

基于多色彩空间的 YOLOv5 松枯死树检测方法

游子绎^{1,2}, 王文瑾³, 邵历江³, 郭丹^{1,2}, 吴松青^{1,2}, 黄世国^{2,3*}, 张飞萍^{1,2}

¹福建农林大学林学院, 福建 福州 350002; ²福州农林大学生态公益重大有害生物防控福建省
高校重点实验室, 福建 福州 350002; ³福建农林大学计算机与信息学院, 福建 福州 350002

摘要:【目的】针对在松枯死树监测实践中,从无人机航拍 RGB 影像中自动识别松枯死树漏检率高的问题,提出了一种生产应用场景下基于多色彩空间的 YOLOv5 松枯死树高精度自动识别新方法。【方法】利用无人机采集大面积松材线虫病发生林分的 RGB 图像,用 Pix4Dmapper 软件拼接,用 LabelImg 开源软件建立 VOC 格式的松枯死树数据集,分别用 Faster R-CNN、YOLOv3、YOLOv4、YOLOv5、SSD 和 EfficientDet 等 6 种基于深度学习的目标检测算法对数据集进行训练和测试,以精确率、召回率、平均准确率以及 F_1 分数作为评价指标筛选出最优目标检测算法;然后将采集的 RGB 图像转换成 LAB 和 HSV 色彩空间图像,再将这 3 个色彩空间的图像分别用最优目标检测算法进行训练,得到目标在每个色彩空间的边界框,使用非极大值抑制算法对这些边界框进行处理,得到最优边界框实现松枯死树自动识别。【结果】6 种算法均取得良好效果,其中 YOLOv5 模型为最优算法,其精准率、平均查准率和 F_1 分数在 6 种算法中均最高,分别达到 97.58%、82.40% 和 0.85。通过 3 个色彩空间融合后,反映漏检情况的召回率由 74.54% 提高到 98.99%,平均准确率提升至 98.39%。【结论】基于多色彩空间的 YOLOv5 模型能够显著提高从无人机航拍 RGB 影像中检测松枯死树的精度,为松枯死树监测提供了有力工具,也有助于松材线虫病的防治。



开放科学标识码
(OSID 码)

关键词: 无人机影像; 松枯死树; 深度学习; 多色彩空间; 松材线虫病

Dead pine detection by multi-color space based YOLOv5

YOU Ziyi^{1,2}, WANG Wenjin³, SHAO Lijiang³, GUO Dan^{1,2}, WU Songqing^{1,2},
HUANG Shiguo^{2,3*}, ZHANG Feiping^{1,2}

¹College of Forestry, Fujian Agriculture and Forestry University, Fuzhou, Fujian 350002, China; ²Key Laboratory of Integrated Pest Management in Ecological Forests, Fujian Province University, Fujian Agriculture and Forestry University, Fuzhou, Fujian 350002, China; ³College of Computer and Information Sciences, Fujian Agriculture and Forestry University, Fuzhou, Fujian 350002, China

Abstract:【Aim】To address the issue of the high misdetection rate from RGB images taken by the UAV in the monitoring practice of pine dead trees, a new YOLOv5 model based on multi-color space is proposed for recognizing pine dead trees precisely.【Method】UAVs were used to collect RGB images of a large-area forest with pine nematode disease. The images were spliced with Pix4Dmapper software, and a dataset detailing pine dead trees in VOC format was established using LabelImg open-source software. Six object detection algorithms based on deep learning, namely Faster R-CNN, YOLOv3, YOLOv4, YOLOv5, SSD, and EfficientDet, were used to train and test the dataset. The optimal object detection algorithm was filtered using precision, recall, average precision (AP), and the F_1 score as evaluation metrics. Then, the collected RGB images were converted into LAB and HSV color space images, and the three color space images were trained with optimal object detection algorithms to obtain the bounding boxes of the target in each color space. These bounding boxes were processed using non-maximum suppression algorithms, and an optimal bounding box was obtained to realize the automatic recognition of dead trees.【Result】All six algorithms have achieved good results, of which the YOLOv5 model was the optimal algorithm. Its precision, AP, and F_1 score were the highest among the six algorithms, reaching 97.58%, 82.40%, and 0.85, respectively. After the fusion of the three color space images, the misdetection was reflected in the re-

收稿日期(Received): 2022-10-12 接受日期(Accepted): 2022-11-28

基金项目: 国家林业和草原局重大应急科技项目(ZD202001); 福建省林业科技项目(闽林文[2021]35号); 福建农林大学科技创新专项基金项目(KFb22097XA)

作者简介: 游子绎, 男, 硕士研究生。研究方向: 无人机遥感。E-mail: 773999158@qq.com

* 通信作者(Author for correspondence), 黄世国, E-mail: fjhsg25@126.com

call rate, which increased from 74.54% to 98.99%, and the AP, which increased to 98.39%. 【Conclusion】 The YOLOv5 model based on multi-color space can significantly improve the accuracy of detecting dead pine trees from RGB images taken by the UAV. The proposed model is a powerful tool for monitoring dead trees and assisting in controlling pine wood nematode disease.

Key words: UAV image; dead pine trees; deep learning; multi-color space; pine wood nematode disease

松材线虫病 *Bursaphelenchus xylophilus* (Steiner et Buhner) Nickle 是一种危害松科植物的林业检疫性有害生物, 已在我国造成较大危害(叶建仁, 2019)。该病主要通过媒介昆虫松墨天牛 *Monochamus alternatus* Hope 扩散蔓延, 而该虫具有选择衰弱、濒死松树产卵的习性。准确监测和定位林分中的松枯死树, 并对其及时进行无害化处理, 是防治松材线虫病的核心措施之一(李成和刘波, 2021)。长期以来我国主要采用地面人工普查、目测方法进行松枯死树的监测定位。然而, 由于山地地形复杂、林层多样、交通不便以及地面人工普查存在成本高、效率低等, 大量的松枯死树不能被及时发现和无害化处理, 已成为影响松材线虫病防治的重要因素之一。

随着无人机和数字图像等技术的快速发展, 利用无人机快速获取林分彩色 (red-green-blue color space, RGB) 遥感影像监测定位野外松枯死树, 具有高效、精准、低成本、受地形因子限制小等优势, 具有广阔的应用前景。但由于无人机获取的影像数据量大, 人工判读存在工作量大、时效性差等问题, 因此, 利用计算机视觉技术自动识别影像中的松枯死树已成为生产应用上亟待解决的问题(地力夏提·包尔汉, 2021)。对此, 国内外进行了大量相关研究, 如: 尹华阳等(2020)采用传统机器学习方法, 利用手工设计的特征通过算子提取松枯死树的特征, 然后应用分类器进行识别, 取得了良好的效果; 陈魏冬(2018)、陶欢等(2019)研究发现, 在“色调—饱和度—明度”(hue-saturation-value, HSV)色彩空间和 LAB (CIE Lab color space) 色彩空间中, 可以识别出在 RGB 色彩空间中无法识别的松枯死树。

随着深度学习技术的逐渐成熟(Dosovitskiy *et al.*, 2020), 利用该方法替代传统的机器学习方法被广泛用于松枯死树的监测研究(Deng *et al.*, 2019)。相较于传统机器学习方法, 深度学习不需要手工提取特征, 而是使用自动设计特征提取的方法, 自动抽取无人机拍摄的松枯死树低层的细节信息和高层的语义信息, 并通过信息融合的方式实现识别, 其识别性能显著高于传统方法。因此, 深度学习算

法等已成为松枯死树识别最重要的方法(李浩等, 2021; 刘顺利等, 2022; Wu *et al.*, 2021)。

尽管将深度学习算法应用于松枯死树的监测研究中取得了很高的精度, 但在实践中还存在一些局限性。首先, 对于松材线虫病防治而言, 全面彻底无害化处置松枯死树是其中关键的环节, 这就要求对松枯死树的监测和识别有高准确率的同时还要有低漏检率。现有研究虽已有了较高的精度, 但是对识别误差的分析表明, 漏检是当前误差的主要来源。其次, 现有研究大多在特定飞行高度、小面积林分等场景下进行, 但由于野外地形的复杂多变, 在野外大面积实践中往往需要提高无人机飞行高度以便提高效率, 这也导致识别的性能降低。造成上述问题的一个重要原因在于现有深度学习算法仅在 RGB 空间进行分析, 对不同颜色空间的信息利用缺乏研究。

鉴于此, 本研究在生产应用实际场景下, 利用无人机采集大面积松材线虫病发生林分的 RGB 遥感影像。在此基础上, 应用多种基于深度学习的目标检测算法识别松枯死树, 在筛选出性能最优算法的基础上, 充分利用不同色彩空间存在的互补作用(Gowda & Yuan, 2018), 进一步挖掘在多个色彩空间的目标检测结果, 达到降低漏检率并提高识别性能的目的, 以期建立一种满足生产实践需求, 能够及时、高效、省时省力地从大面积林分中准确识别松枯死树的技术, 为科学有效防治松材线虫病提供技术支撑。

1 材料与方法

1.1 研究样地与数据采集

本研究设 2 个无人机航拍样地: 样地 1 位于福建省福州市闽侯县鸿尾乡(118.97°E, 26.147°N), 属南方典型丘陵地势, 林地最高点海拔 1037 m, 林分构成以马尾松 *Pinus massoniana* Lamb. 为主, 混有杉木 *Cunninghamia lanceolata* (Lamb.) Hook. 以及多种彩色阔叶树或落叶阔叶树, 该样地松材线虫病发生严重, 松枯死树多; 研究样地 2 位于福建省莆田市仙游县西天尾镇(119.04°E, 25.539°N), 其林

分类型也是马尾松为优势种的马、杉、阔混交林。

2020 年 11 月,松树受害枯死高峰期后,选择晴朗天气采集 2 个研究样地的遥感影像。使用 CW-007 型固定翼无人机搭载 CA-102 型无人机相机(60 mm f/2.0G 定焦镜头,分辨率 7952×5304 像素);根据地势情况确定无人机飞行高度,样地 1 为 400~1200 m,样地 2 为 800 m 左右,飞行速度均为 $20 \text{ m} \cdot \text{s}^{-1}$,均在最优光照条件期间(10:00—15:00)飞行;采用定距曝光的方式航拍采集影像数据。样地 1 采集遥感影像 15 个架次,总计飞行面积约 368.1 km^2 。样地 2 采集遥感影像 2 个架次,总计飞行面积约 32.3 km^2 。遥感影像采集完成后,将每个架次拍摄的影像导入 Pix4Dmapper 软件进行图像拼接,得到包含地理信息的完整航空图像,2 个样地共计获得完整航空图像 17 张。

1.2 数据预处理

将样地 1 每架次用 Pix4D 拼接好的 RGB 遥感影像数据等分为 4096 张图像,共得到 15×4096 张图像。参照李凤迪(2020)的方法,应用 LabelImg 软件使用矩形框人工标注每幅图像中的松枯死树,每个矩形框对应一棵松枯死树样本,并将 red 标签作为松枯死树类别标签,从而得到 VOC 格式数据集。标注示例见图 1。人工标注结果发现,有松枯死树的图像 3436 张,标注得到松枯死树共 9023 棵。在完成标注后,针对样地 1 中连片或多棵松枯死树聚集的样本以及因图像清晰度不高导致无法确定的样本,采用人工地面踏查结合无人机低空巡查对松枯死树标注情况进行实地验证,确保标注准确性和完整性。然后再按照 0.35:0.35:0.30 的比例随机划分训练集、验证集、测试集,对模型进行训练。



图 1 枯死松树样本示例
Fig.1 Sample of dead pine tree

1.3 基于多色彩空间的 YOLOv5 目标检测

采用当前流行的目标检测算法 YOLOv5 作为

松枯死树识别模型。该模型根据残差组件和卷积核数量从少到多可分为 4 个网络结构,即 YOLOv5s、YOLOv5m、YOLOv5l、YOLOv5x。由于航拍时间、天气、地形因素等影响,获取的松枯死树大小、颜色、亮度、纹理、尺度等变化很大,因此使用残差组件和卷积核数量最多的 YOLOv5x 网络结构。该结构通过增加模型深度和宽度提高了网络特征提取和特征融合的能力,能够更好地应对野外松枯死树样本特征复杂多变的情况。

在使用 YOLOv5 算法时,本研究首先对输入图像通过 Mosaic 数据增强(随机选取带标注的 4 张图片,分别对 4 张图片进行翻转、缩放、色域变化等操作,分别进行图片和框的组合),以随机缩放、随机裁剪、随机排布的方式对图片进行拼接,然后将图像按目标检测的通常做法自适应缩放至 608×608 像素。同时,在输入卷积神经网络前,使用 k-means 算法和遗传学习算法自适应地生成与数据集匹配的先验框尺寸,避免人工设计的误差。

采用 CSPDarkNet53 实现特征提取,该网络包括了 Focus 结构、CSP 结构和 SPP 结构。在特征提取前使用 Focus 结构进行切片操作,将图片隔像素取值并按区域划分组合,得到 4 份图像后再按通道融合。融合后的图像经 CBL(conv-bn-leakyrelu)层通过卷积、批量归一化和 Leaky_ReLU 函数激活,提取特定的局部图像特征。YOLOv5 在主干网络(backbone)和模型颈部(neck)2 部分均设计了 CSP_X 结构,本研究使用 CSP1_12 和 CSP2_4 结构。SPP 结构使用滤波器为 5×5 、 9×9 、 13×13 的最大值池化提取不同尺度特征,再将原图和池化后的 3 幅图像叠加。同时,模型颈部使用 FPN+PAN 的结构。经过特征提取和特征融合网络后,得到 3 种不同尺寸的下采样特征图。计算定位损失采用了 GIOU_Loss,对于多目标框筛选采用 DIOU_nms 模块。并最终输出预测结果,从而实现多尺度网络预测。

本研究以迁移学习的方式用 Bdd100k 数据(Yu *et al.*, 2020)学习的权重参数初始化网络,然后对目标数据集从头开始训练,加快并优化模型的学习效率。同时,由于不同色彩空间在松枯死树识别过程中存在互补性,本研究提出在深度学习的晚期阶段结合不同色彩空间的信息以提高识别的性能。具体如下:首先将训练集 RGB 通道图像分别转化为 LAB 通道图像和 HSV 通道图像,之后使用 3 个

色彩通道的图像分别进行训练。训练出 3 个色彩通道的预测模型后,再分别对 3 个色彩通道图像进行预测,汇总不同颜色空间的目标预测边界框,使用非极大值抑制(non-maximum suppression, NMS)算法保留置信度最高的候选框后,过滤交并比(IoU)大于 0.5 的其他候选框,解决松枯死树重复计数的问题,最终实现不同色彩空间的信息利用。

1.4 评价指标

当林分中存在没有被检测发现和无害化处置的松枯死树,将显著降低松材线虫病的防治效果。因此,漏检率(即召回率)即没有被检测到的松枯死树样本数是很重要的一个指标。在现有松枯死树识别研究采用的性能指标中,一般采用平均准确率去综合考虑精确率和召回率,而没有对精确率和召回率作进一步分析(黄丽明等,2021),这导致该类研究的平均精度较高,但漏检情况不明确。因此,

本研究采用精确率(precision)、召回率(recall)、平均准确率(average precision, AP)和 F_1 分数作为模型性能的评价指标。其中,精确率是指正样本预测数占样本预测数的比例;召回率是指正样本预测数占正样本数的比例;平均准确率是指精确率和召回率曲线(P-R 曲线)下的面积,即为不同召回率的情况下所有精确率的平均值; F_1 分数是指精确率和召回率的调和平均,是一种衡量二分类模型精准度的指标,公式如下:

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (1)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (2)$$

$$F_1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (3)$$

式(1)、(2)中 TP、FP、FN 的含义见表 1 混淆矩阵。

表 1 混淆矩阵
Table 1 Confusion matrix

真实情况 Current situation	预测结果 Predicted results	
	正例 Positive example	反例 Negative example
正例 Positive example	TP: True positive (被模型预测为正的正样本)	FN: False negative (被模型预测为负的正样本)
反例 Negative example	FP: False positive (被模型预测为正的负样本)	TN: True negative (被模型预测为负的正样本)

1.5 试验环境

YOLOv5 模型使用 Pytorch 框架实现,CPU 为 Intel Xeon Cascade Lake 8255C (2.5 GHz),内存为 32 GB,GPU 为 Tesla V100。为了说明 YOLOv5 在松枯死树识别中的性能情况,选择几种常见的基于深度学习的目标检测算法进行对比,分别为 Faster R-CNN、YOLOv3、YOLOv4、SSD 和 EfficientDet 等目标检测模型。其中,YOLOv3、YOLOv4、Faster R-CNN 与 SSD 模型已应用到松枯死木识别中,EfficientDet 模型(Tan *et al.*, 2020)是新提出的性能较优的目标检测模型。不同模型采用的框架见表 2,其他参数设置:批量大小 8,训练轮次 300,学习速率 0.001。

1.6 模型验证

为进一步测试模型性能,模拟实际生产应用的场景。本研究在研究样地 1 测试集的基础上,以研究样地 2 为新的测试集,并同样采取人工地面踏查结合无人机低空飞行的方式,对模型预测结果进行验证,根据验证结果对模型性能进行评价。

表 2 不同深度学习算法使用的主干网络

Table 2 Main backbone networks in different deep learning algorithms

深度学习算法 Deep learning algorithm	主干网络 Backbone network
Faster R-CNN	ResNet50
YOLOv3	DarkNet53
YOLOv4	CSPDarkNet53
YOLOv5	CSPDarkNet53
SSD	VGG
EfficientDet	EfficientNet

2 结果与分析

2.1 不同深度学习算法性能比较

采用不同深度学习算法处理样地 1 的数据集,得到 RGB 图像空间下的松枯死树识别精确率、召回率、平均准确率及 F_1 分数见表 3。从表中可以看出,不同算法的精确率高低依次为 YOLOv5 > EfficientDet > YOLOv4 > SSD > YOLOv3 > Faster R-CNN, YOLOv5 模型在所有算法中最高,达到 97.58%,说明该算法能够很好地识别出松枯死树样本,将松枯死树误分为负样本的情况很少。Faster R-CNN 的精确率最低,说明该算法将松树枯死误分为负样本

的情况很多。不同算法的召回率大小次序为 Faster R-CNN>YOLOv5>YOLOv4>SSD>YOLOv3>Efficient-Det,说明 Faster R-CNN 算法将松枯死树漏检的情况较少,而 YOLOv5 算法的漏检率仅比 Faster R-CNN 低,普遍优于其他算法,EfficientDet 则存在严重的漏检情况,说明不同算法在精确率和召回率指

标上有很大差异。不同算法的平均准确率从高到低依次为 YOLOv5>EfficientDet>YOLOv4>Faster R-CNN>SSD>YOLOv3。综合考虑各项评价指标, YOLOv5 是性能最优的算法,其准确率达到 82.40%,在精确率和召回率上取得了较优的平衡。

表 3 不同深度学习算法的性能评价

Table 3 Performance evaluation of different deep learning algorithms

深度学习算法 Deep learning algorithm	精确率 Precision/%	召回率 Recall/%	平均准确率 AP/%	F ₁ 分数 F ₁ score
Faster R-CNN	56.46	80.65	67.68	0.66
YOLOv3	78.14	56.30	50.51	0.65
YOLOv4	86.70	62.52	72.77	0.73
YOLOv5	97.58	74.54	82.40	0.85
SSD	81.19	60.49	66.43	0.69
EfficientDet	94.87	33.35	73.61	0.49

2.2 YOLOv5 算法在不同色彩空间的性能

分别计算在 RGB、LAB、HSV 3 个色彩空间及其融合色彩空间中 YOLOv5 模型的识别性能,结果见表 4;与 RGB 和 LAB 色彩空间相比,基于多色彩空间的精确率为 77.51%,说明不同色彩空间融合后错误样本判别数增加;基于多色彩空间的召回率

为 98.99%,而在单独的色彩空间中,其召回率均低于 80%,说明结合了不同色彩空间的信息后,松枯死树被漏判的情况显著减少;基于多色彩空间的平均准确率达到 98.39%,远高于 RGB 空间的 82.40%;基于多色彩空间的 F₁ 分数也比独立的色彩空间有明显提升。

表 4 YOLOv5 算法在不同色彩空间的性能评价

Table 4 Performance evaluation of the YOLOv5 algorithm in different color spaces

色彩空间 Color spaces	精确率 Precision/%	召回率 Recall/%	平均准确率 AP/%	F ₁ 分数 F ₁ score
RGB	97.58	74.54	82.40	0.85
LAB	87.03	73.74	79.73	0.80
HSV	76.96	79.96	79.80	0.78
RGB+LAB+HSV	77.51	98.99	98.39	0.87

进一步对模型在不同色彩空间中的性能进行可视化分析(图 2)。从图中可以看出,图 2A 中在 RGB 色彩空间中未检测到 3 棵松树,但在 LAB 空间中(图 2B)能够全部检测出图像中的松枯死树;在 HSV 空间中(图 2C)能够检测出 RGB 空间中遗漏的 3 棵树,但 RGB 空间中能够检测出的部分目标在 HSV 空间则未能检测出。在图 2D 的 RGB 空间中有一棵松树被漏检,在 LAB 空间(图 2E)也同样未检出,但在 HSV 空间中(图 2F)被检出。上述结果说明,不同色彩空间之间存在着较强的互补性。因此,将 3 个色彩空间的结果汇总后,通过 NMS 算法保留置信度最高的候选框后过滤交并比大于 0.5 的其他候选框,就可以利用不同色彩空间

的检测信息得到比单一色彩空间更优的性能。

2.3 模型验证

采用样地 2 的数据验证 YOLOv5 算法在不同色彩空间的性能,结果见表 5。从表中可以看出,基于多色彩空间的模型相对于单色彩空间的模型在精确率上略有下降,但是召回率显著上升,说明此前单一色彩空间中被遗漏的样本经过挖掘多色彩空间的信息后被预测出来。平均准确率和 F₁ 分数也显著提高。综合以上评价结果发现,单色彩空间下模型性能伴随着数据集的更换准确率有所浮动,但是综合利用多色彩空间信息的模型表现十分稳定,性能相较于单色彩空间的模型均有明显提升。

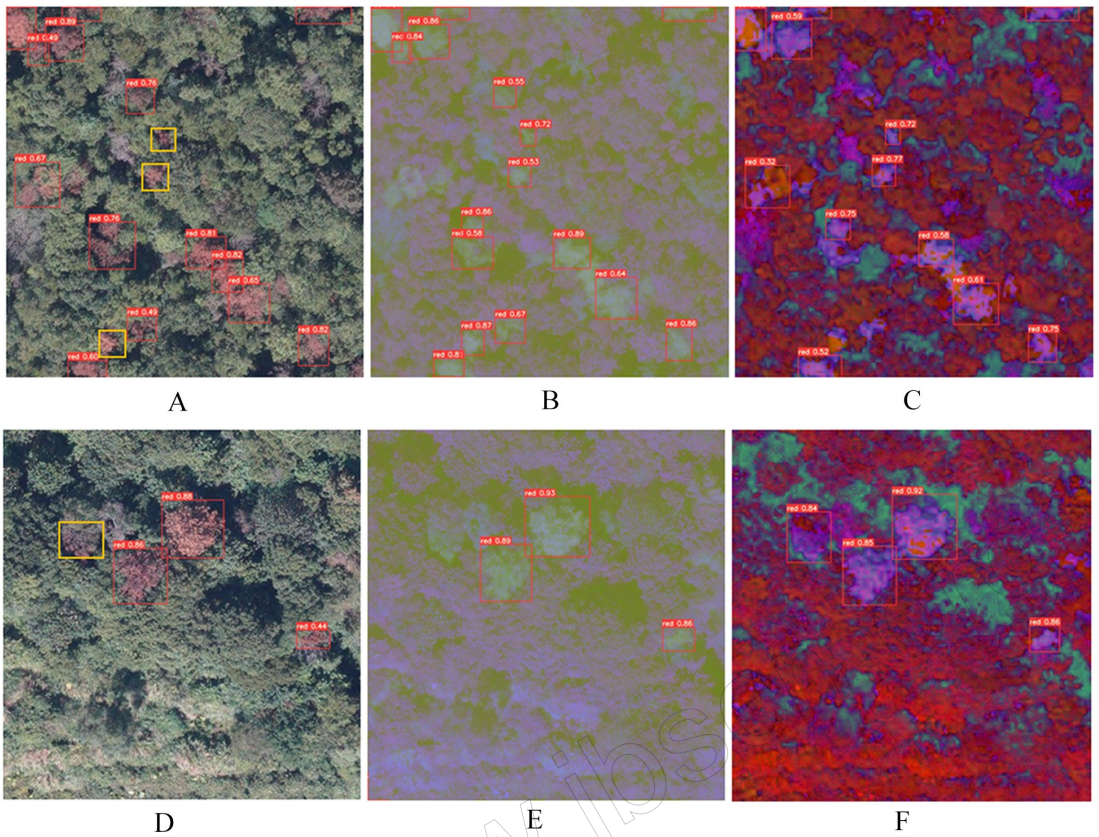


图 2 不同色彩通道下枯死松树检测示例

Fig.2 Demonstration of dead pine detection under different color spaces

A: RGB 通道图像预测结果 1; B: LAB 通道图像预测结果 1; C: HSV 通道图像预测结果 1; D: RGB 通道图像预测结果 2; E: LAB 通道图像预测结果 2; F: HSV 通道图像预测结果 2。黄色边框表示在 RGB 空间中被漏检的枯死松树, 红色边框表示在不同色彩空间中检出的松树。
 A: Result 1 of RGB channel image prediction; B: Result 1 of LAB channel image prediction; C: Result 1 of HSV channel image prediction; D: Result 2 of RGB channel image prediction; E: Result 2 of LAB channel image prediction; F: Result 2 of HSV channel image prediction. The yellow border represents the dead pine that has been missed in RGB space, and the red border represents the pine that has been detected in different color spaces.

表 5 YOLOv5 算法在不同色彩空间性能的验证

Table 5 Performance testing of the YOLOv5 algorithm in different color spaces

色彩空间 Color spaces	精确率 Precision/%	召回率 Recall/%	平均准确率 AP/%	F ₁ 分数 F ₁ score
RGB	96.83	56.48	71.78	0.71
LAB	96.10	68.52	80.62	0.80
HSV	96.40	62.04	73.66	0.75
RGB+LAB+HSV	93.81	84.26	90.19	0.89

本研究发现, 对比样地 1 与样地 2 的数据, 在 LAB 色彩空间和 HSV 色彩空间中的精确率、RGB 色彩空间下的召回率差别较大。对此进行了可视化分析, 通过筛选被模型判定为正确, 实际为错误的样本, 发现误差主要来源于几方面。(1) 阔叶树的混入。在 RGB 图像转换为 HSV 图像之后, 考虑到 HSV 色彩通道图像的特点, 不同色系的对比更加明显, 但是相同色系的对比被显著弱化。在这种情况下, 松枯死树与阔叶树的特征在图像上看来十分接近。如图 3B 所示, 3 个样本在 HSV 图像中极为相似, 导致了误判的发生。(2) 红土地的混入。

由图 3C 与图 3D 可以看出, 经过色彩空间的转换后, 部分图像中松枯死树特征与红土地特征相比更加相近。因此, 外观形状接近于松枯死树的红土地会被机器误判为正确样本。(3) 屋顶的混入。在 LAB 色彩空间下, 屋顶的特征接近于松枯死树的特征(图 3F), 造成了在该色彩空间下有屋顶的样本被识别为松枯死树带来误差。上述三点对精确率带来了影响, 根据样地的不同精确率会产生波动。由于样地 2 的航拍面积较小, 遇到上述误差来源少, 因此精确率显著高于样地 1。(4) 松枯死树连片导致矩形框框选不准确。分析发现, 样地 2 相对

于样地 1 存在更多松枯死树连片的情况。在这种情况下,本模型在样本框的预测上可能不准确,即模型可以准确预测连片区域,但无法准确框选每个

样本。如图 3G 所示,模型仅检测出 7 个矩形框的结果,但经过现场验证后实际结果共有 13 棵松枯死树,这也导致了召回率的大幅降低。




图 3 误差主要来源

Fig.3 Main source of error

A: RGB 通道图像预测结果 1; B: HSV 通道图像预测结果 1; C: RGB 通道图像预测结果 2; D: HSV 通道图像预测结果 2; E: RGB 通道图像预测结果 3; F: LAB 通道图像预测结果 3; G: RGB 通道图像预测结果 4。RGB 图像中的蓝色边框表示在不同色彩空间中检出的错误样本,黄色边框表示人工标注的结果。

A: Result 1 of RGB channel image prediction; B: Result 1 of HSV channel image prediction; C: Result 2 of RGB channel image prediction; D: Result 2 of HSV channel image prediction; E: Result 3 of RGB channel image prediction; F: Result 3 of LAB channel image prediction; G: Result 4 of RGB channel image prediction. The blue border in RGB image represents an erroneous sample detected in a different color space. The yellow border indicates the result of manual labeling.

3 讨论

目前,利用基于深度学习的计算机视觉方法判别松材线虫病发生林分中的松枯死树研究取得了重要进展,一些模型已在我国被尝试用于生产实践中。但由于建模样本量少、评价方法单一和模型先天缺陷等,实践中上述模型对松枯死树样本识别准确性不高,特别是漏检造成识别性能降低。此外,现有研究样本数据集的采集均存在无人机飞行高度较低且单一的局限性,其飞行高度均在 600 m 以内,且研究样地较为集中,因此研究结果往往十分理想,但忽视了大面积野外作业条件的复杂性。显然,无人机低空飞行采集数据拥有更高的识别准确率,但实践中进行大面积样地飞行时,无人机航拍需根据样地高程情况决定航拍高度,无法以单一飞行高度进行所有航拍图像的采集,这是导致上述模型在应用实践中存在局限性的主要原因。

针对以上问题,本研究根据实际生产应用的场景,提出了一种基于深度学习的松枯死树检测方法,通过建立大数据量的数据集,选择多种深度学习算法,对目标检测模型进行训练,筛选出平均准确率最高的深度学习模型,并通过综合多个色彩空间信息的方式,明显减少了松枯死树漏检的情况,提高了松枯死树的识别准确率。与前人的研究相比,一方面,本研究采集的数据集样本量大,经验证过的松枯死树样本量超过 9000 株,远高于现有研究的数据量,确保深度学习技术可以更加准确、高效地从样本中提取松枯死树的目标特征。另一方面,本研究通过收集不同飞行高度下的航拍图像,获得了更加丰富的样本数据,不会因为过高或过低的飞行高度影响识别准确率。

此外,本研究将 Faster R-CNN、YOLOv3、YOLOv4、YOLOv5、SSD 和 EfficientDet 等 6 个深度学习算法用于

松枯死树识别,并采用精确率、召回率、平均准确率及 F_1 分数 4 个评价指标对不同模型进行全面评价和对比分析,发现 YOLOv5 目标检测算法的性能明显优于 Faster R-CNN、YOLOv3 等模型。在此基础上进一步有针对性地综合利用多色彩空间的信息,使用 NMS 算法对不同色彩空间下的样本进行汇总,发现相对于单一色彩空间下的模型,充分利用多色彩空间信息的模型在召回率、平均准确率和 F_1 分数上均有明显提升,特别是召回率提升了 15.74% 以上,有效控制了松枯死树漏检的情况。

本研究可视化的定性分析结果也表明,不同色彩空间在进行目标检测时存在着互补作用。在 RGB 颜色空间中存在特征模糊的样本和小样本漏检的情况,在 HSV 和 LAB 空间中可以被检出,这表明 HSV 和 LAB 空间具有更强的红色特征提取能力,通过 3 种色彩空间的互补,可以大幅减少样本被漏检的数量,从而有效提高目标检测的性能。本研究认为,采用基于多色彩空间的 YOLOv5 目标检测模型是当前更优的检测识别松枯死树的方法,能够满足生产实践的需求。

参考文献

陈魏冬, 2018. 基于无人机航拍图像的枯死松树自动识别与定位. 硕士学位论文. 福州: 福建农林大学.

地力夏提·包尔汉, 2021. 无人机遥感技术在林业资源调查与监测中的应用. 广东蚕业, 55(5): 111-112.

李成, 刘波, 2021. 我国松材线虫病的发生与防治技术研究进展. 吉林林业科技, 50(2): 39-41, 48.

李凤迪, 2020. 基于深度学习和无人机遥感的松材线虫病树监测系统研究. 硕士学位论文. 泰安: 山东农业大学.

李浩, 方伟泉, 李浪浪, 陈学永, 2021. 基于深度学习的松材线病虫害松木识别. 林业工程学报, 6(6): 142-147.

黄丽明, 王懿祥, 徐琪, 刘清华, 2021. 采用 YOLO 算法和无人机影像的松材线虫病异常变色木识别. 农业工程学报, 37(14): 197-203.

刘顺利, 刘昌华, 张雷, 彭词清, 薛冬冬, 2022. 基于改进 SSD 的无人机影像松材线虫病变色木检测. 林业资源管

理, 21(3): 135-141.

陶欢, 李存军, 谢春春, 周静平, 淮贺举, 蒋丽雅, 李凤涛, 2019. 基于 HSV 阈值法的无人机影像变色松树识别. 南京林业大学学报(自然科学版), 43(3): 99-106.

叶建仁, 2019. 松材线虫病在中国的流行现状、防治技术与对策分析. 林业科学, 55(9): 1-10.

尹华阳, 汤宗斌, 董广平, 2020. 无人机监测枯死松树技术应用研究. 安徽林业科技, 46(4): 3-5.

DENG X L, TONG Z J, LAN Y B, HUANG Z X, 2020. Detection and location of dead trees with pine wilt disease based on deep learning and uav remote sensing. *AgriEngineering*, 2(2): 294-307.

DOSOVITSKIY A, BEYER L, KOLESNIKOV A, WEISSENBORN D, ZHAI X H, UNTERTHINER T, DEGHANI M, MINDERER M, HEIGOLD G, GELLY S, USZKOREIT J, HOULSBY N, 2020. An image is worth 16x16 words: transformers for image recognition at scale// International Conference on Learning Representations. [2022-09-15]. <https://arxiv.org/abs/2010.11929>

GOWDA S N, YUAN C, 2018. *ColorNet: investigating the importance of color spaces for image classification*. Cham: Springer.

TAN M, PANG R, LE Q V, 2020. *EfficientDet: scalable and efficient object detection*// Conference on Computer Vision and Pattern Recognition (CVPR). [2022-09-15]. <https://arxiv.org/pdf/1911.09070v1.pdf>.

WU B Z, LIANG A J, ZHANG H F, ZHU T F, ZOU Z Y, YANG D M, TANG W Y, LI J, SU J, 2021. Application of conventional UAV-based high-throughput object detection to the early diagnosis of pine wilt disease by deep learning. *Forest Ecology and Management*, 486: 118986

YU F, CHEN H F, WANG X, XIAN W Q, CHEN Y Y, LIU F C, MADHAVAN V, DARRELL T, 2020. *Bdd100k: a diverse driving dataset for heterogeneous multitask learning*// Seattle, America: Computer Vision and Pattern Recognition (CVPR). [2022-09-15]. DOI: 10.48550/arXiv.1805.04687.

(责任编辑:郭莹)