

基于深度学习的无人机遥感影像松材线虫病害监测方法

吴艳兰, 王彪, 杨辉, 秦军

摘要: 松材线虫病害是一种破坏性和传染性极强的世界性松树病害, 且当前监测手段仍以人工实地勘察为主, 而无人机遥感技术能为松材线虫病害智能监测提供有效的技术支持。本文以松材线虫病害监测智能化、自动化、高效率为目标, 利用飞马 D200 多旋翼无人机飞行平台搭载多光谱相机, 于 2019 年 8 月 12 日对安徽省黄山市某区域进行数据采集。针对染病松树光谱与空间特征, 设计并改进 DenseNet 网络结构, 结合注意力机制, 综合感知其多层次特征, 进一步推进松材线虫病害监测效果。实验结果表明, 本文方法识别精度达到 92.06%, 具有识别速度快、精度高、流程自动化等优点, 极大减少人力、物力支出, 为松材线虫病害监测提供了可靠的技术支撑。

关键词: 无人机遥感; 松材线虫病害监测; 深度学习

1 引言

松材线虫病 (Pine Wilt Disease, PWD) 又称松树枯萎病, 是一种由松材线虫引起的世界性松树病, 具有极强的破坏性与传染性, 在 1905 年日本就有关于松树大量枯死的记录^[1,2], 1982 年在我国南京中山陵首次发现松材线虫病^[3-5], 1983 年松材线虫病在台湾被发现^[5], 1999 年葡萄牙报告了松树枯萎病^[6], 2008 年松材线虫病出现在了西班牙^[7]。现如今, 我国 18 个省、自治区与直辖市地区都已发现松材线虫病害, 累计毁灭松林约 33.33 多万 hm^2 , 造成经济损失数千亿元。

松材线虫病监测是松材线虫防控的重要环节, 传统的松材线虫病害监测主要采用人工实地调查, 很难及时准确的发现染病松树。随着遥感技术的快速发展, 利用各类航空航天遥感技术进行病虫害监测已成为主要技术手段之一^[8-10], 卫星影像可以通过增强型植被指数 (Enhanced Vegetation Index, EVI) 与叶面积指数 (Leaf Area Index, LAI) 的相互关系, 能够准确地反映松林的生长与健康情况^[11]; 测定松材线虫自然侵染后黑松和马尾松不同受害阶段的光谱曲线, 分析其光谱参数、光谱特征以及叶绿素的相应变化, 发现随着病害程度加深, 叶绿素含量降低, 且光谱特征参数与叶绿素含量之间具有显著的相关性^[12]。卫星遥感在病虫害监测上取得了很多成果, 发展较快, 但受到成像条件、大气环境、地形地貌等复杂条件的影响, 仍存在许多亟待解决的问题^[13], 进而难以快速、有效的发现单株染

病松树。但如果不能及时发现染病松树并销毁，则松材线虫病感染范围将会迅速扩散。因此，如何高效、准确的进行松材线虫病害监测，已经成为当前国家林业资源迫切需要解决的重点问题之一。近年来，随着无人机技术不断发展，凭借着快速、便捷、高效等优点，已成为对地观测的重要手段之一^[14-16]。无人机遥感能快速获取多时态、多角度、多光谱的超高分辨率影像，为松材线虫病监测提供技术支持^[17]。目前，支持向量机等机器学习算法能实现对无人机影像松材线虫病害的自动识别^[18-19]，并通过 GIS 系统自动获取病源坐标^[20]；同时，可将无人机遥感影像中提取的枯死松树地理位置信息与 GPS 现地采集的地理位置信息进行对比验证，表明无人机遥感提取的坐标信息位置数据比较准确，具有较高的可操作性^[21]。虽然当前松材线虫病害监测已经取得了一定发展，但细节特征难以顾及，受复杂背景条件干扰，易导致椒盐现象，引起误分、漏分，进而影响监测结果。

深度学习是机器学习研究中的一个新的领域，在计算机视觉领域获得了巨大成功。自从 Krizhevsky 等^[22]构建深度学习网络 AlexNet 赢得了 2012 年 ILSVRC 冠军，深度学习开始受到学术界广泛的关注。2015 年，Long 等^[23]提出完全卷积网络（Fully Convolutional Networks, FCN），改变了原有的卷积神经网络结构，通过去掉全连接层、增加上采样层，完成图像的语义分割任务。FCN 作为最早提出的语义分割网络之一，成为后续许多语义分割网络的基本框架。其后出现的 U-Net、Segnet、RefineNet、DeepLab 等方法^[24-27]，这些网络框架不仅具有高级特征来进行像素分类的能力，并且能够重复使用低级特征来获取丰富的空间信息和详细细节。深度学习与遥感技术相结合已成为了研究热点之一，并已经在遥感监测上取得了良好的效果。

深度学习与遥感技术相结合已成为了研究热点之一，在遥感监测上取得了良好的效果，因而本文将 Dense Networks（DenseNets）深度学习网络应用于无人机影像的枯死松树病害监测技术。DenseNets 网络创新性的提出了 Dense Block，每一个 Dense Block 中任意两层直接都有直接连接（dense connection）^[28]。本文以 DenseNet 作为网络的整体框架，并结合 FCN 模型与注意力机制，充分利用目标的浅层特征与深层特征，构建 FC-DenseNet 模型，综合感知多层次特征，以此提升染病松树的识别率，为地面人员提供可靠的位置信息。

2 实验数据及预处理

本文以安徽省黄山市岩寺镇某区域为研究区域，该区域以山区为主，松材线虫病虫害感染严重。以飞马 D200 无人机为空中飞行平台，搭载多光谱相机，包括蓝、绿、红、近红和红边五个波段，分辨率设置为 10cm。由于本次实验所采用的无人机飞行平台搭载实时差分系统，能够有效提供影像的外方位元素，且本次飞行范围较小，因此，采用无像控数据采集方式。首先进行多光谱影像的正射影像生产，主要包含：相机内定向、坐标系统选取、辐射定标、波段配准、空中三角测量、数字高程模型及多光谱正射影像生产等处理。



图 1 飞马 D200 无人机起飞前准备及辐射定标

3 研究方法

3.1 FC-Densenet

FCN (Fully Convolutional Networks) 摒弃了以往 CNN (Convolutional Neural Network) 的全连接层，采用反卷积层对最后一个卷积层进行上采样，从而解决语义级别的分割问题。本文以 DenseNet 为框架，结合 FCN 的语义分析能力，构建 FC-DenseNet 模型。DenseNet 具备多层次特征重用 (feature reuse) 的特性，能够有效降低因参数和计算成本等问题引起的梯度弥散和消失效应，加强了特征传递机制，有效利用多层次特征，进一步提升松材线虫病害的识别能力。L 层的传统卷积网络通常将产生 L 个连接，而 DenseNet 具有 $L \times (L+1) / 2$ 个连接。对于每个特征层，前面所有层的输出将作为输入，其自身也将用作后续层的输入。本文所使用的 FC-DenseNet 结构如图所示：




图2 本文所用 FC-Densenet 基本结构

本文的网络结构下采样由批标准化层，激活层， 1×1 卷积层，Dropout 层与 2×2 最大池化层组成，上采样使用 3×3 反卷积层。本文使用两种图片大小作为输入，分别是 64×64 和 128×128 。Dense 模块的密集连接具有几个优点，例如加强特征重用，减少参数量，这使得网络更容易训练。但与此同时，这种方式将导致过度使用低级特征并导致过度分割。

3.2 注意力机制

受到注意力机制能够使用高级特征来加权低级特征的启发，首先使用激活层对高级特征进行激活，并用作低级特征的权重；然后，将高级特征激活输出乘以低级特征以获得加权的低级特征；最后，添加高级特征和加权低级特征作为 Dense 模块的输入以逐渐恢复影像的详细信息。注意力模块的体系结构如图所示：

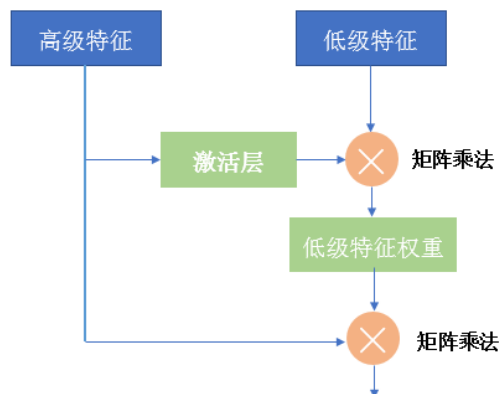



图3 注意力模块体系结构

3.3 模型训练与部署

本试验采用 Tensorflow 深度学习开源框架，训练阶段采用 Adam 优化器对权重进行优化，设置初始学习率为 10^{-2} ，以 15 张图像为一个批次，共训练 60 轮，每轮设置迭代次数 750 次，同时将图像大小缩小为 64×64 ，且只输入蓝、绿、红、近红四个波段。

4 结果与分析

图 4(a)为本文的测试区，该区域位于安徽省黄山市，测区大小为 20hm^2 ，该区域地形主要为山区与盆地，林区树种以松树为主，并有房屋、道路、田地和池塘等多种复杂地物。本研究基于 FC-DenseNets 模型对该测区影像进行识别，识别结果如图 4(b)所示。




(a) 原始影像

(b) 监测结果


图 4 松材线虫病害监测结果

如图 5(a)与图 5(b)所示，本文方法对松材线虫病害具有良好的监测能力。同时，受光照、地形等因素的影响，造成影像部分区域产生光谱差异，本文方法对于该部分区域，同样具有良好的监测能力（图 5(c)与图 5(d)）。




(a) 样图 1

(b) 监测效果图 1



(c)样图 2



(d)监测效果图 2

图 5 监测效果图

根据识别结果，生成坐标信息，并进行实地核查，核查结果如表 1 所示。实地核查共抽取 63 处预测点进行核查，抽查率为 30%，其中有 58 处为染病松树或已砍倒的染病松树，正确率为 92.06%，如表 2 所示：

表 1 核查结果

序号	X	Y	外业核查结果
1	627477.43029200000	3295677.07653000000	是
2	627478.45370500000	3295682.84008000000	是
3	627500.33918700000	3295687.87545000000	已砍倒枯树
4	627562.84339000000	3295686.86299000000	已砍倒枯树

表 2 监测精度

总疑似点	抽查点数	抽查率	正确识别数目	错误识别数目	正确率	误检率
210	63	30%	58	5	92.06%	7.94%

实地核查后发现，本文方法通过利用细节特征，能很好地区分出每一株染病松树，并由于染病松树砍伐后未及时销毁，在影像上呈现出与染病松树相似的光谱信息，因此本文方法对已砍倒松树具有同样的识别效果(图 6)。这充分说明本文方法具有良好的松材线虫识别性能，可以为松材线虫监测及地面人员清理工作检查提供可靠的依据。



(a) 染病松树



(b) 已砍倒松树

图 6 实地核查图

经实际核查，部分识别点松树叶片少部分变黄，大部分仍呈现绿色，处于染病前期（图 7），这类染病松树在传统的机器学习算法识别中往往不易被识别。但本文通过引入注意力机制，忽略背景等无关信息，关注重要的病害信息，经过学习训练，模型更好地区分在影像上特征表现不明显的染病松树，因此对于这类染病前期的松树，模型也能将其识别出来。若此类松树能得到及时、有效地治理，能有效的抑制松材线虫病害的传播，缓解松材线虫病害疫情，具有重要的实际意义。



图 7 染病前期松树

本次识别结果共有五处错误识别点，其中一处识别点附近未发现相似地物。有一处识别点为田埂苗木，另有三处为枯黄灌木丛，在影像中的表征与染病松树相似（图 8）。由于本文方法未对样本库类别进行细化，没有区分树种，而其它枯死树种在多光谱影像中有时与染病松树具有相似的光谱特征，因此模型对此类地物有时存在难以区分的情况，通过构建多类别样本库可进一步提高模型精度。



图 8 错误识别点

5 结论与讨论

本文利用无人机影像具有时效性强、空间分辨率高的特点对松材线虫病监测方法进行的研究。通过选取飞马 D200 多旋翼无人机在 150m 飞行高度下对感染松材线虫病的枯死松树进行影像采集，利用 FC-Densenet 模型并结合注意力机制对无人机影像进行了识别，有效改善了传统方法中存在的椒盐现象，同时解决了 Dense 模块过度利用特征造成的过度分割问题，对枯死松树、已砍倒的枯死病树以及染病前期的松树都具有良好的识别效果，总体识别精度达到 92.06%。

本研究表明将无人机遥感技术与深度学习结合进行松材线虫监测的方法具有重要的应用价值与实际意义。本方法对松材线虫病的早期预警，以及病死枯树的识别的良好效果很好的改善了传统作业方法的不足，且具有高效、便捷、精确等优点。但由于其它枯死植物的光谱特性与枯死松树相近，容易造成误分，在今后的的研究中将考虑植物类别等因素，构建多类别样本库用以提高模型精度，提升对松材线虫监测的识别率。

参考文献:

- [1] 吴敏娟, 尤誉杰, 张晓红, 王懿祥, 邱婉婷, 吕玉龙, 应彬彬, 陈时跃. 不同干扰模式对受害马尾松人工纯林林分结构的影响[J].应用生态学报,2019,30(01):58-66.
- [2] 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(03):367-370.
- [3] Pan Jie,Zhang Heng,Ju Yunwei,Liao Zhenfeng. Early Monitoring of Pine Wilt Disease in Pinus massioniana based on Hyperspectral Data[J]. Plant Diseases and Pests,2015,6(Z1):1-5.
- [4] William R Nickle,薛煜. 松材线虫枯萎病[J]. 吉林林业科技,1987,(03):57-59.
- [5] 王曦苗, 曹业凡, 汪来发, 朴春根, 李成录. 松材线虫病发生及防控现状[J]. 环境昆虫学报, 2018,40(02):256-267.
- [6] Manuel M. Mota,Helen Braasch,Maria Antonia Bravo,Ana Catarina Penas,Wolfgang Burgermeister,Kai Metge,Edmundo Sousa. First report of Bursaphelenchus xylophilus in Portugal and in Europe[J]. Nematology,1999,1(7):727-734.
- [7] Abelleira A,Picoaga A,Mansilla J P,Aguin O. Detection of Bursaphelenchus Xylophilus, Causal Agent of Pine Wilt Disease on Pinus pinaster in Northwestern Spain.[J]. Plant disease,2011,95(6).
- [8]Camps-Valls G,Shervashidze N. Spatio-spectral remote sensing image classification with graph kernels[J].IEEE Geoscience and Remote Sensing, 2010, 7(4): 741-745.
- [9] Mingyang Li, Milan Liu, Min Liu. Monitoring exotic forest pest based on high-resolution remote sensing image and CART model[P]. Image and Signal Processing (CISP), 2010 3rd International Congress on,2010.
- [10] Wang, L., Zhang, X., Luo, Y.,et.al. A Study on the Changes of Pinus Massoniana Spatial Pattern by Pine Wood Nematode Invasion Based on Remote Sensing and GIS[P]. Geoscience and Remote Sensing Symposium, 2006. IGARSS 2006. IEEE International Conference on,2006.
- [11] 郭仲伟,吴朝阳,汪箫悦.基于卫星遥感数据的森林病虫害监测与评价[J].地理研究,2019,38(04):831-843.
- [12] 徐华潮,骆有庆,张廷廷,施拥军.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(05):1352-1356.
- [13] 鲁军景, 孙雷刚, 黄文江. 作物病虫害遥感监测和预测预警研究进展[J]. 遥感技术与应用,2019,34(01):21-32.
- [14] U. Niethammer,M.R. James,S. Rothmund,et.al. UAV-based remote sensing of the Super-Sauze landslide: Evaluation and results[J]. Engineering Geology,2012,128.
- [15] 魏杰, 戎征, 邢昱. 无人机遥感技术在环境监测的应用研究[J]. 中国资源综合利用,2018,36(10):190-192.
- [16] Zang, Wenqian,Lin, Jiayuan,et.al. Investigating small-scale water pollution with UAV Remote Sensing Technology[P]. World Automation Congress (WAC), 2012.
- [17] 张红梅, 陆亚刚. 无人机遥感技术国内松材线虫病监测研究综述[J]. 华东森林经理, 2017(3).
- [18] 胡根生,张学敏,梁栋.基于 WWSVDD 多分类的遥感图像病害松树识别[J].北京邮电大学学报,2014,37(02):23-27.
- [19] 胡根生,张学敏,梁栋,黄林生.基于加权支持向量数据描述的遥感图像病害松树识别[J].农业机械学报,2013,44(05):258-263+287.

- [20] 黄焕华, 马晓航, 黄华毅, 周宇飞, 张伟, 黄咏槐. 利用固定翼无人机监测松材线虫病疫点枯死松树的初步研究[J]. 环境昆虫学报, 2018,40(02):306-313.
- [21] 曾全, 孙华富, 杨远亮. 无人机监测松材线虫病的精度比较[J]. 四川林业科技, 2019(3):92-95.
- [22] Krizhevsky A , Sutskever I , Hinton G . ImageNet Classification with Deep Convolutional Neural Networks[C]. NIPS. Curran Associates Inc. 2012.
- [23] Long J , Shelhamer E , Darrell T . Fully Convolutional Networks for Semantic Segmentation[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2014, 39(4):640-651.
- [24] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation[C]. International Conference on Medical Image Computing & Computer-assisted Intervention. 2015.
- [25] Badrinarayanan V , Kendall A , Cipolla R . SegNet: A Deep Convolutional Encoder-Decoder Architecture for Scene Segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017:1-1.
- [26] Lin G , Milan A , Shen C , et al. RefineNet: Multi-Path Refinement Networks for High-Resolution Semantic Segmentation[J]. 2016.arXiv 2016,arXiv:1611.06612.
- [27] Chen L C , Papandreou G , Kokkinos I , et al. Semantic Image Segmentation with Deep Convolutional Nets and Fully Connected CRFs[J]. Computer Science, 2014.
- [28] Huang G, Liu Z, Laurens V D M, et al. Densely Connected Convolutional Networks[J]. 2016.