

基于改进语义分割网络的 落叶松电阻率层析成像的图像心材区域识别

凌昊, 徐华东*, 郭旭辉

(东北林业大学机电工程学院, 哈尔滨 150040)

摘要: 针对落叶松活立木心材精准识别难题, 提出一种基于电阻断层成像 (electrical resistivity tomography, ERT) 的智能分割方法。通过对比分析落叶松样本 ERT 图像与物理切面, 发现心边材的交界区域电阻变化率达 90%~94%。根据该阈值范围, 建立落叶松活立木心材 ERT 图像分割标注准则。由于 ERT 图像获取困难, 构建 Mini-200 小样本和 Mids-3200 大样本 2 个数据集, 通过小训练集快速适应分割任务, 结合大训练集提升模型鲁棒性、减少过拟合。提出改进的语义分割网络 (DeepLabv3+) 模型, 通过引入 ResNet101、混合注意力机制 (convolutional block attention module, CBAM) 与特征强化模块 (data communication module, DCM) 优化其特征提取能力。消融试验表明, 在 Mini-200 数据集上, 改进模型准确率 (accuracy, A)、精确率 (precision, P)、交并比 (intersection over union, IoU)、平均交并比 (mean intersection over union, mIoU) 和 Dice 损失函数 5 个评价指标较基础模型提升 0.14%~0.44%; 在 Mids-3200 数据集上, 改进后的 DeepLabv3+ 模型分割性能最优, 与原模型相比, 心材的像素准确率 (pixel accuracy, PA) 和 IoU 分别提高了 0.32% 和 2.45%, 类别像素准确率 (class pixel accuracy, CPA)、mIoU 和 Dice 系数分别提高 0.47%、2.13%、0.25%, IoU 达 98.80%, 证明改进模型用于落叶松 ERT 图像心材分割的效果良好。

关键词: 落叶松; 心材; ERT; DeepLabv3+; 混合注意力

中图分类号: S791.222; TP391.4

文献标识码: A

DOI: 10.7525/j.issn.1006-8023.2025.06.018

Heartwood Region Recognition in Larch ERT Images Based on Improved Semantic Segmentation Network

LING Hao, XU Huadong*, GUO Xuhui

(College of Mechanical and Electrical Engineering, Northeast Forestry University, Harbin 150040, China)

Abstract: Aiming at the difficulty of accurately recognizing the heartwood of larch standing trees, this study proposes an intelligent segmentation method based on electrical resistance tomography (ERT). By comparing and analyzing ERT images and physical sections of larch samples, it is found that the resistance change rate of the junction region of the heart sapwood reached 90%-94%. Based on this threshold range, the segmentation annotation criterion for ERT image segmentation of larch standing tree heartwood was established. Due to the difficulty in acquiring ERT images, two datasets, Mini-200 small samples and Mids-3200 large samples, were constructed to quickly adapt to the segmentation task through the small training set, and combined with the large training set to improve the model robustness and reduce overfitting. The improved semantic segmentation network (DeepLabv3+) model was proposed to optimize its feature extraction capability by introducing ResNet101, convolutional block attention mechanism (CBAM) and data communication module (DCM). The ablation experiments showed that the five evaluation indexes of accuracy (A), precision (P), intersection over union (IoU), mean intersection over union (mIoU) and Dice loss function of the improved model were im-

收稿日期: 2025-03-24

基金项目: 黑龙江省自然科学基金项目 (LH2024C054); 国家自然科学基金项目 (31870537)。

第一作者简介: 凌昊, 硕士研究生。研究方向为森林工程。E-mail: 2022111628@nefu.edu.cn

* 通信作者: 徐华东, 博士, 教授。研究方向为树木健康监测。E-mail: huadongxu@nefu.edu.cn

引文格式: 凌昊, 徐华东, 郭旭辉. 基于改进语义分割网络的落叶松电阻率层析成像的图像心材区域识别 [J]. 森林工程, 2025, 41(6): 1290-1298.

LING H, XU H D, GUO X H. Heartwood region recognition in larch ERT images based on improved semantic segmentation network [J]. Forest Engineering, 2025, 41(6): 1290-1298.

proved by 0.14%–0.44% compared with the base model on the Mini-200 dataset; on the Mids-3200 dataset, the improved DeepLabv3+ model had the optimal segmentation performance, and compared with the original model, the pixel accuracy (PA) and IoU of the heartwood were improved by 0.32% and 2.45%, respectively, and the class pixel accuracy (CPA), mIoU and Dice coefficient were improved by 0.47%, 2.13%, 0.25%, respectively, and the IoU reached 98.80%, compared with the original model. It proves that the improved model works well for the segmentation of the heartwood of the ERT image of larch.

Keywords: Larch; heartwood; ERT; DeepLabv3+; hybrid attention

0 引言

在林木培育领域,心材的精准识别直接影响材料价值评估与资源高效利用。以珍贵树种为例,降香黄檀(*Dalbergia odorifera*)心材材质远高于边材^[1],而日本扁柏(*Chamaecyparis obtusa*)心材因特有的抗菌特性在高端建材市场溢价率达300%^[2],因此,需要利用立木的心材检测方法进行心材的识别。进行立木心材检测时,可能存在边材与心材颜色相近的情况,传统依赖颜色辨识的破坏性检测方法已不再适用,因此,寻找新的手段准确地识别心材成为亟待解决的问题。

在树木边、心材识别领域,目前主要依赖物理检测手段、阈值分割和形态学操作等图像处理技术。其中电阻率层析成像技术(electrical resistivity tomography, ERT)^[3]基于介质电阻率差异实现非破坏性内部结构成像,在木材检测中因高分辨率、实时监测等优势被应用于心材识别、根系分布及土壤水分评估^[4]。但其实际应用受限于接触不良导致图像伪影等电极布置精度问题和森林复杂土壤电导率波动的环境噪声干扰问题,尤其在异质性强或高阻抗区域易出现成像失真,需结合机器学习算法优化反演精度以提升可靠性。Guyot等^[5]利用ERT技术结合木材含水率、电解质浓度和密度实测分析等方法,确定了湿地松(*Pinus elliottii*)与加勒比松(*Pinus caribaea*)的边材-心材(sapwood-heartwood)边界;ERT成像显示心材区域呈现高电阻率,向外逐渐降低,估算的边材面积与伐后实测值基本一致。而CT图像^[6]根据立木的密度差异结合形态学方法提取心材边界,但易受噪声干扰且依赖人工参数调整。随着深度学习模型在图像处理方面成为主流,许多研究尝试将其与传统方法结合,进行心材识别。Hatta等^[7]提出一种带批量归一化的卷积神经网络分类方法,依照印尼国家标准(SNI 7631:2018)将沉香(*Aquilariacrassna*)心材分为3个等级。但是,活立木的心材区域数据获取成本高、心材与边材过渡区域边界模糊、算法对细微差异的敏感性不足、实时性与计算效率的平衡问题等导致模型泛化能力不足,心材识别困难,难以取得很好的效果。

针对立木心材识别困难等问题,提出基于ERT与深度学习融合的识别方法。通过ERT技术获取落叶松(*Larix gmelinii*)的电阻二维断层图像(ERT图像),构建大小2个数据集。选择DeepLabv3+为基础网络,相比U-Net的简单跳跃连接或PSPNet的单一金字塔池化,DeepLabv3+通过空洞空间金字塔池化(ASPP)与解码器(Decoder)的协同设计,实现了语义信息与空间细节的更优平衡。同时,在DeepLabv3+的基础上进行改进,进一步强化其特征提取能力,在保持模型轻量化的同时提升像素级分割精度,解决ERT图像分辨率低和心材区域特征不明显所导致的心材识别不准确问题。

1 材料与方法

1.1 试验材料

选取购置的新鲜落叶松原木样本10段,高25 cm,直径为16.9 cm±1.9 cm。在试验室,将原木样本加工成厚度为5 cm的圆盘样本,共计50个。打磨圆盘表面,保证样本纹理清晰;为样本编号,在表面标注测量起始点。在纯净水中浸泡24 h,浸泡后质量为0.964 kg±0.164 kg,从而保证其整体含水率在85%左右,模拟活立木状态,使样本拥有良好的导电能力。

1.2 试验方法

使用ERT主机(德国PiCUS TreeTronic³)采集ERT图像,如图1所示。擦拭浸泡后的样本表面至无水状态,以标记的起始点为基准,沿圆周逆时针方向嵌入12枚电极,电极间距由样本周长动态计算并保持均匀分布。在ERT主机中设置树种、样本周长(53.2~59.7 cm)、电极数和激励频率(10 kHz)等参数,获取测量数据。将测量数据导入PiCUS Q74-EXPT软件,设定网格剖分密度为5级,采用改进的代数重建法(algebra reconstruction technique, ART)进行电阻场反演计算。为降低测量随机误差,对50个样本分别重复3次进行ERT测试,获取ERT图像。

ERT技术的原理为通过测量边界电压获得物体内部电导率分布^[8]。由边界处向测量物体注入电流,并建立测量场域^[9];当场域内电导率改变时,其边界电压也随之改变;通过测量被测物体边界电压即可得到场




图1 ERT测试过程

Fig. 1 ERT test procedure

域内物体电导率变化情况^[10]。根据反演算法获得物体内部的电导率分布图,实现被测场域的可视化检测^[11]。

1.3 标注标准

图2为ERT图像和落叶松物理切面的对比。样本1的ERT图像中红色区域电阻值较大,蓝色区域电阻值较小^[12-14],边心材交界处的电阻值、样本表面的电阻值和中心位置的电阻值定义为 R_d 、 R_0 和 R_1 ,边心材交界处的电阻变化率(E_d)计算公式为

$$E_d = \frac{|R_d - R_0|}{|R_1 - R_0|} \times 100\% \quad (1)$$

表1 圆盘样本1电极方向上心边材交界处电阻变化率

Tab. 1 Resistance change rate at the junction of heartwood and sapwood in the electrode direction for disc 1 %

测量次数 Number of measurements	电极序号 Electrode number											
	1	2	3	4	5	6	7	8	9	10	11	12
1	92.1	92.2	91.5	90.9	93.5	90.3	93.2	92.5	90.9	92.4	91.5	92.8
2	92.6	92.7	91.8	90.8	93.2	90.7	93.7	92.0	91.0	92.0	91.2	93.4
3	92.1	92.8	91.1	90.5	93.3	90.5	93.6	92.5	91.5	92.4	91.8	93.0

2 深度学习模型改进

2.1 DeepLabv3+网络

DeepLabv3+的核心架构采用编码器-解码器设计。编码器通过逐步压缩特征图尺寸捕获高层次语义特征,解码器通过上采样操作将低分辨率特征图还原至输入图像尺寸,过程中融合不同层级的特征信息,实现对分割结果的细节优化与精度提升。

编码器部分主要包括主干网络和ASPP两部分。主干网络中Xception的核心思想是深度可分离卷积操作^[16],即将普通卷积操作分解为深度卷积和逐点卷积2个步骤;ASPP模块接受主干网络的输出作为输入,增强网络对边、心材分割的鲁棒性,利用不同膨胀率的空

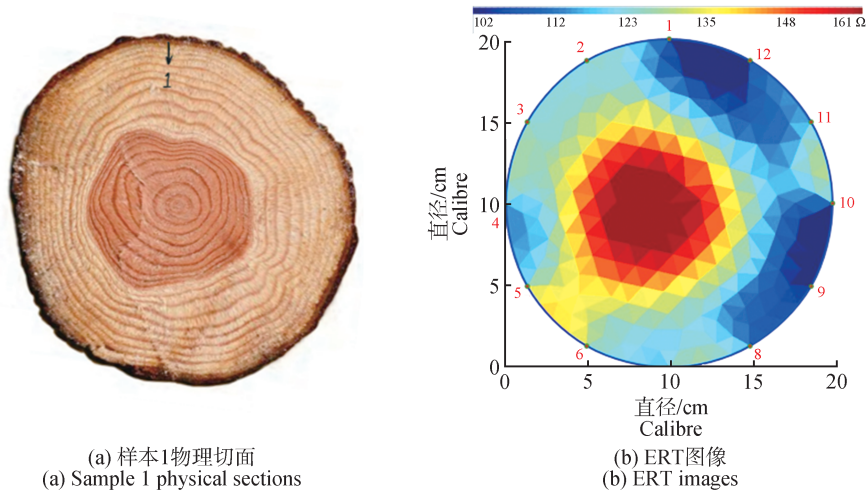
落叶松心材的木质素质量分数较边材高20%左右^[15],纤维素质量分数较低,导致心材部分的含水率与Na、K等离子低于边材,心材与边材电阻差异大且分界明显,可由 E_d 确定心材范围。计算样本1的3次试验的电极方向上的边、心材过渡区 E_d ,见表1。 E_d 范围为90.5%~93.7%。综合分析50组样本数据可知,落叶松的边、心材交界处的电阻变化率(E_d)范围为90.0%~94.0%。实地测量验证了该规律,并以此作为数据集的标注标准。

洞卷积从多尺度提取输入特征。

解码器将主干网络中间层的低级特征与ASPP输出的高级特征作为输入,通过 1×1 卷积压缩低级特征的通道维度,对高级特征线性插值、上采样并卷积;将二者沿通道维度拼接融合后,利用 3×3 卷积组进行特征整合与优化,最后通过线性插值上采样至原图分辨率,输出预测结果。

2.2 DeepLabv3+改进方法

基于原始DeepLabv3+框架,通过调整主干网络为ResNet101,并融合注意力机制模块(convolutional block attention module, CBAM)与特征增强模块(data communication module, DCM)提升模型特征提取能力,如图3所示。ResNet101利用残差连接提取心材细节



(a) 样本1物理切面
(a) Sample 1 physical sections

(b) ERT图像
(b) ERT images

图 2 ERT 图像与落叶松物理切面对比图

Fig. 2 Comparison of ERT images with physical sections of larch

信息,加速模型的收敛;ASPP 模块输出的多尺度特征经 CBAM 的通道加权与空间筛选,强化关键区域的语义表达并弱化冗余背景干扰;解码器整合 2 个特征源:ResNet 网络中间层提取的低级特征与编码器路径

上采样后的高级特征。二者通过通道拼接实现多级特征融合,经 3×3 卷积层进行跨尺度信息整合后,采用线性插值恢复至原始图像分辨率,输出高精度的分割结果。

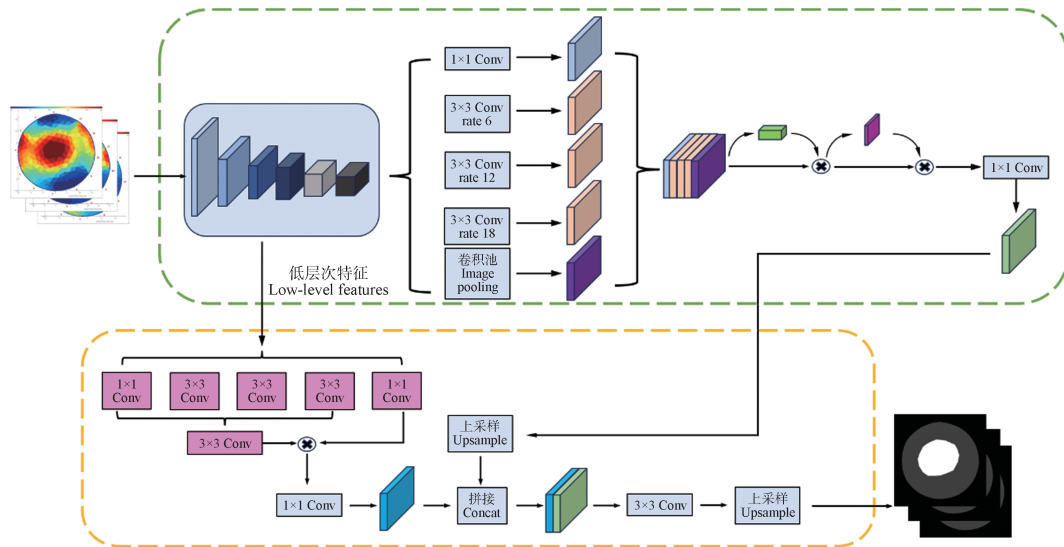


图 3 改进 DeepLabv3+模型结构

Fig. 3 Architecture of the improved DeepLabv3+ model

2.3 混合注意力机制

注意力机制可以动态调整特征权重,强化目标相关特征并弱化无关背景干扰,是提升分割精度的重要技术^[17]。根据作用不同,注意力机制可分为通道注意力机制(channel attention mechanism, CAM)与空间注意力机制(spatial attention mechanism, SAM)。

混合注意力机制 CBAM 模块如图 4 所示,通过通道注意力筛选出高贡献度特征,再利用空间注意力定

位特征图中的有效区域;双重注意力协同作用下,可以从多维度增强模型对关键特征的捕捉能力。

2.4 特征强化

落叶松的电阻二维断层图像中,边、心材过渡区域颜色逐渐变化,很难清晰地分割出心材组织,因此需要增强心材的特征,凸显边、心材的界限,实现精确分割。而空洞卷积通过设置膨胀系数扩展卷积核覆盖范围,能捕获多尺度上下文信息,有效提升特征的语义表达

能力,强化目标区域的形态特征。

本模型针对 ResNet101 输出的浅层特征设计特征增强模块(DCM)。使用 1×1 卷积层与 3×3 空洞卷积提取多尺度特征,利用通道拼接融合特征;应用通道注意

力机制对融合特征加权,区分心材与周围边材组织的不同特征。将该特征重新提取,通过空间注意力机制对特征图进行空间域加权,增强心材区域与边材组织的对比度,使特征更易被分辨(图4)。

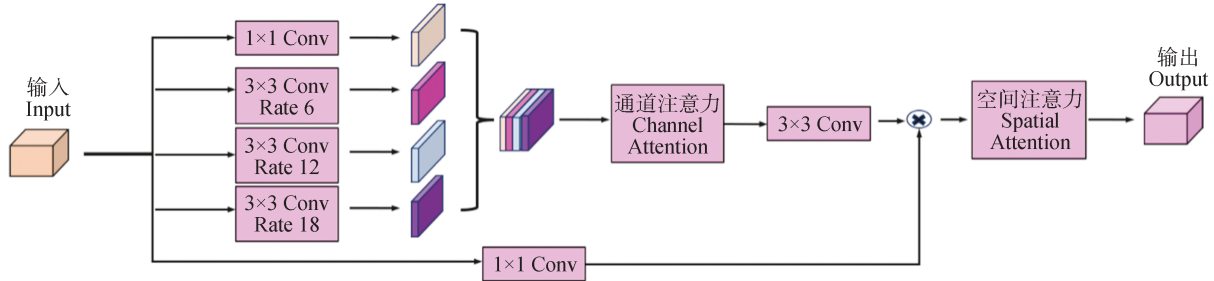


图4 特征增强DCM模块结构图
Fig. 4 Structure of feature-enhanced DCM

3 试验设置

3.1 试验环境与数据集

试验环境: Windows11 操作系统,显卡为 NVIDIA RTX 4060,处理器为 AMD EPYC 7763、24 GB 内存、Python3.8。采用深度学习 PyTorch 框架,软件环境为 Pycharm,Pytorch2.0、CUDA11.8。

选取东北林业大学林场中 150 棵健康落叶松进行检测,样树树龄为 45~60 a,胸径为 16.6~23.7 cm(平均 18.7 cm),整体含水率为 75.6%~88.7%(平均 84.2%)。采集距地高度 2 m 以下树干的 ERT 图像,每棵样本由下至上采集 12 次,采集间隔 15 cm,共计 1 800 张。将这些图像标准化预处理,对分割标签进行与 ERT 图像相同的旋转裁剪等空间变换,确保像素级对齐,并统一至 512×512 分辨率。最后使用 Roboflow 按照电阻变化

率 90%~94% 标注心材范围。

由于 ERT 图像获取难度大,难以制作大数据集,因此将试验数据集分为 2 部分。第 1 部分有 200 张 ERT 图像(Mini-200 数据集),其中心材区域清晰的 ERT 图像与心材区域模糊的占比为 4:1。第 2 部分通过 Imgaug 工具包进行数据增强,如图 5 所示。采用旋转 $\pm 15^\circ$ (图 5(b))、HSV(Hue saturation value)色彩空间饱和度 $\pm 20\%$ 、亮度 $\pm 15\%$ 色彩扰动(图 5(c))及弹性形变(图 5(d))等操作,将样本量扩充至 3 200 张(Mids-3200 数据集),其中心材区域清晰图像占 82.7%,心材区域模糊图像占 17.3%,按 8:2 比例随机划分为训练集(2 560 张)与测试集(640 张)。Mini-200 数据集加快模型适应新任务,减少训练时间,Mids-3200 数据集提升模型鲁棒性,减少过拟合,共同验证改进的 DeepLabv3+ 性能的优劣。

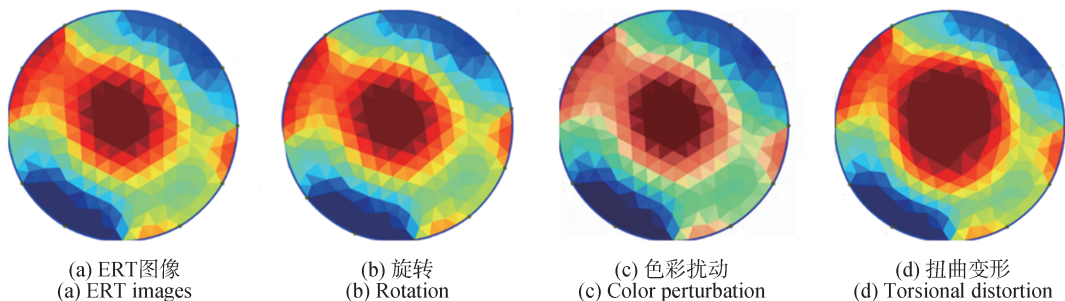


图5 ERT图像数据增强
Fig. 5 ERT image data enhancement

3.2 评价指标

采用准确率(accuracy, A)、精确率(precision, P)、交并比(intersection over union, IoU, 式中为 I_{ou})、平均交并比(mean intersection over union, mIoU, 式中为

m_{IoU})和Dice损失函数5个指标对模型进行评价。前4个指标计算公式为

$$A = \frac{T_P + T_N}{T_P + T_N + F_P + F_N} \quad (2)$$

$$P = \frac{T_p}{T_p + F_p} \text{ 或 } \frac{T_N}{T_N + F_N} \quad (3)$$

$$I_{IoU} = \frac{T_p}{T_p + F_p + F_N} \text{ 或 } \frac{T_N}{T_N + F_p + F_N} \quad (4)$$

$$m_{IoU} = \frac{1}{2} \left[\frac{T_p}{T_p + F_p + F_N} + \frac{T_N}{T_N + F_p + F_N} \right] \quad (5)$$

式中: T_p 为实际为正例的样本被正确预测的数量; F_p 为实际为负例的样本被错误预测为正例的数量; F_N 为实际为正例的样本被错误预测的数量; T_N 为实际为负例的样本被正确预测的数量^[18]。

3.3 损失函数

损失函数用于评价模型预测值和真实值的差异程度,参考文献[19]使用 Dice Loss 进行评价。Dice 系数是用于评估 2 个集合相似性的度量函数($D_{ice Loss}$),常用于语义分割问题中,其计算公式为

$$D_{ice Loss} = 1 - \frac{2|X \cap Y|}{|X| + |Y|} \quad (6)$$

式中: X 为真实分割图像的像素标签; Y 为模型预测分割图像的像素类别; $|X|$ 为 X 中元素的个数; $|Y|$ 为 Y 中

元素的个数; $|X \cap Y|$ 为 X 与 Y 之间交集元素的个数。

Dice Loss 在处理图像分割任务时对不平衡类别的鲁棒性较强,在训练模型时可以优化模型的预测结果,使其更加精准地匹配实际分割标签。

4 结果与分析

在落叶松 ERT 图像的二维识别过程中,为验证改进模型的有效性,本研究选取 Transfuse、U-Net、PSPNet、SegNet 和 DeepLabv3+ 这 5 个经典模型作为基准,采用 Mids-3200 数据集进行对比试验,见表 2。改进模型在边材、心材等关键目标的 IoU 和像素准确率(pixel accuracy, PA)指标上均取得最优值,其中心材 IoU 达到 98.80%,较次优模型 SegNet 的 97.46% 提升 1.34%。尽管 SegNet 在边材分割的 PA 指标为 99.01%,PSPNet 在边材分割的 IoU 指标为 78.75%,接近改进模型的 99.06% 和 74.21%,但 SegNet 与 PSPNet 心材的 PA 和 IoU 分别为 96.45%、97.46% 和 82.11%、92.46%,低于改进模型的 1.34%~16.83%,说明改进模型在复杂目标分割上具有优势。

表 2 不同模型的语义分割指标结果对比

Tab. 2 Comparison of results of semantic segmentation metrics for different models

模型 Model	像素准确率(PA) Pixel accuracy		类别像素准确率 (CPA) Class pixel accuray	交并比(IoU) Intersection over union		平均交并比(mIoU) Mean intersection over union	Dice 系数 Dice coefficient
	心材 Heartwood	边材 Sapwood		心材 Heartwood	边材 Sapwood		
	Transfuse	95.28	95.16	95.20	95.09	75.00	85.80
U-Net	89.39	90.76	90.24	93.29	75.16	84.32	98.49
PSPNet	82.11	88.52	85.94	92.46	78.75	85.45	97.16
SegNet	96.45	99.01	97.53	97.46	72.19	84.15	99.10
DeepLabv3+	98.62	98.44	98.53	96.35	77.62	86.99	99.25
DeepLabv3+ + CBAM + DCM(ResNet101)	98.94	99.06	99.00	98.80	79.43	89.12	99.50

定量分析表明,改进模型的 mIoU 达 89.12%,类别像素准确率(class pixel accuray, CPA)达 99.00%,较对比模型提升显著,Dice 系数达到 99.50%,基准模型最高值为 99.25%。值得注意的是,原版 DeepLabv3+ 虽在边材 PA 达 98.44%,接近改进模型的 99.06%,但其心材 IoU 为 96.35%,仍存在明显差距,这验证了改进模块在特征融合和边界识别方面的有效性。

Mini-200 数据集的消融试验数据见表 3,引入 ResNet101、DCM 与 CBAM 对于边、心材的区分具有积极作用。引入 ResNet101 与 CBAM 的 DeepLabv3+ 模型在 CPA、IoU 和 Dice 系数上高于其他模型,但 mIoU 明显

低于其他模型。Mini-200 数据集在模型训练中波动较大,可能是数据量过小使得模型学习不够充分,局部最优而未收敛至全局最优,但 DeepLabv3+ 改进模型的性能较基础模型都有一定的提升,最终改进模型心材的 PA 和 IoU 分别提升 0.28% 和 0.19%,CPA、mIoU 和 Dice 系数分别提高 0.44%、0.44%、0.14%,说明 ResNet101、DCM 与 CBAM 对于边、心材的分割起正向作用,应扩大数据集进一步验证改进的 DeepLabv3+ 模型性能。

Mids-3200 数据集的消融试验数据见表 4,DeepLabv3+ 最终改进模型的 PA、IoU、mIoU 和 Dice 系数都

表3 Mini-200数据集消融试验结果
Tab. 3 Results of ablation experiments for Mini-200

模型 Model	像素准确率(PA) Pixel accuracy		类别像素准确率 (CPA) Class pixel accuray	交并比(IoU) Intersection over union		平均交并比(mIoU) Mean intersection over union	Dice系数 Dice coefficient
	心材 Heartwood	边材 Sapwood		心材 Heartwood	边材 Sapwood		
	Baseline	98.35	98.65	98.51	98.38	73.52	85.95
Baseline(ResNet101)	95.01	97.42	96.23	98.12	70.25	84.19	98.82
Baseline + CBAM	98.24	98.76	98.52	98.56	75.44	85.50	99.16
Baseline + CBAM(ResNet101)	98.94	99.01	99.05	98.81	76.39	87.60	99.43
Baseline + DCM	98.29	98.65	98.47	98.54	76.58	87.56	99.34
Baseline + DCM(ResNet101)	98.21	98.84	98.69	98.23	75.56	86.90	99.23
Baseline + CBAM + DCM	98.38	98.91	98.67	98.54	75.45	87.00	99.29
Baseline + CBAM + DCM(ResNet101)	98.63	99.20	98.95	98.57	74.21	86.39	99.21

注: Baseline表示使用SGD优化器的DeepLabv3+原始消融模型。

Note: Baseline represents the DeepLabv3+ raw ablation model using the SGD optimizer.

高于其他模型,其他改进模型5个评价指标也都有明显的提升。虽然加入CBAM的DeepLabv3+模型的CPA和IoU表现最好,但其他3个评价指标较低,说明模型不够稳定。最终的DeepLabv3+改进模型心材的

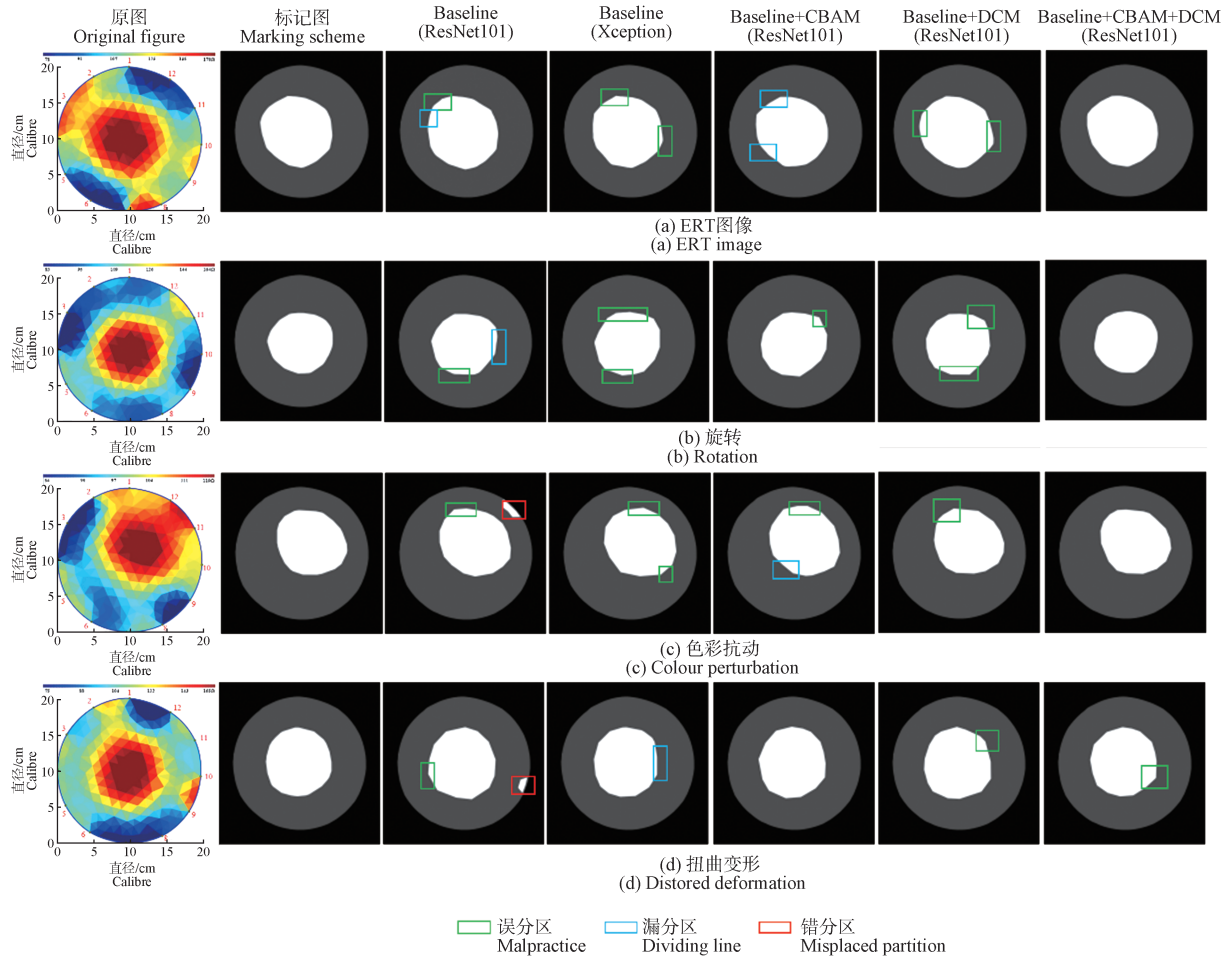
PA和IoU相比基础模型分别提高0.32%和2.45%, CPA、mIoU和Dice系数分别提高0.47%、2.13%、0.25%。试验验证了改进模型对落叶松边、心材分割的有效性。

表4 Mids-3200数据集消融试验结果
Tab. 4 Results of ablation experiments on the Mids-3200

模型 Model	像素准确率(PA) Pixel accuracy		类别像素准确率 (CPA) Class pixel accuray	交并比(IoU) Intersection over union		平均交并比(mIoU) Mean intersection over union	Dice系数 Dice coefficient
	心材 Heartwood	边材 Sapwood		心材 Heartwood	边材 Sapwood		
	Baseline	98.62	98.44	98.53	96.35	77.62	86.99
Baseline(ResNet101)	98.56	98.26	98.41	97.42	75.62	86.52	99.19
Baseline + CBAM	96.43	96.09	96.26	98.43	76.60	87.52	99.36
Baseline + CBAM(ResNet101)	98.69	99.39	99.04	98.80	73.57	86.19	99.11
Baseline + DCM	98.72	98.52	98.62	97.50	76.15	86.83	99.25
Baseline + DCM(ResNet101)	98.69	98.33	98.51	97.61	78.97	88.29	99.23
Baseline + CBAM + DCM	98.81	99.13	98.97	98.67	75.19	86.93	99.16
Baseline + CBAM + DCM(ResNet101)	98.94	99.06	99.00	98.80	79.43	89.12	99.50

Mids-3200数据集可视化显示,如图6所示。所有模型都能够分割边、心材与背景,但分割准确性有差异。其中,单独使用ResNet101的DeepLabv3+模型误将一部分边材识别成心材(红色错分区),此种错误较为严重,同时误分与错分情况发生频率也较高(绿色误分区、蓝色漏分区),但误分与错分的面积较小。基础

模型与使用ResNet101与DCM的改进模型经常出现误分的情况。而使用ResNet101与CBAM的改进模型漏分的概率较高,误差率较基础模型有所下降。使用ResNet101、DCM与CBAM的DeepLabv3+模型分割效果最接近标记图,偶尔会出现误分情况,误差小,分割效果最优。



白色部分表示心材;灰色部分表示边材;黑色部分为背景。

The white portion indicates the heartwood, the gray portion indicates the sapwood, and the black portion is the background.

图 6 Mids-3200 数据集可视化对比图

Fig. 6 Comparison plot of Mids-3200 dataset visualization

5 结论

针对落叶松心材智能识别问题,将电阻断层成像技术(ERT)与深度学习相结合,构建融合深度学习与图像处理技术的识别框架。研究结论如下。

1) 研究发现 ERT 图像中心边材交界处电阻变化率介于 90%~94%, ERT 图像识别可参照该阈值作为数据集标注标准。

2) 针对心边材边界模糊、识别难问题,构建了 DeepLabv3+模型。从准确率(PA)、精确率(CPA)、交并比(IoU)、平均交并比(mIoU)和Dice 系数 5 个维度对模型进行判定,与 Transfuse、U-Net、PSPNet、SegNet 等模型对比发现,DeepLabv3+模型的心材 PA 与 IoU 指标高 16.51% 和 3.89%, CPA、mIoU 和 Dice 系数高 12.59%、2.84% 和 2.09%,证明 DeepLabv3+模型识别 ERT 图像中心边材效果最优。

3) 针对深度学习模型对心材边界特征提取能力欠佳的问题,提出一种基于 DeepLabv3+的改进模型。该模型利用 ResNet101 替代 Xception 作为骨干网络以提取更精细的心材特征;引入特征强化模块(DCM)通过多尺度空洞卷积增大感受野,捕获更广泛的上下文信息;融合包含通道注意力和空间注意力的 CBAM 模块以关注边心材分界的关键特征。Mids-3200 数据集消融试验表明,改进模型在心材区域的 PA 和 IoU、mPA、mIoU、Dice 系数指标均显著提升,提升幅度分别为 0.32%、2.45%、0.47%、2.13%、0.25%。可视化结果证明,改进模型整体分割性能优于原始模型,在边材与心材相似度较高时也可有效分割心材区域。

参 考 文 献

[1] 杨柳,方崇荣,张建,等. 气质联用鉴别降香黄檀与越南香枝的研究[J]. 南京林业大学学报(自然科学版), 2016,40(1):97-103.

- YANG L, FANG C R, ZHANG J, et al. The identification of *Dalbergia odorifera* and *D. tonkinensi* by gas chromatography mass spectrometry [J]. Journal of Nanjing Forestry University (Natural Sciences Edition), 2016, 40(1): 97–103.
- [2] EL HACHLAFI N, LAKHDAR F, KHOUCHLAA A, et al. Health benefits and pharmacological properties of hinokitiol [J]. Processes, 2021, 9(9): 1680.
- [3] DIVAKARA B N, CHAITHRA S. Electric resistance tomograph (ERT): A review as non-destructive tool (NDT) in deciphering interiors of standing trees [J]. Sensing and Imaging, 2022, 23(1): 18.
- [4] 杨露露, 董喜斌, 徐华东. 电阻法和应力波法在活立木内部腐朽缺陷检测中的对比 [J]. 森林工程, 2022, 38(4): 82–88.
- YANG L L, DONG X B, XU H D. Comparison between electrical resistance method and stress wave method in the detection of decay defects in living trees [J]. Forest Engineering, 2022, 38(4): 82–88.
- [5] GUYOT A, OSTERGAARD K T, LENKOPANE M, et al. Using electrical resistivity tomography to differentiate sapwood from heartwood: Application to conifers [J]. Tree Physiology, 2013, 33(2): 187–194.
- [6] URSELLA E. In-line industrial computed tomography applications and developments [D]. Venezia, Italy: Università Ca'Foscari Venezia, 2021.
- [7] HATTA H R, NURDIATI S, HERMADI I, et al. Grade classification of agarwood sapwood using deep learning [J]. International Journal on Informatics Visualization, 2024, 8(4): 2075–2081.
- [8] 张立峰, 佟彤, 肖凯. 基于深度森林及电阻层析成像的气液两相流流型辨识 [J]. 计量学报, 2023, 44(6): 893–898.
- ZHANG L F, TONG T, XIAO K. Flow pattern identification of gas-liquid two-phase flow based on deep forest and electrical resistance tomography [J]. Acta Metrologica Sinica, 2023, 44(6): 893–898.
- [9] VINCIGUERRA A, ALEARDI M, MADSEN L M, et al. Stochastic inversion of time-lapse electrical resistivity tomography data by means of an adaptive ensemble-based approach [J]. Geophysical Prospecting, 2024, 72(1): 268–284.
- [10] 范妍洁, 卢玉斌, 陈少波, 等. 基于微波法与电阻率法的智能冬笋探测器 [J]. 林产工业, 2022, 59(7): 38–42.
- FAN Y J, LU Y B, CHEN S B, et al. Intelligent winter bamboo shoot detector based on microwave and resistivity method [J]. China Forest Products Industry, 2022, 59(7): 38–42.
- [11] 朱俊波, 赵冠华, 向小旭, 等. 基于传感涂层的混凝土裂缝电阻层析成像检测 [J]. 无损检测, 2023, 45(8): 8–13.
- ZHU J B, ZHAO G H, XIANG X X, et al. Electrical resistance tomography detection of concrete cracks based on sensor coatings [J]. Nondestructive Testing, 2023, 45(8): 8–13.
- [12] 时小龙, 王立海, 徐华东, 等. 基于阻抗仪和 ERT 技术的红松内部腐朽定量检测 [J]. 北京林业大学学报, 2017, 39(9): 102–111.
- SHI X L, WANG L H, XU H D, et al. Quantitative characterization of decay detection in standing trees of Korean pine based on Resistograph and ERT [J]. Journal of Beijing Forestry University, 2017, 39(9): 102–111.
- [13] BIEKER D, RUST S. Non-destructive estimation of sapwood and heartwood width in Scots pine (*Pinus sylvestris* L.) [J]. Silva Fennica, 2010, 44(2): 267–273.
- [14] GUYOT A, OSTERGAARD K T, LENKOPANE M, et al. Using electrical resistivity tomography to differentiate sapwood from heartwood: Application to conifers [J]. Tree Physiology, 2013, 33(2): 187–194.
- [15] CZAJKA M, FABISIAK B, FABISIAK E. Emission of volatile organic compounds from heartwood and sapwood of selected coniferous species [J]. Forests, 2020, 11(1): 92.
- [16] CHOLLET F. Xception: Deep learning with depthwise separable convolutions [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). July 21–26, 2017, Honolulu, HI, USA. IEEE, 2017: 1800–1807.
- [17] SI Y Z, XU H Y, ZHU X Z, et al. SCSA: Exploring the synergistic effects between spatial and channel attention [J]. Neurocomputing, 2025, 634: 129866.
- [18] YEUNG M, SALA E, SCHÖNLIEB C B, et al. Focus U-Net: A novel dual attention-gated CNN for polyp segmentation during colonoscopy [J]. Computers in Biology and Medicine, 2021, 137: 104815.
- [19] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C]//2017 IEEE International Conference on Computer Vision (ICCV). October 22–29, 2017, Venice, Italy. IEEE, 2017: 2999–3007.