 通过一个能够权值共享的一维卷积进行学习,并在学习过程中考虑每个通道与其 k 个近邻来捕获跨通道交互。 k 代表一维卷积的内核大小,通过跨通道信息交互作用的覆盖范围与通道维数 C 的正比关系,获




图 4 ECA 注意力模块结构图
Fig. 4 ECA attention module structure

得公式(3),自适应确定 k 的取值,公式为:

$$k = \psi(C) = \left\lceil \frac{\log_2 C + b}{\gamma} \right\rceil_{\text{odd}}, \quad (3)$$

式中: $\gamma = 2, b = 1$; C 为通道维数^[17]; $_{\text{odd}}$ 为离 k 最近的奇数,若 k 为偶数则选 $k + 1$ 。

改进后的模型结构如图 5 所示。




图 5 改进后 YOLOv4 - tiny 结构
Fig. 5 Improved YOLOv4 tiny structure

2 实验与分析

2.1 数据采集及预处理

本文使用大疆 PHANTOM4 RTK 四旋翼无人机,采集辽南某风景区山林的枯死树木 RGB 影像信息。无人机飞行高度为 80 ~ 120 m,影像采集时间段为下午 3: 00—5: 00,无人机飞行时镜头呈 90°拍摄,航向重叠与旁向重叠均设为 80%。由于无人机获取的原始影像较大且不是每张影像中均含有枯死树木,不能直接输入网络进行训练,因此需要将影像进行筛选及裁剪处理,选取裁剪后包含枯死树木的影像,影像分辨率为 913 × 913,影像大小为 96 dpi,图 6 为裁剪后部分影像数据集。




图 6 部分影像数据集
Fig.6 Partial dataset image

将选取后的影像使用 LabelImg 软件标注其中枯死树木目标,并使用 PASCAL VOC^[18] 格式的 XML 文件注释。但由于本文实验条件有限,不能直接获取大量的影像数据,为了避免数据过少造成模型稳定性差或过拟合等问题,对影像进行翻转及对数变

换进行数据增强,将处理后的影像加入数据集中。处理后的影像如图 7 所示。本文实验共获得 10 000 张枯死树木影像作为数据集,其中 8 000 张影像作为训练集和验证集,2 000 张影像作为测试集。




图 7 数据增强
Fig.7 Data enhancement

2.2 实验环境与评价指标

本文实验使用 TensorFlow 框架,Python 版本为 3.7,NVIDIA RTX 3080(10 GB)显卡,内存 32 G。训练模型的初始学习率为 0.000 1,模拟余弦退火衰减策略调整网络学习率,Epoch 设置为 600。
本文实验使用平均精度(average precision, AP)和每秒检测影像的数量(frames per second, FPS)作为评价指标;AP 指标通常在单目标检测中衡量某

一类目标检测的精度,其指的是准确率 - 召回率曲线(Precision - Recall, P - R)上精准度的均值,计算公式如下^[19]:

$$Precision = \frac{Num(TP)}{Num(TP) + Num(FP)} \quad , \quad (4)$$

$$AP = \frac{\sum Precision}{Num(TotalObjects)} \quad , \quad (5)$$

式中： TP 为实际正类预测为正类的数量； FP 为实际负类预测为正类的数量； $TotalObjects$ 为图片总数。

2.3 实验结果分析

2.3.1 不同注意力机制对模型性能的影响

为了比较不同注意力机制对模型检测性能的影响,本实验分别在 YOLOv4 - tiny 模型中加入 3 种注意力机制,即 SENet,CBAM 和 ECANet,并利用 3 种网络对数据集进行训练,训练完成后利用所获权值对测试集进行检测和对比,实验结果如表 1 所示。

表 1 不同注意力机制检测结果

Tab.1 Results of different attention mechanisms

模型	AP/%	FPS
YOLOv4 - tiny(SENet)	87.69	187.77
YOLOv4 - tiny(CBAM)	88.04	176.84
YOLOv4 - tiny(ECANet)	88.65	200.94

从表中能够看出,加入 ECA 注意力机制的 YOLOv4 - tiny 网络模型的 AP 值高于另 2 种注意力机制模型,高于 YOLOv4 - tiny(SENet)模型 0.96%,高于 YOLOv4 - tiny(CBAM)模型 0.61%,达到 88.65%,在 3 种加入注意力机制的模型中检测效果最佳。此外,加入 ECA 注意力机制的模型得到了 3 种模型中最高的检测速度,达到 200.94 FPS。

为了验证改进算法对枯死树木的检测效果,可视化地对比 3 种模型的检测效果,使用 3 种模型分别对测试集图片进行检测。测试的部分结果如图 8 所示,从图 8(a) — (c)能够看出,基于 SENet 和 CBAM 的 YOLOv4 - tiny 算法会出现漏检某些背景较为复杂的目标的情况;从图 8(d) — (f)能够看出,CBAM 算法会对小目标枯死树木造成漏检;从图 8(g) — (i)能够看出,SENet 算法会对图片




图 8 部分检测结果对比

Fig.8 Comparison of partial detection results

中颜色和枯死树木相近的物体或区域进行错检,而加入 ECANet 的 YOLOv4 - tiny 算法不论是在背景复杂、颜色相近或是图片中包含小目标的情况下均有着良好的检测效果。

2.3.2 不同激活函数对模型性能的影响

为了显示 ELU 激活函数在训练过程中能够使模型更具鲁棒性,从而获得更佳的训练效果,本实验分别在模型中使用 LeakyReLU 和 ELU 两种激活函数进行训练,再对同一测试集进行预测,2 种激活函数的对比如表 2 所示。

表 2 不同激活函数对比

Tab.2 Comparison of different activation functions		
激活函数	AP/%	FPS
LeakyReLU	88.65	200.94
ELU	90.87	188.12

从表中能够得知,使用 ELU 激活函数的 AP 值为 90.87%,相比使用 LeakyReLU 作为激活函数的网络模型提升 2.22%。结果表明 ELU 激活函数相比 LeakyReLU 对于噪声具有更强的鲁棒性,收敛速度更快,能够提升模型的训练效率,获得较好的检测效果。使用 ELU 作为激活函数的模型,FPS 略低于

使用 LeakyReLU 作为激活函数的模型。

2.3.3 加入 SPP 结构对模型性能的影响

为了研究加入 SPP 结构是否能够对模型的检测进行优化,本实验分别使用加入 SPP 结构和未加入 SPP 结构的模型进行训练,并对测试集进行检测,检测结果如表 3 所示。

表 3 2 种模型检测结果对比

Tab.3 Comparison of test results of 2 models		
模型	AP/%	FPS
YOLOv4 - tiny	90.87	188.12
YOLOv4 - tiny(SPP)	93.25	182.63

从表中能够看出,加入 SPP 结构的模型取得较好的检测结果,AP 值优于未加入 SPP 结构的模型,AP 值达到了 93.25%,高于原始模型 2.38%。结果表明,加入 SPP 结构能够在训练时加强模型的鲁棒性,对模型检测进行优化。

2.3.4 检测模型影像适应性实验

为了证实本实验模型是否能够在不同条件下的影像中均获得较好的检测效果,本实验通过对影像进行筛选及图像增强的方法分别获得 600 张明亮和黑暗状态的枯死树木影像,如图 9 所示。




图 9 不同状态部分影像

Fig.9 Different state partial images

为了验证本实验算法对不同亮度影像检测的适应性,本实验分别使用改进的 YOLOv4 - tiny, YOLOv4,SSD 和 YOLOv4 - tiny 算法分别对上述 2 种状态影像进行检测,实验结果如表 4 所示。

从表中能够看出,在影像明亮的状态下,本文算

表 4 4 种模型对不同影像检测结果对比

Tab.4 Comparison of four models for different image detection results (%)				
状态	YOLOv4	SSD	YOLOv4 - tiny	本文算法
明亮	85.50	86.56	83.55	93.16
黑暗	88.80	95.91	86.23	94.32

法获得了较好的检测效果,准确率达到 93.16%,相比 YOLOv4 和 SSD 分别高出 7.66% 及 6.6%,同时相比原始 YOLOv4-tiny 算法高出 9.61%。在影像黑暗状态下,本文算法同样取得较好的检测效果,准确率高于 YOLOv4 及 YOLOv4-tiny 算法,分别高出 5.52% 及 8.09%;但是低于 SSD 算法 1.59%。因此能够看出,本文作为轻量级模型对于不同影像的检测适应性较好,在不同环境的条件下对枯死树木均有不错的检测效果。

2.3.5 不同检测模型对比实验

为了验证本文算法可靠性,使用相同的实验数据分别在 YOLOv4,SSD,YOLOv4-tiny、文献[8]算法及本文算法中进行训练。5 种模型在训练时 Loss 的变化趋势如图 10 所示。




图 10 模型训练时 Loss 变化趋势

Fig.10 The change trend of Loss in model training

从图中能够看出,YOLOv4 及文献[8]算法 Loss 值始终高于另 3 种算法,本文算法 Loss 值略高于 YOLOv4-tiny 及 SSD 算法。本文算法在迭代时, Loss 在 0~100 个 Epoch 之间下降最快,当 Epoch 到达 200 时, Loss 曲线逐渐趋于平缓。

为验证本实验算法的性能,选择上述 5 种算法在测试集上进行检测,结果如表 5 所示。

表 5 4 种模型对测试集检测结果对比

模型	AP/%	FPS
YOLOv4	82.71	47.45
SSD	80.68	110.37
YOLOv4-tiny	83.67	196.22
文献[8]	88.38	179.54
本文算法	93.25	182.63

从表中能够看出,本文算法的 AP 值高于 YOLOv4 模型 10.54%,高于 SSD 模型 12.57%,高于 YOLOv4-tiny 模型 9.58%,高于文献[8]模型

4.87%。结果表明,本文算法相比其他检测模型,在检测枯死树木方面能够取得较好的效果。在 FPS 方面,本文算法高于 YOLOv4 和 SSD 模型,但是由于加入注意力机制和 SPP 模块以及更改了激活函数, FPS 略低于原始 YOLOv4-tiny 模型。

2.3.6 不同参数对模型精度的影响

1)不同 Batch Size 对模型精度影响。由于在训练时不同的 Batch Size 会影响模型的泛化性能,因此为了验证不同 Batch Size 在训练时对模型检测精度的影响,本文分别将 Batch Size 设为 2,4,6,8,16,32 和 64 进行训练,训练后检测结果如表 6 所示。

表 6 不同 Bactch Size 对比

Batch Size	AP/%	FPS
2	90.36	170.23
4	92.65	175.29
8	92.33	177.46
16	93.25	182.63
32	93.36	174.38
64	91.80	178.73

从表中能够看出,当 Batch Size 为 2 时,训练效果较差,仅获得 90.36% 的 AP 值,可能是由于 Batch Size 设置过小会使模型收敛较慢,导致训练结果较差,而当 Batch Size 为 64 时,训练结果同样并不理想,AP 值仅为 91.80%,可能是由于 Batch Size 设置较大时导致模型泛化能力下降,同时还会造成内存不够。当 Batch Size 为 4 和 8 时,检测结果较为一般,AP 值分别为 92.65% 和 92.33%;当 Batch Size 为 16 时,训练结果与最好的 32 相差无几,AP 值能够达到 93.25%;当 Batch Size 为 32 时,得到的检测效果最好,AP 值最高,达到 93.36%,分别高出 Batch Size 为 4,8 和 16 时的 0.71%,1.03% 和 0.11%。

2)不同数据集数量对模型精度的影响。为了验证不同参数量对模型检测精度的影响,本文数据集以 1 000 张影像为基础,每次增加 1 000 张影像作为一个新的数据集输入模型进行训练,共分 8 次进行实验,实验结果如表 7 所示。

表 7 不同数量数据集对比

数量	AP/%	FPS
1 000	75.65	177.40
2 000	78.08	164.18
3 000	82.60	175.40
4 000	84.42	174.73
5 000	86.59	174.26
6 000	89.21	175.12
7 000	91.98	175.39
8 000	93.36	174.38

从表中能够看出,随着训练数据集的增加,模型检测的 AP 值逐步提升,每增加 1 000 张影像,AP 值能够提升 2% ~ 4%,当数据集数量达到本文准备的最多的 8 000 张时,AP 值达到最高,为 93.36%。仅根据本实验能够看出,本文模型在一定范围内,随着数据集的增加,AP 值逐渐提升。

3 结论

1)为解决目前枯死树木检测较为依赖人工实地踏勘的情况,本文将无人机与深度学习应用到枯死树木检测中,使用无人机航飞获取航拍影像并制作数据集,提出一种改进后的 YOLOv4 - tiny 网络模型,在模型的 Backbone 后加入 SPP 模块,实现局部特征和全局特征的融合;将原始网络中的激活函数替换为 ELU,提升模型的训练效率;将注意力机制 ECA 引入到网络模型当中,使网络能够自动地突出影像中的重要信息。

2)本文通过实验验证了本文算法在精度方面的提升,其 AP 值达到 93.25%,相比原始的 YOLOv4 - tiny, YOLOv4 和 SSD 算法分别提升 9.58%,12.57% 和 10.54%,同时检测速度相比 YOLOv4 及 SSD 具有明显的提升,相比文献[8]算法 AP 值提升 4.87%,有效避免了在检测过程中容易出现的错检、漏检等情况。

3)但是,本文还存在着数据集样本不足、检测精度有待提升等问题,后续研究将建立更加复杂、多元的枯死树木数据集用于研究,同时从数据预处理及模型结构等方面进行改进,从而提升模型的普适性,发挥研究算法的最大价值。

参考文献(References):

[1] Kamińska A, Lisiewicz M, Stereńczak K, et al. Species - related single dead tree detection using multi - temporal ALS data and CIR imagery[J]. Remote Sensing of Environment, 2018, 219: 31 - 43.

[2] 毕凯,李英成,丁晓波,等. 轻小型无人机航摄技术现状及发展趋势[J]. 测绘通报, 2015(3): 27 - 31, 48.

Bi K, Li Y C, Ding X B, et al. Aerial photogrammetric technology of light small UAV; Status and trend of development[J]. Bulletin of Surveying and Mapping, 2015(3): 27 - 31, 48.

[3] 汪沛,罗锡文,周志艳,等. 基于微小型无人机的遥感信息获取关键技术综述[J]. 农业工程学报, 2014, 30(18): 1 - 12.

Wang P, Luo X W, Zhou Z Y, et al. Key technology for remote sensing information acquisition based on micro UAV[J]. Transactions of the Chinese Society of Agricultural Engineering, 2014, 30(18): 1 - 12.

[4] Kamińska A, Lisiewicz M, K Stereńczak, et al. Species - related

single dead tree detection using multi - temporal ALS data and CIR imagery[J]. Remote Sensing of Environment, 2018, 219: 31 - 43.

[5] Manandhar A, Hoegner L, Stilla U. Palm tree detection using circular autocorrelation of polar shape matrix[J]. ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences, 2016, 3: 465 - 472.

[6] 宋以宁,刘文萍,骆有庆,等. 基于线性谱聚类的林地图像中枯死树监测[J]. 林业科学, 2019, 55(4): 187 - 195.

Song Y N, Liu W P, Luo Y Q, et al. Monitoring of dead trees in forest images based on linear spectral clustering[J]. Scientia Silvae Sinicae, 2019, 55(4): 187 - 195.

[7] Culman M, Delalieux S, Van Tricht K. Individual palm tree detection using deep learning on RGB imagery to support tree inventory[J]. Remote Sensing, 2020, 12(21): 3476.

[8] 王新彦,吕峰,易政洋. 基于深度学习的草坪树木检测方法研究[J]. 中国农机化学报, 2021, 42(7): 136 - 141.

Wang X Y, Lyu F, Yi Z Y. Research on lawn tree detection method based on deep learning[J]. Journal of Chinese Agricultural Mechanization, 2021, 42(7): 136 - 141.

[9] Yu R, Luo Y, Zhou Q, et al. Early detection of pine wilt disease using deep learning algorithms and UAV - based multispectral imagery[J]. Forest Ecology and Management, 2021, 497: 119493.

[10] 李海滨,孙远,张文明,等. 基于 YOLOv4 - tiny 的溜筒卸料煤尘检测方法[J]. 光电工程, 2021, 48(6): 73 - 86.

Li H B, Sun Y, Zhang W M, et al. The detection method for coal dust caused by chute discharge based on YOLOv4 - tiny[J]. Opto - Electronic Engineering, 2021, 48(6): 73 - 86.

[11] Bochkovskiy A, Wang C Y, Liao H Y M. YOLOv4: Optimal speed and accuracy of object detection[J]. Computer Vision and Pattern Recognition, 2020, 17(9): 198 - 215.

[12] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2117 - 2125.

[13] He K, Zhang X, Ren S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1904 - 1916.

[14] Clevert D A, Unterthiner T, Hochreiter S. Fast and accurate deep network learning by exponential linear units (ELUS)[C]//Proceedings of the 4th International Conference on Learning Representations. ICLR, 2015: 375 - 387.

[15] Wang Q, Wu B, Zhu P, et al. ECA - Net: Efficient channel attention for deep convolutional neural networks[C]//CVF Conference on Computer Vision and Pattern Recognition. Seattle. IEEE, 2020: 11531 - 11539.

[16] Hu J, Shen L, Sun G. Squeeze - and - excitation networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132 - 7141.

[17] 赵杰伦,张兴忠,董红月. 基于尺度不变特征金字塔的输电线路缺陷检测[J]. 计算机工程与应用, 2022, 58(8): 289 - 296.

Zhao J L, Zhang X Z, Dong H Y. Defect detection in transmission line based on scale - invariant feature pyramid networks[J]. Computer Engineering and Applications, 2022, 58(8): 289 - 296.

[18] Everingham M, Van Gool L, Williams C K I, et al. The pascal visu-

al object classes (voc) challenge [J]. International Journal of
Computer Vision,2010,88(2):303 – 338.

[19] 郭晓征,姚云军,贾 坤,等. 基于 U – Net 深度学习方法火星沙
丘提取研究[J]. 自然资源遥感,2021,33(4):130 – 135. doi:
10. 6046/zrzyyg. 2020397.

Guo X Z, Yao Y J, Jia K, et al. Information extraction of Mars
dunes based on U – Net [J]. Remote Sensing for Natural Re-
sources,2021,33(4):130 – 135. doi:10. 6046/zrzyyg. 2020397.

A dead tree detection algorithm based on improved
YOLOv4 – tiny for UAV images

JIN Yuanhang, XU Maolin, ZHENG Jiayuan

(School of Civil Engineering, Liaoning University of Science and Technology, Anshan 114051, China)

Abstract: The current dead tree detection primarily relies on manual field surveys and, thus, is limited by forest topography, suffers a low detection efficiency, and is dangerous. Given these problems, this study proposed a YOLOv4 – tiny dead tree detection algorithm based on the attention mechanism and spatial pyramid pooling (SPP) and improved the original detection model. First, the SPP structure was introduced after the Backbone part of the model to combine local and global features and enrich the feature representation capability of the model. Then, the original activation function LeakyReLU in the model was replaced with ELU, which made the activation function saturate unilaterally, thus improving the convergence and robustness of the model. Finally, the attention mechanism ECANet was introduced into the model to enhance the capacity of the network to learn important information in images, thus improving the performance of the network. The images of trees in a mountain forest of a scenic area in southern Liaoning were collected using an unmanned aerial vehicle (UAV). Then, dead trees in these images were detected using different models. The detection results show that the improved algorithm had a detection accuracy of 93.25% , which was improved by 9.58% , 12.57% , 10.54% , and 4.87% than that of the YOLOv4 – tiny, YOLOv4, and SSD algorithms and an algorithm stated in literature [8], respectively, and achieved the effective detection of dead trees.

Keywords: dead tree; YOLOv4 – tiny; attention mechanism; SPP; ELU activation function
(责任编辑: 李 瑜)