

doi:10.6041/j.issn.1000-1298.2020.07.026

基于 Faster R - CNN 的松材线虫病受害木识别与定位

徐信罗¹ 陶欢² 李存军² 程成² 郭杭¹ 周静平²

(1. 南昌大学信息工程学院, 南昌 330031; 2. 北京农业信息技术研究中心, 北京 100097)

摘要: 松材线虫病是一种毁灭性松树传染病,其传播速度快、发病时间短、致病力强,及时发现、确定受害木的位置,并采取安全处理措施是目前控制松材线虫病蔓延的有效手段。本文通过小型无人机搭载可见光 RGB 数码相机获取超高空间分辨率影像,采用 Faster R - CNN 目标检测算法实现对染病变色松树的自动识别,与传统受害木识别方法不同,本文考虑了其他枯死树和红色阔叶树对受害木识别的影响。实验结果表明,根据受害木的冠幅大小修改区域生成网络中的锚框(anchor)尺寸,并考虑其他枯死树和红色阔叶树的影响,有利于提高受害木识别效果和检测精度。改进后受害木识别总体精度从 75.64% 提高到 82.42%,提高了 6.78 个百分点,能够满足森林防护人员对受害木定位处理的需求。通过坐标转换的方式得到受害木的精确位置信息与空间分布情况,结合点位合并过程,最终正确定位出 494 棵受害木。本文通过无人机遥感结合目标检测算法能监测松材线虫病的发生和获取受害木的分布情况,可为松材线虫病的防控提供技术支持。

关键词: 松材线虫病; 无人机影像; Faster R - CNN; 目标识别; 定位

中图分类号: S763; TP391 文献标识码: A 文章编号: 1000-1298(2020)07-0228-09

OSID:



Detection and Location of Pine Wilt Disease Induced Dead Pine Trees Based on Faster R - CNN

XU Xinluo¹ TAO Huan² LI Cunjun² CHENG Cheng² GUO Hang¹ ZHOU Jingping²

(1. School of Information Engineering, Nanchang University, Nanchang 330031, China

2. Beijing Research Center for Information Technology in Agriculture, Beijing 100097, China)

Abstract: Pine wilt disease (PWD) is a devastating infectious disease for the rapid spread, short disease period, and strong pathogenic ability. At present, detecting the PWD induced dead pine trees (DPT) timely and then taking corresponding measures are vital to control the spread of PWD. An unmanned aerial vehicle (UAV) platform equipped with the Vis - RGB digital camera was used to obtain the ultra-high spatial resolution images. Deep learning object detection of Faster R - CNN was adopted to detect the DPT automatically. Different from the previous research on the DPT identification, the influences of other dead trees and red broad-leaved trees on DPT identification were considered. The results showed that Faster R - CNN can effectively identify the DPT. The 6.78 percentage points detection accuracy of the DPT would be improved when taking the anchor size, other dead trees and red broad-leaved trees into consideration. The overall accuracy of DPT detection can reach 82.42%, which can meet the protector for felling of the DPT. Finally, the position of predicted DPT was calculated accurately using coordinate transformation. Combined with the point combination process, 494 DPT were correctly located. This research had the advantages of low cost, high efficiency and automatic identification, and can provide technical support for the prevention and control of PWD. The combination of UAV remote sensing and object detection algorithms was a promising method to monitor the occurrence of PWD and the distribution of the DPT, which provided important basis for the consequence harmless treatment of PWD induced DPT.

Key words: pine wilt disease; unmanned aerial vehicle image; Faster R - CNN; object detection; location

收稿日期: 2019 - 11 - 06 修回日期: 2019 - 12 - 11

基金项目: 国家自然科学基金项目(41571423, 41764002)

作者简介: 徐信罗(1995—),男,实习研究员,主要从事智能控制和深度学习智能识别研究, E-mail: xuxinluo@163.com

通信作者: 陶欢(1989—),男,助理研究员,主要从事 GIS 在林业和生态中的应用研究, E-mail: taoh.11s@igsrr.ac.cn

0 引言

松材线虫病是松树的毁灭性病害,具有很强的传染性,主要通过传播媒介松墨天牛^[1](*Monochamus alternatus*)进行扩散。松树一旦感染此病(以下称为“受害木”),从出现症状到死亡只需40 d左右,整片松林的毁灭只需3~5年^[2]。KIYOHARA等^[3]进行了大规模的接种试验,于1971年首次证实了松材线虫(Pine wilt nematode, PWN)对松树的致病性。在分子植物病理学中,松材线虫是十大植物寄生线虫之一^[4]。松树染病后,其针叶由有光泽的绿色变为黄褐色乃至红褐色,直至最后枯萎死亡^[5]。松材线虫病起源于北美洲,之后传播至日本^[6]。我国自1982年在南京中山陵首次发现感染松材线虫病的黑松^[7]后,该病在我国不断扩散,并造成大量松树死亡。据国家林业和草原局2019年2月1日发布的松材线虫病疫区公告,全国范围内松材线虫病疫区已扩散至18个省的588个县,新增疫区282个,发生面积64.93万 hm^2 ^[8]。据不完全统计,30多年来,全国因松材线虫病致死的松树累计达数十亿株,造成了上千亿元直接和间接的经济损失。

杀灭松材线虫病的传播媒介松墨天牛是目前防控松材线虫病的主要手段,最有效的措施是直接对受害木进行砍伐,然后对其进行熏蒸、焚烧或微波加热等无害化处理^[9],也可采用悬挂诱捕器^[10-11]和投放天敌的方式。疫情调查是松材线虫病防控的工作基础,现有受害木的监测手段主要有地面调查^[12]、卫星遥感监测^[13-14]和无人机遥感监测^[15-20]。地面调查和卫星遥感监测有其局限性。无人机遥感具有灵活性高、应用周期短、时间和空间分辨率高、成本低、操作简便等优点^[21],目前已在森林资源调查、森林火灾监测、森林病虫害监测防治、森林信息提取等方面得到广泛应用^[21-23]。在受害木的检测中,使用无人机遥感既能节省大量的人力和物力,又能克服空间分辨率的限制,达到监测单株受害木的目的。

基于无人机的受害木识别已有大量的研究报道。李卫正等^[15]用无人机获取高空间分辨率的松林影像,正射处理后导入Geo Link软件,通过目视判读寻找受害木。吕晓君等^[16]根据感病松树树冠颜色的变化,对无人机采集的数字正射图像进行目视判读。利用人工对无人机影像中的受害木进行判读,效率低且主观性强。陶欢等^[17]对获取的无人机影像采用HSV(色调、饱和度、明度)阈值法实现变色松树的识别,能有效提高人工判断的效率。随着

图像分析技术的发展,刘遐龄等^[18]用无人机获取高分辨率影像,采用多模板识别法对不同染病阶段的受害木进行识别,结果表明,相比于目视判读,模版匹配方法能有效提高受害木的检测效率。当机器学习成为研究热点后,一些研究者尝试使用机器学习的方法对受害木进行检测^[19-20]。

基于深度学习的Faster R-CNN^[24]目标检测算法在番茄^[25]、船^[26-27]、鸟^[28]和飞机^[27-29]等物体的检测中都取得了较好的效果。Faster R-CNN是一种基于区域建议的目标检测算法,在Fast R-CNN^[30]和R-CNN^[31]算法基础上改进后提出。与基于回归的SSD^[32]和YOLO^[33]等目标检测算法相比,Faster R-CNN算法的检测精度更高^[34]。目前,在受害木的识别中尚未见使用深度学习的方法。本文提出基于深度学习的高空间分辨率无人机遥感影像的受害木自动检测方法,同时考虑因其他原因(干旱或自然死亡等)致死的松树(以下称为“其他枯死树”)和红色阔叶树对受害木识别的影响,使用包含受害木、其他枯死树和红色阔叶树的数据集对模型进行训练,以达到提高受害木识别效果和检测精度的目的。

1 研究区概况

研究区位于福建省晋江市紫帽镇(24.87°~24.91°N,118.47°~118.53°E),如图1a所示,该地区为松材线虫病重疫区^[8]。所选区域的总面积为4.25 km^2 ,最高海拔为517.8 m,如图1b所示。晋江市属于亚热带季风气候,夏季长冬季短,年平均光照时间为2100 h,年平均温度为20~21℃,七、八月是温度最高的2个月(平均气温27.8~29.4℃)。年平均降水量为911~1231 mm,降雨主要集中在夏季,夏季以西南风为主,其他季节盛行东北风。在现有森林资源中,松林面积16 km^2 ,占全市林分总面积的26.15%。晋江市于2015年秋季和2016年春季开展松材线虫病及受害木普查,紫帽镇为重点调查区域且该区域的疫情较为严重。由于寄主植物(松树)和寄主昆虫(松墨天牛)的存在以及舒适的生存环境,松材线虫病在该区域呈爆发式传播。

2 材料与方法

2.1 数据获取与预处理

使用QK-4071型无人机(配备包含红、绿、蓝3个光谱的SONY A5100型数码相机)获取研究区域的影像,将全球导航卫星系统(Global navigation satellite system, GNSS)和惯性测量单元(Inertial measurement unit, IMU)模块整合到无人机平台,确

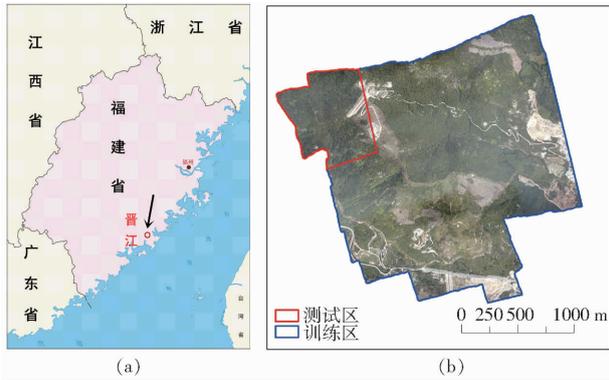


图1 研究区域

Fig.1 Research area

保水平和垂直方向的位置误差在 2 m 和 5 m 左右。数码相机的镜头与位置和方向系统 (Position and orientation system, POS) 信息的记录同步, 以确保将 POS 信息附加到每幅图像上。

首先从 Google Earth 卫星影像中了解研究区域的地理情况并根据天气情况制定相应的飞行计划。然后在 2018 年 3 月 11—13 日利用无人机获取影像, 在晴朗无风条件下共飞行了 13 架次, 分别为: 3 月 11 日 11:00—16:00, 飞行 5 架次; 3 月 12 日 11:00—16:00, 飞行 4 架次; 3 月 13 日 10:00—13:00, 飞行 4 架次。考虑到实际地形、植被状况以及所需覆盖的区域, 将无人机飞行的相对高度设置为 300 m, 每次飞行的航向重叠率和旁向重叠率分别为 60% 和 50%。每次飞行后, 检查每幅影像的数据质量, 将无效影像删除并再次拍摄。最后使用 Pix-4D 软件进行图像校准和镶嵌, 得到空间分辨率为 8.47 cm 的数字正射模型 (Digital orthogonal model, DOM) 影像, 利用 ENVI 软件对影像进行增强。使用无人机自身携带的差分自动驾驶仪可以精确给出每幅影像中心点经纬度坐标, 再结合无人机航向、姿态数据和相机参数, 可精确给出影像上每个像元的坐标信息, 为受害木的定位提供准确位置信息。

2.2 数据集准备

受害木表现出红褐色的颜色特征, 在无人机影像上与绿色的健康松树存在明显的色差。通过 2018 年 4 月 1—3 日的地面调查以及对无人机影像的分析发现, 研究区域存在一些颜色、纹理与受害木相近的树木, 比如其他枯死树, 此类松树以灰褐色为主; 红色阔叶树呈黄褐色, 此类树木与枯死树颜色最为相近, 3 种树木的无人机影像和实地图像如表 1 所示。其他枯死树和红色阔叶树没有松材线虫病, 故无需对其进行处理, 但这两种树木对受害木的识别会造成一定干扰。

首先将研究区划分为训练区和测试区, 如图 1b

表 1 3 种树木的无人机影像和实地图像

Tab.1 UAV images and field photos of three trees

地物类型	无人机影像	实地图像
单株受害木		
其他枯死树		
红色阔叶树		

所示, 蓝色区域为训练区, 红色区域为测试区。选择较大的区域作为训练区, 是为了保证深度学习模型学习到足够多的特征信息。然后对训练区和测试区进行影像裁剪, 人工对训练区内的受害木进行标注并裁剪图像 (256 × 256, 图像尺寸单位为像素, 下同), 在训练区共采集到 1 283 幅图像, 按 8:2 的比例将训练区的图像随机分成训练集和验证集, 训练集包含 1 026 幅图像, 验证集包含 257 幅图像。通过 ArcGIS 软件中的 Split Raster 工具将测试区的图像裁剪为 256 × 256, 共采集到 279 幅图像。由于其他枯死树和红色阔叶树的存在, 故将这两种树木与受害木同时用于模型训练, 则该数据集包括受害木、其他枯死树和红色阔叶树 3 类树木。在使用 LabelImg 软件制作与图像一一对应的可扩展标记语言 (XML) 文件时, 将 3 种类型的树木都做上标记, 将该数据集称为数据集 1。此外, 建立只包含受害木信息的数据集, 即在制作 XML 文件时只对图像中受害木进行标记, 将该数据集称为数据集 2, 用于验证在考虑了其他枯死树和红色阔叶树后是否有助于提高受害木的检测精度。数据集 1 中各类树木的统计情况如表 2 所示, 除受害木外, 研究区内的其他枯死树数量相对较多, 而红色阔叶树数量较少, 整个区域共标记 2 102 棵受害木、778 棵其他枯死树和 192 棵红色阔叶树, 而数据集 2 只包含表 2 中的受害木部分。

表 2 数据集 1 中各类树木的统计结果

Tab.2 Statistical results of various types of trees

集合分类	in dataset 1			棵
	受害木	其他枯死树	红色阔叶树	
训练集	1 236	487	134	
验证集	294	151	40	
测试集	572	140	18	
总计	2 102	778	192	

2.3 研究方法

2.3.1 受害木识别算法的整体框架

Faster R-CNN 的整体框架如图 2 所示,其中 FC 表示全连接层,Conv 表示卷积层。Faster R-CNN 目标检测算法主要分为两部分,分别是区域生成网络 (Region proposal network, RPN) 和 Fast R-CNN。Faster R-CNN 通过共享卷积的方式将这两部分连接起来。使用 VGG16^[35] 作为特征提取网络并使用线性整流函数 (Rectified linear unit, ReLU) 作为激活函数,VGG16 包含 13 个卷积层、5 个最大池化层和 3 个全连接层。当输入的无人机遥感图像经过 VGG16 特征提取网络后,会对受害木、其他枯死树和红色阔叶树的特征信息进行提取,并输出特征图。RPN 网络以卷积神经网络输出的特征图作为

输入,并通过滑窗 (尺寸为 3×3) 获得锚框,锚为每个滑窗的中心,结合不同尺寸和比例的区域建议,每个锚产生 9 个不同的锚框,然后输出一系列可能包含受害木、其他枯死树和红色阔叶树的矩形候选框和相应的候选框得分。由于 RPN 产生的区域候选框的尺寸不同,故使用 RoI Pooling 层将不同尺寸的区域候选框映射成固定尺寸后输入全连接层, RoI Pooling 以特征提取网络输出的特征图和 RPN 网络输出的区域候选框作为输入。最后利用 Softmax 层对每个候选框进行分类并输出所属类别的得分;同时利用边框回归获得每个候选框相对实际位置的偏移量预测值,用于修正候选框的位置,以得到更精确的受害木边界框。

在原始的 RPN 网络中,锚框是基于多尺寸

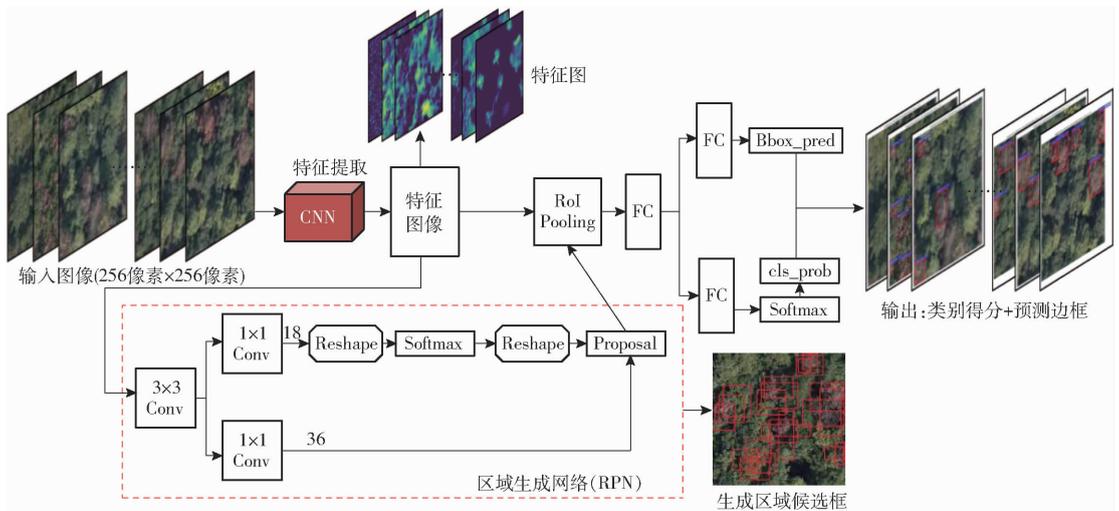


图 2 Faster R-CNN 整体框架

Fig. 2 Overall framework of Faster R-CNN

($\{128^2, 256^2, 512^2\}$) 和多比例 ($\{1:1, 1:2, 2:1\}$) 产生的。PASCAL VOC 数据集中的图像尺寸和目标尺寸都比较大,则原始的锚框尺寸适合于该数据集,并能取得较好的实验结果。根据实际情况对数据集中受害木的冠幅面积进行统计分析,由于 3 类树木的冠幅尺寸相近,故只对受害木的冠幅进行统计。由图 3 可以看出,冠幅面积主要在 $10^2 \sim 60^2$ 之间,且在 30^2 左右最为集中,原始锚框的像素面积尺寸远远超过了本数据集中受害木冠幅的尺寸,因此将锚框的尺寸修改为 $\{16^2, 32^2, 64^2\}$,使之能达到更好的识别效果。

2.3.2 坐标转换与点位合并

为了方便森林防护人员及时了解受害木的分布情况并进行高效率的处理工作,需给出模型预测结果中受害木的平面坐标信息并以点的形式在测试区域中标出。模型的输出结果包含预测边界框的像素位置信息,即相对于图像左上角的像素坐标信息,结果用 4 个数值表示预测边界框的位置,分别是左上

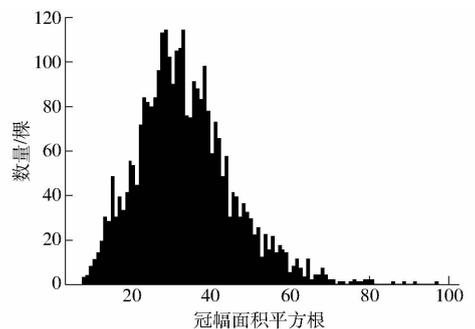


图 3 冠幅面积统计

Fig. 3 Crown area statistics

角和右下角的像素坐标值 x_{imin} 、 y_{imin} 、 x_{imax} 、 y_{imax} 。因此需要将预测边界框中心点的像素坐标转换为平面坐标点信息,然后用 ArcGIS 软件进行标点,所选用的坐标系为 WGS_1984_UTM_zone_50N。

图 4a 中的 XY 坐标系为平面坐标系,xy 坐标系为像素坐标系,大的矩形框表示图像,小的矩形框表示图像中的某一预测边界框。结合图像获取和图像裁剪过程,可知每幅图像中心点 (X_0, Y_0) 的平面坐

标,然后根据 (X_0, Y_0) 计算每个预测边界框的中心点的平面坐标。首先计算图像左上角的平面坐标值

$$\begin{cases} X_{01} = X_0 - \frac{1}{2}L \\ Y_{01} = Y_0 - \frac{1}{2}b \end{cases} \quad (1)$$

其中

$$L = b = 21.69 \text{ m}$$

式中 L ——图像长度所表示的实际地理长度, m

b ——图像宽度所表示的实际地理宽度, m

(X_{01}, Y_{01}) ——图像左上角的平面坐标, m

然后计算图像中预测边界框中心点像素坐标值

$$\begin{cases} x_i = \frac{1}{2}(x_{i\min} + x_{i\max}) \\ y_i = \frac{1}{2}(y_{i\min} + y_{i\max}) \end{cases} \quad (2)$$

式中 i ——图像上预测框的序号

(x_i, y_i) ——边界框中心点像素坐标

最后将预测框中心点的像素坐标转换为平面坐标

标

$$\begin{cases} X_i = x_i \Delta x + X_{01} \\ Y_i = y_i \Delta y - Y_{01} \end{cases} \quad (3)$$

其中

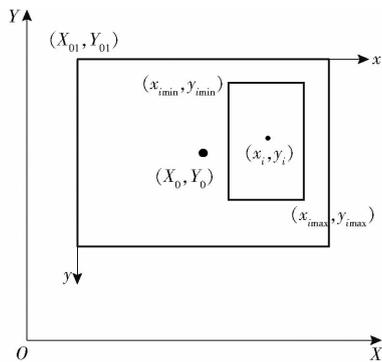
$$\Delta x = \Delta y = 8.47 \text{ cm}$$

式中 Δx ——水平方向上的空间分辨率, cm

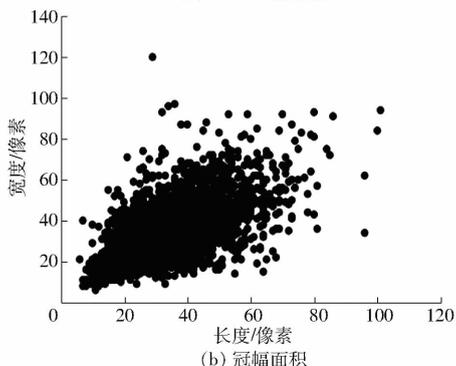
Δy ——垂直方向上的空间分辨率, cm

(X_i, Y_i) ——第 i 个预测边界框中心点平面坐标, cm

由此可得到每个预测边界框中心点的平面坐标。



(a) XY平面坐标系



(b) 冠幅面积

图4 坐标转换与点合并

Fig.4 Coordinate transformation and point combination

在对无人机影像进行裁剪的过程中可能将某一棵受害木切割到两幅甚至更多幅子图像中,故在定位结果中会存在某一棵受害木同时由两个以上点位表示的情况。为了避免这种情况,需要对同时表示一棵受害木的多个点进行合并。通过对整个测试区域的分析发现,受害木的分布较为离散,不存在连片的受害木;对受害木的冠幅尺寸进行分析,由图4b可以看出,冠幅的长、宽主要集中在80像素以内,再结合空间分辨率8.47 cm,故将点位合并的欧氏距离阈值设置为3.40 m。合并后的点位坐标值为原来各点位的平均坐标值。

2.4 Faster R-CNN 模型训练

2.4.1 实验平台和参数设置

实验操作平台为 Ubuntu16.04 计算机, Intel Core i7-3770 CPU@3.40 GHz, 8 位英特尔处理器, NVIDIA GeForce GTX 1080Ti GPU, 使用 TensorFlow 作为深度学习框架。在参数设置方面,迭代次数设置为40 000次,初始学习率设为0.001,每次迭代训练图像的数量(batch size)为256,学习率的衰减系数(γ)和动量分别为0.1和0.9^[25],非极大值抑制(NMS)的阈值为0.7^[29],置信度阈值设置为0.8。

2.4.2 评价指标

为了定量评价模型的性能,采用交并比(Intersection over Union, IoU)、准确率 P (Precision)、召回率 R (Recall)、总体精度 F1 值和平均精度 (Average precision) 作为评价指标。

(1) 交并比

交并比定义为模型预测边界框与真实标记框的重叠比率,用于评价目标是否被准确预测,结果越趋近于1表示预测越准确。计算公式为

$$I = \frac{A(B_{\text{pred}} \cap B_{\text{truth}})}{A(B_{\text{pred}} \cup B_{\text{truth}})} \quad (4)$$

式中 I ——交并比 A ——面积函数

B_{pred} ——预测边界框的区域

B_{truth} ——真实标记框的区域

(2) 召回率和准确率

R 和 P 的计算依赖于正确检测 (TP)、错检 (FP) 和漏检 (FN) 3 个参数。如果某一预测边界框与同类的真实标记框的交并比大于某一确定的阈值 (本研究中 I 设定为 0.5)^[27], 则将该预测边界框定义为 TP, 即为正确检测。否则将该预测框定义为 FP, 即为错检。如果某个真实标记框找不到相应的预测边界框与之相匹配, 则将这一真实标记框定义为 FN, 即为漏检。 P 和 R 的计算公式为

$$P = \frac{T_p}{T_p + F_p} \times 100\% \quad (5)$$

$$R = \frac{T_p}{T_p + F_N} \times 100\% \quad (6)$$

式中 T_p ——正确检测的样本数量

F_p ——错误检测的样本数量

F_N ——漏检样本数量

P 表示在某个类别的所有预测结果中,正确检测的比例。 R 表示在某个类别的所有真实标记框中,正确检测的比例。

(3) 总体精度和平均精度

F1 值^[35]用于评价模型的整体性能,计算公式为

$$F_1 = 2 \frac{PR}{P+R} \quad (7)$$

式中 F_1 ——总体精度

F1 值为 P 和 R 的调和平均数,在 0(最差)和 1(最佳)之间变化。

平均精度是评价模型性能的重要指标,计算公式为

$$I_{AP} = \int_0^1 PdR \quad (8)$$

式中 I_{AP} ——平均精度

若一个模型在不同的 R 下都能保持较高的 P , 则 I_{AP} 就越高,说明模型对此类检测的表现较好。

3 实验结果

3.1 受害木识别

将由数据集 1 训练得到的模型对测试集进行测试,得到的受害木 I_{AP} 为 78.42%,其他枯死树和红色阔叶树的 I_{AP} 分别为 63.27% 和 33.20%,红色阔叶树的 I_{AP} 较低,可能与其样本量相对较少有关。本研究以受害木的识别为重点,由于其他枯死树和红色阔叶树不带有松材线虫病,且不需要森林防护人员进行及时清理,故对这两种树木的检测结果不做具体分析。

该模型检测的各类树木的准确率、召回率和 F1 值的计算结果如表 3 所示,模型从 572 棵受害木中正确检测出 504 棵,漏检了 68 棵,其召回率达到了 88.11%,受害木漏检率为 11.89%;模型误判了 147 棵受害木,原因是将其他枯死树和红色阔叶树误判为受害木,其准确率为 77.42%;模型识别受害木的总体精度为 82.42%。

模型训练过程中损失值(Loss)随迭代次数变化的曲线如图 5 所示。模型的迭代次数为 40 000 次,在模型训练的初始阶段其 Loss 值保持在一个较高的水平,随着迭代次数的增加,Loss 值存在一个缓慢振荡下降的过程,当迭代到 25 000 次之后,Loss 值

表 3 准确率、召回率和 F1 值的计算结果

Tab.3 Calculation results for precision, recall and

F1 scores			
参数	受害木	其他枯死树	红色阔叶树
检测到的目标数量/棵	651	94	9
真实目标数量/棵	572	140	18
T_p /棵	504	76	5
F_p /棵	147	18	4
F_N /棵	68	64	13
P /%	77.42	80.85	55.56
R /%	88.11	54.29	27.78
F1 值/%	82.42	64.95	37.04

基本趋于稳定且不再下降。总体来说,Loss 曲线相对平滑且最终 Loss 值保持在 0.14 左右。

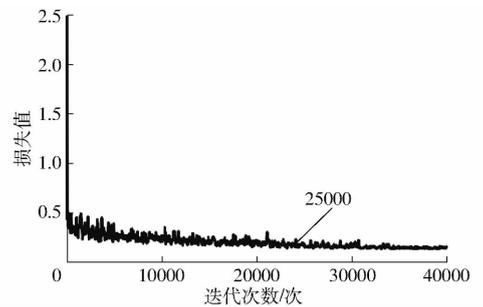


图 5 Faster R-CNN 训练时的损失值曲线

Fig.5 Loss curve of Faster R-CNN training

3.2 受害木定位

从模型的预测结果中筛选出所有被正确检测的受害木共 504 棵,然后将每个受害木预测边界框的位置信息通过式(1)~(3)转换得到其在平面坐标系中的点位坐标,并将点位坐标通过 ArcGIS 软件在测试区域以点的形式标出。最后,通过设定的点位合并阈值将表示同一棵受害木的多个点位进行合并,最终正确定位出 494 棵受害木,点位合并过程如图 6a 所示。最终的受害木定位结果如图 6b 所示。

4 讨论

使用只包含受害木信息的数据集 2 进行模型训练与检测。此外,使用原始锚框尺寸($\{128^2, 256^2, 512^2\}$)对 2 个数据集进行检测实验,所有实验使用的平台和参数设置都一致。表 4 为在不同模型下测试得到的 I_{AP} ,表 5 为不同模型下受害木检测的准确率、召回率和 F1 值。对比表 4 中模型 1、3 和模型 2、4 发现,在相同的锚框尺寸下,数据集 1 训练模型比数据集 2 训练模型的受害木的 I_{AP} 分别高 5.38 个百分点和 6.14 个百分点;同理,表 5 中模型 1、2 比模型 3、4 的 F1 值分别提高了 5.22 个百分点和 6.10 个百分点,此外准确率和召回率都有不同程度的提高;结果表明,由数据集 1 训练的模型在受害木识别



(a) 定位合并过程



(b) 定位结果

图 6 受害木定位合并过程与定位结果分布图

Fig. 6 DPT positioning process and result distribution map

表 4 不同模型的 I_{AP}

Tab. 4 I_{AP} values of different models %

模型序号	数据集	基础锚框尺寸	受害木	其他枯死树	红色阔叶树
1	1	{16 ² , 32 ² , 64 ² }	78.42	62.37	32.20
2	1	{128 ² , 256 ² , 512 ² }	75.74	50.95	28.66
3	2	{16 ² , 32 ² , 64 ² }	73.04		
4	2	{128 ² , 256 ² , 512 ² }	69.60		

表 5 受害木在不同模型下的准确率、召回率和 F1 值

Tab. 5 Precision, recall and F1 score values for DPT under different models %

模型序号	数据集	基础锚框尺寸	P	R	F1 值
1	1	{16 ² , 32 ² , 64 ² }	77.42	88.11	82.42
2	1	{128 ² , 256 ² , 512 ² }	77.17	86.89	81.74
3	2	{16 ² , 32 ² , 64 ² }	77.14	77.27	77.20
4	2	{128 ² , 256 ² , 512 ² }	76.30	75.00	75.64

上有更好的表现和检测精度。对比表 4 中模型 1、2 和模型 3、4 发现,在相同的数据集下,根据实际目标大小将锚框尺寸修改为 {16², 32², 64²} 后,受害木的 I_{AP} 分别提高了 2.68 个百分点和 3.34 个百分点,且模型 1 中其他枯死树和红色阔叶树的 I_{AP} 均高于模型 2,该结果与 REN 等^[29] 在小目标检测中根据真实目标大小修改锚框尺寸后得到的实验结果一致;同理,表 5 中模型 1、3 比模型 2、4 的受害木的 F1 值分

别提高了 0.68 个百分点和 1.56 个百分点,准确率和召回率同样有小幅度的提高。结果表明,在使用基于深度学习的目标检测技术对受害木进行检测时,根据受害木冠幅大小修改锚框尺寸后将松林中存在的其他枯死树和红色阔叶树的样本信息加入数据集并用于模型训练,能提高受害木识别效果和检测精度。

使用目标检测技术对受害木进行识别能达到较好的检测精度,同时也会引起漏检和误判。最理想的检测结果如图 7a 所示,图中 5 棵受害木均能被正确检测出。图 7b 中有 2 棵受害木,模型正确检测出了 1 棵,漏检了 1 棵。图 7c 显示的是将其他枯死树误判为受害木的情况,除了将 1 棵其他枯死树误判为受害木外,模型正确检测出了其余受害木。图 7d 是将红色阔叶树误判为受害木的情况,模型将图中受害木和其中一棵红色阔叶树正确检测出来的同时,将另一颗红色阔叶树误判为受害木。误判的原因可能是其他枯死树和红色阔叶树的颜色特征相近。图 7 中 deadpinetrees 表示受害木, otherdeadtrees 表示其他枯死树, redbroadleavedtrees 表示红色阔叶树,黄色矩形框表示漏检,黑色矩形框表示误判。

使用深度学习的方法对受害木进行识别, F1 值能达到 82.42%, 能够满足森林防护人员对受害木实地砍伐的要求。与传统的目视判读方法相比该方法能极大地提高受害木的识别效率并且能做到自动识别。与陶欢等^[17] 提出的 HSV 阈值法的总体精度 (58% ~ 65%) 相比,检测精度有明显的提高。本研究的精度略低于刘遐龄等^[18] 提出的模板匹配方法的正确率 (83.9%), 但本研究考虑了其他枯死树和红色阔叶树的存在,精度的可靠性更高。使用深度



(a) 受害木正确检测

(b) 受害木漏检



(c) 将其他枯死树误判为受害木

(d) 将红色阔叶树误判为受害木

图 7 模型 1 检测结果可视化

Fig. 7 Model 1 detection results visualization

学习方法检测受害木能充分发挥计算机识别速度快的优点,从而达到及时检测的目的。最后通过坐标转换的方法对预测结果中的受害木进行定位,能提供每棵受害木精确的位置信息及总体分布情况,为森林防护人员寻找和清除染病松树提供了技术支持,且能有效提高工作效率。本研究利用无人机遥感技术对松材线虫病进行监测并使用目标检测算法对染病松树进行识别,表明通过结合无人机遥感和目标检测算法能监测松材线虫病的发生现状和染病松树的分布情况,为后续的实时处理提供了依据,具有重要的现实意义。

松树感染松材线虫病是一个动态过程,不同的染病阶段症状不尽相同^[37-38],染病初期只有少量松树针叶褪色发黄,染病中期大部分针叶变为黄褐色,染病后期全部针叶变为黄褐色或红褐色^[18]。本方法根据颜色特征只能识别出中后期的染病松树,无法检测颜色变化较小的染病初期的松树,因此不能全面对染病松树进行检测。在今后的研究中将采用

高光谱数据进行实验。

5 结束语

使用无人机遥感技术获取超高空间分辨率的松林影像,并结合深度学习的目标检测技术对受害木进行检测,能有效提高受害木的识别效率,且具有较高的检测精度。当根据受害木冠幅的实际尺寸修改RPN网络中的锚框尺寸后,在数据集中加入其他枯死树和红色阔叶树的样本信息,能提高受害木的识别效果和检测精度,受害木识别的总体精度达到82.42%。使用坐标转换的方法对预测结果中的受害木进行定位,结合点位合并过程,最终正确定位出494棵受害木。本文方法能及时发现染病松树,并确定其分布情况,有效监测松材线虫病疫情的发展动态,可为松林管理人员和森林防护人员及时提供准确的信息,同时也为松材线虫病灾害损失评估和松林管理部门制定松材线虫病防控目标等提供客观依据。

参 考 文 献

- [1] 杨宝君,潘宏阳,汤坚,等. 松材线虫病[M]. 北京:中国林业出版社,2003.
- [2] ZHAO B G. Pine wilt disease in China[M]. Tokyo: Springer,2008:18-25.
- [3] KIYOHARA T, TOKUSHIGE Y. Inoculation experiments of a nematode, *Bursaphelenchus* sp., onto pine trees[J]. Journal of the Japanese Forestry Society, 1971, 53(7): 210-218.
- [4] JONES J T, HAEGEMAN A, DANCHIN E G, et al. Top 10 plant-parasitic nematodes in molecular plant pathology[J]. Molecular Plant Pathology, 2013, 14(9): 946-961.
- [5] 王玉嫵. 松树萎蔫线虫病[J]. 植物检疫, 1986(3): 46-51.
- [6] 叶建仁. 松材线虫病在中国的流行现状、防止技术与对策分析[J]. 林业科学, 2019, 55(9): 1-9.
YE Jianren. Epidemic statuses of pine wilt disease in China and its prevention and control techniques and counter measures[J]. Scientia Silvae Sinicae, 2019, 55(9): 1-9. (in Chinese)
- [7] 孙永春. 南京中山陵发现松材线虫[J]. 江苏林业科技, 1982(4): 47,27.
- [8] 国家林业和草原局. 国家林业和草原局公告(2019年第4号)(2019年松材线虫病疫区)2019[EB/OL]. (2019-02-01)[2019-11-03]. <http://www.forestry.gov.cn/main/3457/20190424/162731641935736.html>.
- [9] 徐将. 松材线虫病疫木就地覆盖熏蒸除害处理技术研究[J]. 现代农业科技, 2017(12): 150-151.
XU Jiang. Study on the treatment technology of fumigation and detoxification of pine wood nematode disease[J]. Modern Agricultural Science and Technology, 2017(12): 150-151. (in Chinese)
- [10] 陈元生,罗致迪,赖福胜,等. 松褐天牛引诱剂及诱捕器色泽筛选试验[J]. 中国植保导刊, 2014, 34(12):44-46.
- [11] FOIT J, ČERMÁK V, GAAR V, et al. New insights into the life history of *Monochamus galloprovincialis* can enhance surveillance strategies for the pinewood nematode[J]. Journal of Pest Science, 2019, 92(3): 1203-1215.
- [12] WULDER M A, DYMOND C C, WHITE J C, et al. Detection, mapping, and monitoring of the mountain pine beetle[M]. Victoria: Natural Resources Canada, 2006:123-154.
- [13] SEUNG-HO L, HYUN-KOOK C, WOO-KYUN L, et al. Detection of the pine trees damaged by pine wilt disease using high resolution satellite and airborne optical imagery[J]. Korean Journal of Remote Sensing, 2007, 23(5): 409-420.
- [14] KIM S R, LEE W K, LIM C H, et al. Hyperspectral analysis of pine wilt disease to determine an optimal detection index[J]. Forests, 2018, 9(3): 115-127.
- [15] 李卫正,申世广,何鹏,等. 低成本小型无人机遥感定位病死木方法[J]. 林业科技开发, 2014, 28(6): 102-106.
LI Weizheng, SHEN Shiguang, HE Peng, et al. A precisely positioning technique by remote sensing the dead trees in stands with inexpensive small UAV[J]. Journal of Forestry Engineering, 2014, 28(6): 102-106. (in Chinese)
- [16] 吕晓君,王君,喻卫国,等. 无人机监测林业有害生物初探[J]. 湖北林业科技, 2016, 45(4): 30-33.
LÜ Xiaojun, WANG Jun, YU Weiguo, et al. Study on monitoring forest pests and diseases by unmanned aerial vehicle[J]. Hubei Forestry Science and Technology, 2016, 45(4): 30-33. (in Chinese)
- [17] 陶欢,李存军,谢春春,等. 基于HSV阈值法的无人机影像变色松树识别[J]. 南京林业大学学报(自然科学版), 2019, 43(3): 99-106.
TAO Huan, LI Cunjun, XIE Chunchun, et al. Recognition of red-attack pine trees from UAV imagery based on the HSV

- threshold method[J]. Journal of Nanjing Forestry University (Natural Sciences), 2019, 43(3): 99–106. (in Chinese)
- [18] 刘遐龄,程多祥,李涛,等. 无人机遥感影像的松材线虫病危害木自动监测技术初探[J]. 中国森林病虫,2018, 37(5): 16–21.
LIU Xialing, CHENG Duoxiang, LI Tao, et al. Preliminary study on automatic monitoring trees infected by pine wood nematode with high resolution images from unmanned aerial vehicle[J]. Forest Pest and Disease, 2018, 37(5): 16–21. (in Chinese)
- [19] 胡根生,张学敏,梁栋,等. 基于加权支持向量数据描述的遥感图像病害松树识别[J/OL]. 农业机械学报,2013, 44(5): 258–263,287.
HU Gensheng, ZHANG Xuemin, LIANG Dong, et al. Infected pine recognition in remote sensing images based on weighted support vector data description[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(5): 258–263,287. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20130545&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2013.05.045. (in Chinese)
- [20] 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 Yining, LIU Wenping, LUO Youqing, et al. Monitoring of dead trees in forest images based on linear spectral clustering [J]. Scientia Silvae Sinicae, 2019, 55(4): 187–195. (in Chinese)
- [21] 张艳楠. 无人机遥感在林业中的应用[J]. 内蒙古林业调查设计,2017, 40(6): 77–78.
ZHANG Yannan. Application of UAV remote sensing in forestry[J]. Inner Mongolia Forestry Investigation and Design, 2017, 40(6): 77–78. (in Chinese)
- [22] BANU T P, BORLEA G F, BANU C. The use of drones in forestry[J]. Journal of Environmental Science and Engineering, 2016, B5: 557–562.
- [23] TANG L, SHAO G. Drone remote sensing for forestry research and practices[J]. Journal of Forestry Research, 2015, 26(4): 791–797.
- [24] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137–1149.
- [25] SUN J, HE X F, GE X, et al. Detection of key organs in tomato based on deep migration learning in a complex background [J]. Agriculture, 2018, 8(12): 196–211.
- [26] ZHANG S, WU R, XU K, et al. R-CNN-based ship detection from high resolution remote sensing imagery[J]. Remote Sensing, 2019, 11(6): 631–646.
- [27] HAN X, ZHONG Y, ZHANG L. An efficient and robust integrated geospatial object detection framework for high spatial resolution remote sensing imagery[J]. Remote Sensing, 2017, 9(7): 666–688.
- [28] HONG S J, HAN Y, KIM S Y, et al. Application of deep-learning methods to bird detection using unmanned aerial vehicle imagery[J]. Sensors, 2019, 19(7): 1651–1667.
- [29] REN Y, ZHU C, XIAO S. Small object detection in optical remote sensing images via modified Faster R-CNN[J]. Applied Science, 2018, 8(5): 813–824.
- [30] GIRSHICK R. Fast R-CNN[C]//The IEEE International Conference on Computer Vision, 2015: 1440–1448.
- [31] GIRSHICK R, DONAHUE J, DARRELL T, et al. Region-based convolutional networks for accurate object detection and segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(1): 142–158.
- [32] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multiBox detector[C]//European Conference on Computer Vision, 2016: 21–37.
- [33] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]//The IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779–788.
- [34] 孙红,李松,李民赞,等. 农业信息成像感知与深度学习应用研究进展[J/OL]. 农业机械学报,2020,51(5):1–17.
SUN Hong, LI Song, LI Minzan, et al. Research progress of image sensing and deep learning in agriculture [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(5): 1–17. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20200501&flag=1. DOI:10.6041/j.issn.1000-1298.2020.05.001. (in Chinese)
- [35] SIMONYAN K, ZISSERMAN. A very deep convolutional networks for large-scale image recognition [C] // International Conference on Learning Representations, 2015: 1–14.
- [36] KOIRALA A, WALSH K B, WANG Z, et al. Deep learning—method overview and review of use for fruit detection and yield estimation[J]. Computers and Electronics in Agriculture, 2019,162: 219–234.
- [37] 王震,张晓丽,安树杰. 松材线虫病危害的马尾松林木光谱特征分析[J]. 遥感技术与应用,2007, 22(3): 367–370.
WANG Zhen, ZHANG Xiaoli, AN Shujie. Spectral characteristics analysis of *Pinus massoniana* suffered by *Bursaphelenchus xylophilus*[J]. Remote Sensing Technology and Application, 2007, 22(3): 367–370. (in Chinese)
- [38] 徐华潮,骆有庆,张廷廷,等. 松材线虫自然侵染后松树不同感病阶段针叶光谱特征变化[J]. 光谱学与光谱分析, 2011, 31(5): 1352–1356.
XU Huachao, LUO Youqing, ZHANG Tingting, et al. Changes of reflectance spectra of pine needles in different stage after being infected by pine wood nematode[J]. Spectroscopy and Spectral Analysis, 2011, 31(5): 1352–1356. (in Chinese)