

doi: 10.11823/j.issn.1674-5795.2025.04.06

基于改进YOLO的动态加权竹木缺陷检与评估方法

张沛轩¹, 董一巍^{1*}, 张悺¹, 殷锐扬¹, 吴仙星², 李首政³

(1. 厦门大学 航空航天学院, 福建 厦门 361005; 2. 南平智创技术服务有限公司, 福建 南平 354200;

3. 广州阿普顿自动化系统有限公司, 广东 广州 510530)

摘要: 针对当前竹木加工机械性能不足及竹木材料固有缺陷所导致的加工成品质量不稳定问题, 聚焦于木材智能制造过程中的缺陷检测关键技术, 提出了一种基于改进YOLO(You Only Look Once)目标检测算法的集成化质量评估系统。该系统创新性地引入了多参数缺陷权重机制, 通过量化分析缺陷尺寸、缺陷特征及缺陷严重性等关键指标, 构建了基于模糊综合评价的木材质量分级模型。实验结果表明: 该系统能够有效地将木材产品划分为优等品(A级)、良品/合格品(B级)及不合格品(C级)3个等级。在Plywood木材缺陷数据集上, 实现了91.3%的全类别平均精度均值(mean Average Precision@0.5, mAP@0.5), 其动态权重分级策略与人工评估结果的误差低于5%(欧氏距离0.063, 杰卡德指数0.892), 为木材智能制造提供了高效、可扩展的质量评估范式, 具备显著的工程应用价值。

关键词: 木材缺陷检测; YOLO; 目标检测; 缺陷权重; 模糊综合评价

中图分类号: TB9; TP391 **文献标志码:** A **文章编号:** 1674-5795 (2025) 04-0074-13

Dynamic weighted method for defect detection and evaluation in bamboo and wood materials based on improved YOLO

ZHANG Peixuan¹, DONG Yiwei^{1*}, ZHANG Yi¹, YIN Ruiyang², WU Xianxing², LI Shouzheng³

(1. School of Aerospace Engineering, Xiamen University, Xiamen 361005, China; 2. Nanping Zhichuang Technology Services Co., Ltd., Nanping, 354200, China; 3. Guangzhou Upton Automation Systems Co., Ltd., Guangzhou 510530, China)

Abstract: To address the unstable quality of processed bamboo and wood products caused by both the performance limitations of current processing machinery and the inherent defects of bamboo and wood materials, this study focuses on key defect detection technologies within intelligent wood manufacturing, and proposes an integrated quality assessment system based on an improved YOLO (You Only Look Once) object detection algorithm. Innovatively, the system incorporates a multi-parameter defect weighting mechanism, enabling quantitative analysis of critical indicators such as defect size, characteristics, and severity. Subsequently, a wood quality grading model was constructed using fuzzy comprehensive

收稿日期: 2025-05-30; **修回日期:** 2025-07-07

基金项目: 国家自然科学基金项目(52475491, 51705440); 南平市科技计划项目(N2023Y008); 国家科技重大专项项目(J2019-II-0022-0043, J2019-VII-0013-0153); 航空科学基金项目(20170368001, 20230003068002, 20240003068001); 中科院-福建省STS项目(2022T3071); 福建省自然科学基金项目(2019J01044); 四川省科技计划项目(2025YFHZ0039); 华中科技大学智能制造装备与技术全国重点实验室开放基金项目(IMETKF2024013); 厦门大学四川研究院开放课题项目(202401YB002)

引用格式: 张沛轩, 董一巍, 张悺, 等. 基于改进YOLO的动态加权竹木缺陷检测与评估方法[J]. 计测技术, 2025, 45(4): 74-86.

Citation: ZHANG P X, DONG Y W, ZHANG Y, et al. Dynamic weighted method for defect detection and evaluation in bamboo and wood materials based on improved YOLO[J]. Metrology & Measurement Technology, 2025, 45(4): 74-86.



evaluation. Experimental results demonstrate that the system effectively categorizes wood products into three grades: superior (Grade A), qualified (Grade B), and unqualified (Grade C). For the Plywood wood defect dataset, the system achieved mean average precision@0.5 (mAP@0.5) of 91.3%. Moreover, the dynamic weighting-based grading strategy showed a deviation of less than 5% compared to manual evaluation results (Euclidean distance: 0.063; Jaccard index: 0.892). This research provides an efficient and scalable quality assessment paradigm for intelligent wood manufacturing, demonstrating significant engineering application value.

Key words: wood defect detection; YOLO; object detection; defect weight; fuzzy comprehensive evaluation

0 引言

竹木作为全球利用率超过50%的可再生资源,广泛应用于建筑(占比28.6%)、家具制造(占比34.2%)等领域,其质量稳定性直接关系到下游产品的可靠性^[1]。然而,传统的人工检测方式存在效率低下(检测约30~50片/h)、主观性强等问题^[2];另一方面,工业现场较差的光照条件和细粒度缺陷(如直径小于5 mm的虫眼)等对自动化检测系统提出了严峻挑战^[3]。早期用于无损检测领域的空耦超声(Air Coupled Ultrasound, ACU)^[4]技术可以探测到木材内部缺陷,但受检材检测速度慢以及需要定量传播路径影响,工程适用性不强。随着计算机视觉和深度学习的发展,越来越多基于图像的自动检测方案被提出。

在竹木缺陷检测领域, KOBAYASHI K等人^[5]率先将X射线计算机断层扫描(Computed Tomography, CT)技术应用于木材种类识别,其多尺度特征提取方法为后续缺陷检测提供了重要参考; QAYYUM R等人^[6]通过融合灰度共生矩阵与粒子群优化算法,将木节分类准确率提升至78.26%,但传统机器学习方法在特征工程方面的局限性仍然显著。深度学习通过多层次特征抽象能力,显著提升了对木材的检测性能: HE T等人^[7]采用全卷积网络实现木材定位(准确率91.7%); URBONAS A等人^[8]在快速区域卷积神经网络(Faster Region Convolutional Neural Network, Faster R-CNN)框架中引入ResNet152,使表面缺陷检测全类平均正确率达到80.6%; MOHSIN M等人^[9]进一步开发了基于MobileNetv3的实时检测系统,处理速度突破50 ms/f。但现有方法仍面临形态特征与质量等级关联性弱、动态环境适应性不足等问题。

1 研究现状及本文创新

1.1 传统检测方法

早期木材缺陷检测主要依赖于物理特性分析。CONNERS R W等人^[10]开发的CT-光学多模态系统虽将准确率提升至92.4%,但设备结构复杂,限制了其工业应用。ZHANG T等人^[11]提出的超声波法通过声波反射检测孔洞,但效率低且依赖操作经验; MARHENKE T等人^[4]开发的ACU技术虽实现非接触检测,但对<1 mm缺陷的识别误差达±5%; 戚大伟等人^[12]利用X射线成像结合胡氏不变矩与反向传播神经网络对木材缺陷进行检测,然而该方法检测成本高,并且需要人工提取缺陷形状特征,预处理过程繁琐、涉及多个步骤,最终检测准确率仅为86%。

1.2 深度学习检测方法

在双阶段检测器中, URBONAS A等人^[8]采用ResNet152-Faster R-CNN实现了80.6%的全类平均正确率,但推理速度较慢(200 ms),难以满足实时检测需求。在单阶段算法方面,程大全等人^[13]提出的CBi2-YOLO通过引入微小目标检测头,将裂缝识别率提升至82.1%; MOHSIN M等人^[9]基于轻量化MobileNetv3系统实现了50 ms的实时检测,但细粒度缺陷识别精度下降7.2%。现有的方法在多尺度缺陷检测和同步检测能力方面仍存在不足。例如, DING F等人^[14]改进了单次多框检测器(Single Shot MultiBox Detector, SSD)算法,但在多缺陷场景下,漏检率依然高达18.4%。与此同时,传统的CNN模型(如ResNet50)存在计算复杂度过高的问题(达到11.6 GFLOPs),这使其难以部署到边缘设备上^[15]。此外,现有的分类方法对微小缺陷的敏感度也存在不足。

1.3 木材质量评估方法

当前木材质量评价研究虽已建立基础标准体系(如 ASTM D1666-87)^[16],但仍存在显著局限性。为构建科学、可操作的综合评价方法,需主要解决以下3方面的问题:

1) 检测方法主观性强

现有标准依赖人工视觉判定缺陷(如 Raised grain、Fuzzy grain 等)并划分等级(excellent 至 very poor),对检测者经验要求高,劳动强度大,且难以适应机械化生产需求^[17]。

2) 评价体系不完善

研究多聚焦木材分类与单一缺陷识别,缺乏针对综合质量评价的量化模型。尽管我国已制定128项相关标准(涵盖材质判定、材积计算等),但评价指标分散,未形成系统化多指标融合模型^[18],导致评价结果主观性突出。

3) 理论与实践脱节

现有成果以描述性研究为主,缺乏面向企业生产的技术指导。木材质量评价仍停留在理论层面,未能解决实际生产中的质量量化与等级综合判定问题。

1.4 本文创新

本文提出了一种创新质量评估系统,在改进YOLO算法的基础上引入缺陷权重机制,根据缺陷大小和严重程度赋予不同权重,实现对木材质量的综合评估。该系统具有以下三大技术突破:①

多参数缺陷加权机制:整合 CONNERS R W 团队^[10]

提出的多模态特征融合思想,结合缺陷尺寸、缺陷特征及缺陷严重性构建综合评价体系;②增强型 YOLO 架构:对特征金字塔网络(Feature Pyramid Network, FPN)进行结构化改进,提升竹材特异性缺陷检测精度;③模糊综合评价模型:通过自适应阈值设定,建立 A/B/C 三级质量分级标准。

2 方法

2.1 数据集

本文采用 Plywood 木材缺陷检测数据集^[19]作为核心实验数据源。该数据集是木材表面缺陷检测领域内广泛使用的开源数据集,共包含 9 402 张高清图像,涵盖木材加工与质检场景中 8 类典型缺陷类型(如表 1 所示),包括:石英质(Quartzity)、活结(Live Knot)、髓心变异(Marrow)、树脂囊(Resin)、死结(Dead Knot)、裂纹节(Knot with Crack)、节子缺失(Knot Missing)、裂纹(Crack)。如图 1 所示,各类缺陷实例数量呈现显著差异,其中活结(类别 1)占比最高(约 9 000 例),死结(类别 4)次之(约 7 000 例),其余类型分布相对均衡。为生成更多的训练样本,本文对数量较少的缺陷类型进行数据增强。数据集的图像分辨力统一且细节清晰,图 2(a)的热力图分析表明:样本在空间维度和尺寸分布上具有典型工业特征,能够充分反映真实环境中木材缺陷的复杂形态与纹理特征。数据集的标

表 1 不同类别对应的缺陷名称

Tab.1 Names of defects corresponding to different numbers

类别	术语	中文译名	专业定义与特征
0	Quartzity	石英质	石英颗粒沉积形成的矿物线,常见于树皮附近,硬度较高,可能造成加工刀具磨损。
1	Live knot	活结	由存活枝条形成,年轮与周围木材连续生长,纹理自然衔接,材质坚硬构造完整。
2	Marrow	髓心变异	树干中心疏松组织,呈褐色软质,含水量高易腐朽,常见于原木横截面中心区域。
3	Resin	树脂囊	树脂聚集形成的囊状空隙,多见于针叶材,可能渗出黏性物质影响胶合性能。
4	Dead knot	死结	由枯死枝条形成,与周围木材脱离,内部腐朽呈筛孔状或粉末状,易脱落形成空洞。
5	Knot with crack	裂纹节	节子周围伴随放射状裂纹,裂纹深度可达木质部,显著降低木材抗弯强度。
6	Knot missing	节子缺失	原节子部位脱落形成的孔洞,边缘呈不规则锯齿状,常见于死节腐朽后。
7	Crack	裂纹	木材纤维分离形成的线性缺陷中按成因分干裂(干燥收缩引起)和冻裂(低温导致)。

注工作由相关专家完成,采用边界框与类别标签联合标注的方式,标注框尺寸分布特征可通过图2(b)缺陷分布图直观呈现。标注过程严格遵循木材检测行业标准,并结合图3所示的三维结构可视化分析,为监督学习算法的训练与性能评估提供高置信度的基准数据。




图1 各类缺陷实例数量

Fig.1 Number of defect instances




图2 缺陷热力图和分布图

Fig.2 Visual analysis of defect spatial distribution

2.2 基于改进YOLO算法的目标检测

为提升木材表面缺陷检测的实时性与准确性,本文对YOLO算法展开系统性改进,构建适用于工业场景的轻量化智能检测框架。图4为改进YOLO的动态加权竹木缺陷评估方法总体框图,改进方案从内存管理、网络架构2个维度入手,在保证检测精度的同时提升了模型的运行效率;同时,动态权重公式对缺陷严重性进行量化,为木材加工行业的自动化质检提供了可行的技术解决方案。





图3 三维结构可视化分析

Fig.3 Visual analysis of 3D structure



注: 缺陷权重计算见式(1), 累积总权重计算见式(4)。

图4 改进YOLO的动态加权竹木缺陷评估方法总体框图

Fig.4 Overall block diagram of improved YOLO dynamic weighted bamboo and wood defect assessment method

2.2.1 内存优化策略

针对工业检测设备普遍存在的显存受限问题,本研究设计了一套三级内存管理机制,以实现计算资源的精细化管控。在系统级配置层面,通过设置 NumPy 内存回收策略并启用计算统一设备架构(Compute Unified Device Architecture, CUDA)内核优化,有效降低特征计算过程中的内存占用。进一步引入混合精度训练技术,将该模型的训练所占内存从开始的 8.2 GB 缩小至 5.1 GB。在保证数值稳定性的前提下,平均节约内存约 39%。为防止显存碎片化,开发了动态资源监控模块,在每个训练周期结束后自动执行垃圾回收与显存清理操作,使显存碎片率降低。实测结果表明:该机制可有效避免训练中断,在典型工业检测场景下将系统内存占用稳定控制在 6 GB 以内,满足消费级显卡部署需求。

2.2.2 网络架构改进

针对木材缺陷检测任务中目标尺寸差异大、纹理特征复杂的特点,对 FPN 进行结构化改进。




图5 FPN 结构化改进方法

Fig.5 Structural improvement of FPN

如图5所示,采用转置卷积上采样代替简单插值上采样,以保留更多空间信息;同时,为确保特征图尺寸对齐,添加了参数匹配修正技术。通过转置卷积和自适应卷积层的协同作用,有效提升特征上采样质量,解决了传统 FPN 中特征映射不一致的问题。在原始的 FPN 结构中,不同层级特征图(C3、C4、C5)直接生成对应的输出特征(P3、P4、P5)。在改进的 FPN 中,不同层级特征图分别经过自适应卷积处理后,再通过转置卷积进行上采样,接着进行参数匹配修正,最后通过多尺度融合得到最终输出特征。实验结果表明:优化后的网络架构在木材缺陷数据集上的 mAP@0.5 达到 91.3%。

2.3 缺陷权重机制的数学建模与推导

2.3.1 权重公式

为量化不同类型缺陷对木材质量的影响差异,本文提出一种基于多维度特征的缺陷权重计算方法。设木材表面检测到第 i 个缺陷的属性特征为 (c_i, A_i) , 其中, $c_i \in C$, 表示缺陷类别, $C = \{\text{裂纹, 死结, 活结, } \dots\}$; A_i 为缺陷面积(单位: px^2), 其数据来源于对木材表面图像进行缺陷检测与分割后,统计缺陷区域内所包含的像素点数量后得出的面积,即 YOLO 算法检测出的第 i 个缺陷边界框所覆盖的像素区域面积(宽 $\times$ 高)。 A_{total} 为木材表面总面积, T_{big} 为大缺陷面积阈值,根据具体木材类型和应用场景设定,通常取该类型木材常见缺陷面积的 90% 分位数。本实验中设定 $T_{\text{big}} = 1\,024\, \text{px}^2$, 定义该缺陷的权重 w_i 为

$$w_i = \alpha_{c_i} \cdot \left(\frac{A_i}{A_{\text{total}}} \right)^\gamma \cdot [1 + \eta \cdot \mathbb{I}(A_i > T_{\text{big}})] \quad (1)$$

式中: α_{c_i} 为类别严重性系数; γ 为面积影响因子, $\gamma \geq 1$; η 为大缺陷惩罚系数, $\eta = 0.5$; $\mathbb{I}(\cdot)$ 为示性函数(当 $A_i > T_{\text{big}}$ 时取 1, 否则取 0)。

2.3.2 参数确定

1) 类别严重性系数 α_{c_i} 的确定

参考 GB/T 4822-1999《锯材检验》^[20]、GB/T 18000-1999《木材缺陷图谱》^[21]以及 GB 50206-2002《木结构工程施工质量验收规范》^[22], 并邀请 10 位建材专家对缺陷类型进行独立评价,对缺陷严重性进行完整评估(评分范围 1~10 分, 10 分为最严

重)。综合评估结果表明：对木材的强度和使用影响较大的缺陷有4类——裂纹(显著降低木材结构强度，破坏其连续性，容易引发断裂)、死节(节子与周围木材脱离，常伴有中心腐朽或空洞)、裂纹节(削弱木材整体强度)、树脂囊(影响加工精度和表面质量)。

评分结果取平均值并归一化，如式(2)所示。

$$\alpha_{ci} = 1 + \frac{\bar{S}_i}{\max(S_i)} \quad (2)$$

式中： $\bar{S}_i$ 为第*i*类缺陷平均分，如裂纹平均分 $\bar{S}_{\text{Crack}} = 9.2$ ，则裂纹严重性系数 $\alpha_{\text{Crack}} = 1 + 9.2/10 = 1.92 \approx 1.9$ 。

对其他类别缺陷采用相同方法进行处理，并将所有结果总结于表2。

表2 不同缺陷类别的严重性系数 α_{ci}
Tab.2 Severity coefficient α_{ci} of different defect category

缺陷类别	α_{ci}	评分依据
裂纹	1.9	结构强度损失率高，易受力断裂
死节	1.8	断裂风险提升
裂纹节	1.8	断裂风险提升
树脂囊	1.5	加工废品率高
其他缺陷	1.0	影响程度 $\leq 10\%$

2) 面积影响因子 γ 的确定

传统方法通常采用固定的面积影响因子 γ ，忽略了木材尺寸差异，本文针对不同木材尺寸差异对缺陷的影响，提出了一种灵活的分段动态调整策略， γ 的计算公式为

$$\gamma = \begin{cases} 1.0, & A_{\text{total}} < 2\,000 \text{ px}^2 \\ 1.2, & 2\,000 \text{ px}^2 \leq A_{\text{total}} < 10\,000 \text{ px}^2 \\ 1.5, & A_{\text{total}} \geq 10\,000 \text{ px}^2 \end{cases} \quad (3)$$

对式(3)进行推导的理论依据如下：对于小尺寸木材($A_{\text{total}} < 2\,000 \text{ px}^2$)，面积占比 A_i/A_{total} 易被放大，因此，选择 $\gamma = 1.0$ ，使权重函数退化为线性关系，避免微小缺陷过惩罚；对于常规尺寸($2\,000 \text{ px}^2 \leq A_{\text{total}} < 10\,000 \text{ px}^2$)，采用 $\gamma = 1.2$ 以适度强化面积影响，这是因为 $(A_i/A_{\text{total}})^{1.2}$ 比线性增长快19%(当 $A_i/A_{\text{total}} = 0.1$ 时)；对于大尺寸木材

($A_{\text{total}} \geq 10\,000 \text{ px}^2$)，设置 $\gamma = 1.5$ ，可显著提升大缺陷权重，当 $A_i = 0.1 A_{\text{total}}$ 时，其权重比线性模型高41%。

2.4 质量评估模型

2.4.1 总权重计算与等级划分

1) 累计总权重 W 为

$$W = \sum_{i=1}^N w_i \quad (4)$$

式中：*i*为当前缺陷的序号，*N*为一张图中的缺陷总数量， w_i 为当前缺陷的权重。

2) 阈值确定方法

收集历史合格样本，计算 W 的累积分布函数(Cumulative Distribution Function, CDF)为

$$\begin{aligned} W_1 &= \text{Quantile}(W, 0.95) \\ W_2 &= \text{Quantile}(W, 0.99) \end{aligned} \quad (5)$$

式中：Quantile函数用于计算数据集中某个特定分位数对应的值，即式(5)表示95%~99%的数据小于或等于 W 。例如，在某聚合木数据集中测得 $W_1 = 0.004$ ， $W_2 = 0.08$ 。

3) 分级规则

$$\text{质量等级} = \begin{cases} \text{优等品}, & W \leq 0.004 \\ \text{良等品}, & 0.004 < W \leq 0.08 \\ \text{不合格品}, & W > 0.08 \end{cases} \quad (6)$$

2.4.2 理论支撑

当样本量 $n \rightarrow \infty$ 时，阈值估计量 $\hat{W}_p$ 收敛于真实分位数 W_p 。根据格列汉科定理，经验分布函数 $\hat{F}_n(W)$ 一致收敛于真实分布函数 $F(W)$ 。

$$\sup_W |\hat{F}_n(W) - F(W)| \xrightarrow{a.s.} 0 \quad (7)$$

因此，分位数估计量 $\hat{W}_p = \hat{F}_n^{-1}(p)$ 满足式(8)。

$$\forall \epsilon > 0, \lim_{n \rightarrow \infty} P(|\hat{W}_p - W_p| > \epsilon) = 0 \quad (8)$$

式中： P 为概率函数。

这表明：随着样本量的增加，分位数估计量 $\hat{W}_p$ 会以概率1收敛于真实分位数 W_p 。从理论上证明了本文质量评估模型中阈值估计的准确性和有效性，为其在不同场景下的应用提供了理论依据。

3 实验与结果

3.1 实验设置

实验环境和数据集配置如表3所示。选用Plywood木材缺陷检测数据集，其中包含裂纹、活结

等多种常见木材缺陷的高清图像。数据集具体划分如下：训练集共 8 685 张图像，占总数据集的 92%；验证集共 540 张图像，占总数据集的 6%；

测试集共 177 张图像，占总数据集的 2%。测试集比例参考工业质检场景中实时性需求，且通过多次随机划分验证结果稳定性。

表3 实验设置

Tab.3 Experimental setup

实验设置	硬件环境	数据集	评价指标
细则	NVIDIA RTX4060 GPU, CUDA 12.6	Plywood 数据集: 9 402 图片, 8 种类别	准确度, F1 评分, 混淆矩阵

3.2 实验结果

为全面评估本文提出方法的性能，选取当前主流的轻量级目标检测模型 YOLOv5n、YOLOv9n、YOLOv8n 和 YOLOv11n 作为对比模型，并引入 Faster R-CNN 和 RetinaNet 分别作为经典两阶段和单阶段检测方法的代表。同时引入实时检测变换器 - 大型版本 (Real-Time DETection TRansformer-Large, RT-DETR-L) 作为最新检测方法的代表。在相同实验条件下，采用 mAP@0.5 和 F1 评分等关键指标对各模型的检测性能进行评估。不同模型在本数据集上的测试结果如表 4 所示。

从表 4 可看出，本文所提方法整体性能优于其他对比模型。具体而言，本文模型 mAP@0.5 达到 91.3%，F1 评分达到 0.89，均优于现有模型。相较于 YOLOv5n、YOLOv8n、YOLOv8n 和 YOLOv11n，本文模型在保持高精度的同时，进一步优化了模型的内存占用与训练效率，提升了综合性能。

此外，与传统两阶段模型 Faster R-CNN 相比，本文模型不仅在检测精度上有明显优势，还具备更低的运算复杂度，满足实际应用中对速度与精度的双重需求。与 RetinaNet 相比，本文模型在保持相近 F1 的同时，mAP@0.5 实现了更高突破。

表4 模型在数据集上检测结果

Tab.4 The test results of model on data set

模型	mAP@0.5 / %	F1	参数量 / M	计算复杂度 / G
Faster-R-CNN	87.7	0.87	138	200
RetinaNet	89.3	0.89	34	340
YOLOv5n	89.6	0.87	1.9	4.5
YOLOv8n	90.3	0.87	1.2	8.9
YOLOv9n	90.3	0.88	2.0	10
YOLOv11n	90.7	0.88	2.62	6.6
RT-DETR-L	91.2	0.88	42.8	
YOLOv11n + FPN 重构	91.3	0.89	2.78	7.6
YOLOv11n + FPN 重构 + 内存优化(本文方法)	91.3	0.89	2.78	7.6

相较最新轻量级模型 RT-DETR-L，本文模型在参数量降低 93.5% 的情况下，两者的 mAP@0.5 接近，凸显本文模型设计的优越性。

综上所述，实验结果表明：本文提出的模型在参数量 (2.78 M) 与计算复杂度 (GFLOPS 7.6 G) 影响不大的情况下，实现了 mAP@0.5 = 91.3%、

F1 = 0.89 的领先性能，在评估指标上均取得了最优表现，验证了其在目标检测任务中的优越性。


表 5 中消融实验结果表明：FPN 重构使 mAP@0.5 提升 0.6%；内存优化策略在保持精度不变的同时，将训练内存占用率降低 39.3%。消融实验的结果说明：FPN 重构有效增强了多尺度特征融合

能力，为精度提升提供了有力支撑；内存优化策略在不影响模型表达能力的前提下，显著降低了资源消耗。

如图6所示，本文的模型不仅能识别出木材缺陷的类别，还能正确地检测出缺陷的位置，为木材的缺陷检测以及后续的不良品分类提供了支撑。

表5 消融实验
Tab.5 Ablation experiment

模型	mAP@0.5/%	F1	训练内存/GB
YOLOv11n	90.7	0.88	8.2
YOLOv11n + FPN 重构	91.3	0.89	8.4
YOLOv11n + FPN 重构 + 内存优化(本文方法)	91.3	0.89	5.1



注：1、2、...7代表不同的缺陷类别。

图6 使用YOLO进行缺陷检测及分类(1、2、...7)的示例
Fig.6 Examples of defect testing and classification by using YOLO

如图7所示，F1-置信度曲线揭示了模型检测性能与置信度阈值间的动态关系。曲线呈现典型“先升后降”趋势：当置信度从0提升至0.366时，F1值从初始0.45快速攀升至峰值0.89(对应表4中0.4置信度区间的0.89)，表明模型在此区间能有效平衡精确率与召回率；当置信度超过0.4后，F1随阈值呈单调递减趋势，并在至置信度为1.0时归零，这源于过高置信度阈值导致的漏检率激增。

为进一步研究模型检测不同缺陷类别的性能，分析本文方法的准确率/召回率和mAP@0.5值，如图8所示。图9中展示了不同类别的准确率-召回率关系以及每个类别的mAP@0.5值。整体而言，模型大部分类别的表现良好，但某些类别仍存在





图7 F1-置信度曲线
Fig.7 F1-confidence curve

性能差异，如类别0(石英质)缺陷的mAP@0.5值仅为0.176，表明模型针对该类别的检测性能相对较差，这可能是由于该类别的样本数量较少、特征与其他类别相似或图像质量较差等。进一步采用YOLOv5n、YOLOv8n、YOLOv11n等模型对类别0进行测试后发现：类别0的图像质量较差导致所有模型对类别0的检测效果都较差。如图9所示，分析各类缺陷识别的准确率曲线中发现，类别0的石英质缺陷存在识别不准确的情况，即部分类别0的样本没有被正确识别，即使被识别，准确率也较低；在移除类别0缺陷标签后，模型准确率回升。为防止模型过拟合，训练过程中采用了早停法(Early Stopping)来监控验证集mAP@0.5指标，当其在连续20个训练批次内无提升即终止训练。最终模型在约60个训练批次后收敛，未达到预设的100训练批次上限，表明模型未发生过拟合。



注: mAP@0.5: IoU 阈值为 0.5 时, 模型的 mAP; mAP@0.5 ~ 0.95: IoU 阈值为 0.5 ~ 0.95 时, 模型的 mAP。

图 8 模型评估指标动态曲线

Fig.8 Dynamic curve of model evaluation index




图 9 识别各类缺陷的准确率-召回率曲线

Fig.9 Precision-recall curves per defect category

各类缺陷识别的置信矩阵如图 10 所示。针对 Plywood 数据集上的木材缺陷检测任务, 通过对比实验验证了本文方法的有效性。结果表明: 本文方法的准确率、F1 值等关键指标均获得了提升。

然而, 模型在单个分类方面表现欠佳。针对这一问题, 未来可以进一步探索数据增强、迁移学习等方法, 以提高模型针对不同缺陷类别的检测性能; 同时, 也可以考虑将本文方法应用于其他类似的木材缺陷检测数据集, 以验证其泛化能力。




图 10 各类缺陷识别的置信矩阵

Fig.10 Confidence matrices of various defect identifications

3.3 缺陷评估结果分析

本文选取了典型的木材样本, 并展示系统检测过程和评估结果, 三级分类的效果示例如图 11 所示。在此基础上, 分析了不同缺陷对木材质量的影响以及不同评估策略对缺陷评估的影响。

图 12 展示了本文构建的胶合板木材缺陷检测数据集, 基于人眼视觉评估对木材样本进行品质分类的结果及其占比分布。数据集被划分为 3 个类别(A、B、C), 分别对应不同品质等级的木材。通过人工分类统计可见: B 类木材样本在数据集中占据主导地位, 占比高达 77.8%; A 类木材样本占比为 13.5%; C 类木材样本占比最少, 为 8.7%。该图清晰呈现了各类别样本在整体数据集中的比例关系, 为后续缺陷检测模型的训练与评估提供了数据分布基础。

在以人工划分结果为基准的对比实验中, 动态权重法(如图 13 所示)展现出显著的优势。相较固定权重(如图 14 所示)的分类策略, 动态权重法通过自适应调整分级阈值, 使 B 级良品率从固定权重法的 66.11% 提升至 80.19%, 更接近人工基准的 77.78%; 同时将 C 级不合格率从固定权重法的 13.52% 优化至 9.44%。这种改进源于动态权重法对缺陷特征分布的调整能力, 通过实时更新样本权重矩阵, 有效缓解了传统固定阈值方法在复杂缺陷场景中的分类偏移问题。





图 11 A / B / C 三级系统分类结果示例
Fig.11 Examples of classification results of the A, B, and C three-level systems



注：A 为 A 级优等品，B 为 B 级良品 / 合格品，C 为 C 级不合格品。

图 12 人工数据集分类
Fig.12 Classification of artificial datasets

各种缺陷划分方法和其对应的优、良、不合格比率的详细数据如表 6 所示。尽管大致缺陷面积划分法通过特征分析将 A 级优等品率提升至 29.81%，但其 C 级误判率(6.30%)低于人工基准，反映出该策略可能存在过度筛选倾向。相比之下，动态权重法在保持 A 级优等品率(10.37%)与人工基准(13.52%)合理差异的同时，通过 0.72 的 B 级良品率匹配度(动态法 80.19% vs. 人工 77.78%)和 0.69 的 C 级误判率控制(动态法 9.44% vs. 人工 8.70%)，实现了更优的分级一致性。这种分级性能的提升验证了动态权重配置策略在工业质检场景中的有效性，为减少人工复核成本、提升产线良率、提高预测精度提供了技术借鉴。

在缺陷面积划分法与原始人工标注的对比抽检中，约 10% 以上样本与人工分类的经验结果不符合，产生此现象的原因为：在直接使用缺陷面积划分法时，由于没有考虑到木材缺陷的严重程度以及 YOLO 作为缺陷检测工具时缺陷面积划分不精确的问题，导致划分结果与实际人工划分差异较大。

在固定权重法和动态权重法的比较中，使用欧氏距离 L_{ED} (Euclidean Distance, ED)、余弦相似度 C_{CS} (Cosine Similarity, CS)、KL 散度 D_{KL} (Kullback-Leibler)、杰卡德指数 J_{JI} (Jaccard Index, JI) 4 种指标对样本数据进行计算和量化。




图13 动态权重法划分效果

Fig.13 Division effect of the dynamic weight method




图14 固定权重法划分效果

Fig.14 Division effect of the fixed weight method

表6 缺陷划分方法和其对应的优、良、不合格比率

Tab.6 Defect classification methods and their corresponding superior, good and unqualified product rates

单位:%

缺陷划分方法	A 优等品率	B 良品率	C 不合格率
原始数据人工划分	13.52	77.78	8.70
按大致缺陷面积划分	29.81	63.89	6.30
固定权重法	20.37	66.11	13.52
动态权重法	10.37	80.19	9.44

其中, 预测坐标为 (x_1, y_1) , 实际坐标为 (x_2, y_2) , 则欧式距离 L_{ED} 计算方法为

$$L_{ED} = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (9)$$

余弦相似度 C_{CS} 的计算方法为

$$C_{CS} = \frac{x_1 \cdot x_2 + y_1 \cdot y_2}{\sqrt{x_1^2 + y_1^2} \cdot \sqrt{x_2^2 + y_2^2}} \quad (10)$$

D_{KL} 的计算方法为

$$D_{KL}(P||Q) = \sum_i P(i) \log_e \frac{P(i)}{Q(i)} \quad (11)$$

式中: P 为真实目标的概率分布, Q 为用来近似 P 模型的概率分布, i 为所有可能发生的事件。

杰卡德指数 J_{JI} 的计算方法为

$$J_{JI}(A, B) = \frac{|A \cap B|}{|A \cup B|} \quad (12)$$

式中: A 、 B 为固定权重法和动态权重法的2个集合。

4种指标结果如表7所示, L_{ED} 仅为0.063, 较其他方法降低73%~80%; C_{CS} 达0.998, 与人工划分高度一致; D_{KL} 数值极小, 说明其概率分布高度重合; J_{JI} 显示动态权重法正确分类比例达89.2%, 动态权重法在各类别分布方面与实际人工划分保持最佳一致性。

表7 固定权重配置法与动态权重配置法的近似实际划分缺陷的指标对比

Tab.7 Comparison of indicators for approximating to actual defect classification between the fixed weight configuration method and the dynamic weight configuration method

权重配置方法	L_{ED}	C_{CS}	D_{KL}	J_{JI}
固定权重法	0.233	0.976	0.033	0.781
动态权重法	0.063	0.998	0.005	0.892

4 结论

本文提出了一种基于改进YOLO的木材缺陷检测与质量评估系统,通过引入缺陷权重机制,实现了对木材质量的智能化评估。首先,实现了算法架构改进,通过对FPN进行结构化改进,增强模型对竹材特异性缺陷的感知能力,mAP@0.5提升至91.3%,相较传统YOLO系列模型具有显著优势;其次,改进了权重机制,引入动态权重机制,基于GB/T标准与专家评估构建多参数权重模型,结合分段面积影响因子($\gamma = 1.0 \sim 1.5$)与大缺陷惩罚系数($\eta = 0.5$),解决了固定阈值方法在复杂缺陷场景中的分类偏移问题,使B级良品率匹配人工基准达80.19%(误差<3%)。采用三级内存管理机制(显存占用<6GB),在RTX 4060显卡上实现图像的实时处理,为低算力设备部署提供了可行方案。实验结果表明:系统在分级一致性(C_{cs} 0.998)与误判控制(C级不合格率9.44%)方面优于现有方法,且通过模糊综合评价模型实现了A/B/C三级分类的自动化决策。未来,将聚焦于多模态数据融合与迁移学习,进一步提升模型对稀缺缺陷类别(如石英质)的泛化能力,推动木材加工行业向智能化、高精度方向转型。

参考文献

- [1] RAJAGOPAL H, KHAIRUDDIN A S M, MOKHTAR N, et al. Application of image quality assessment module to motion-blurred wood images for wood species identification system[J]. Wood Science and Technology, 2019, 53: 967-981.
- [2] 王勇, 张伟, 高锐, 等. 基于YOLOv4的结构用锯材表面缺陷识别[J]. 林业工程学报, 2021, 6(4): 120-126.
WANG Y, ZHANG W, GAO R, et al. Research on surface defect recognition of structural sawn timber using YOLOv4[J]. Journal of Forestry Engineering, 2021, 6(4): 120-126. (in Chinese)
- [3] ESPINOSA L, PRIETO F, BRANCHERIAU L, et al. Effect of wood anisotropy in ultrasonic wave propagation: a ray - tracing approach [J]. Ultrasonics, 2019, 91: 242-251.
- [4] MARHENKE T, NEUENSCHWANDER J, FURRER R, et al. Air-coupled ultrasound time reversal (ACU-TR) for subwavelength nondestructive imaging[J]. IEEE Transactions on Ultrasonics Ferroelectrics and Frequency Control, 2019, 99: 1-1.
- [5] KOBAYASHI K, HWANG S, OKOCHI T, et al. Non-destructive method for wood identification using conventional X-ray computed tomography data[J]. Journal of cultural heritage, 2019, 38: 88-93.
- [6] QAYYUM R, KAMAL K, ZAFAR T, et al. Wood defects classification using GLCM based features and PSO trained neural network [C]// 2016 22nd International Conference on Automation and Computing (ICAC). Colchester, UK, 2016: 273-277.
- [7] HE T, LIU Y, XU C, et al. A fully convolutional neural network for wood defect location and identification [J]. IEEE Access, 2019, 7: 123453-123462.
- [8] URBONAS A, RAUDONIS V, MASKELIUNAS R, et al. Automated identification of wood veneer surface defects using faster region - based convolutional neural network with data augmentation and transfer learning[J]. Applied sciences, 2019, 9(22): 4898-4917.
- [9] MOHSIN M, BALOGUN O S, HAATAJA K, et al. Convolutional neural networks for real-time wood plank detection and defect segmentation[J]. F1000Research, 2023, 12: 319.
- [10] CONNERS R W, MCMILLIN C W, LIN K, et al. Identifying and locating surface defects in wood: part of an automated lumber processing system [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1983 (6): 573-583.
- [11] 张甜, 程小武, 陆伟东, 等. 超声波法检测木材内部孔洞缺陷的研究[J]. 西南林业大学学报, 2016, 36(1): 121-125, 130.
ZHANG T, CHENG X W, LU W D, et al. Experimental study on testing internal hole defects of wood by ultrasonic method [J]. Journal of Southwest Forestry University, 2016, 36(1): 121-125, 130. (in Chinese)
- [12] 戚大伟, 牟洪波, 田冠华. 基于X射线与神经网络的木材缺陷分类方法[J]. 林业科学, 2013, 49(8): 112-118.
QI D W, MOU H B, TIAN G H. Wood defect classification based on X-ray and neural network[J]. Scientia Silvae Sinicae, 2013, 49(8): 112-118. (in Chinese)
- [13] 程大全. 基于深度学习的木材表面缺陷检测研究与应用[D]. 济南: 齐鲁工业大学, 2023.

- CHENG D Q. Research and application of surface defect detection in wood based on deep learning [D]. Jinan: Qilu University of Technology, 2023. (in Chinese)
- [14] DING F, ZHUANG Z, LIU Y, et al. Detecting defects on solid wood panels based on an improved SSD algorithm [J]. *Sensors*, 2020, 20(18): 5315.
- [15] 凌嘉欣. 基于RegNet的板材缺陷图像分类研究[D]. 哈尔滨: 东北林业大学, 2023.
LING J X. Research on board defect image classification based on RegNet[D]. Harbin: Northeast Forestry University, 2023. (in Chinese)
- [16] ASTM International. Standard test methods for conducting machining tests of wood and wood-base materials: ASTM D 1666—87[S]. West Conshohocken, 2011.
- [17] 黄庆维. 回顾与展望-谈谈有关我国木材标准化[J]. 木材检验, 2000(1): 29-34.
HUANG Q W. Assessment and future prospects: examine the timber standardization practices in my country [J]. *China Timber*, 2000(1): 29-34. (in Chinese)
- [18] 宋扬扬. 基于集成学习的红木木材质量评价指标的研究[D]. 昆明: 昆明理工大学, 2018.
SONG Y Y. Research on quality evaluation index of mahogany wood based on ensemble learning [D]. Kunming: University of Science and Technology, 2018. (in Chinese)
- [19] Makar Baderko. Plywood dataset[DB/OL]. [2025-05-16]. <https://universe.roboflow.com/makar-baderko-kv1k2/plywood>.
- [20] 国家质量技术监督局. 锯材检验: GB/T 4822-1999 [S]. 北京: 中国标准出版社, 1999.
The state bureau of quality and technical supervision. Defects in sawn timber: GB/ T 4822-1999 [S]. Beijing: Standards Press of China, 1999. (in Chinese)
- [21] 国家质量技术监督局. 木材缺陷图谱: GB/T 18000-1999[S]. 北京: 中国标准出版社, 1999.
The state bureau of quality and technical supervision. Illustrative plats of defects in wood: GB/ T 18000-1999 [S]. Beijing: Standards Press of China, 1999. (in Chinese)
- [22] 国家质量监督检验检疫总局. 木结构工程施工质量验收规范: GB 50206-2002[S]. 北京: 中国建筑工业出版社, 2002.
National Quality and Technical Supervision Bureau. Code for acceptance of construction quality of timber structures: GB 50206-2002 [S]. Beijing: China Architecture & Building Press, 2002. (in Chinese)

(本文编辑: 李成成)



第一作者: 张沛轩(1999—), 男, 博士研究生, 主要研究方向为智能控制、信号处理、轻量化人工智能。



通信作者: 董一巍(1982—), 男, 厦门大学航空航天学院副教授, 美国麻省理工学院博士后, 第二批中英创新领军人才, 福建省、厦门市高层次人才。中国航空学会飞行器载荷分会委员, 曾任厦门市科学技术局高新技术处副处长。长期从事航空先进制造工艺力学、无损检测评估及空天领域关键构件结构优化设计与制造方面研究, 主持和参与国家基础加强计划、国家科技重大专项、国家自然科学基金、航空科学基金、福建省自然科学基金、广东省自然科学基金、深圳市知识创新计划等二十余项科研任务, 获2024年度发明创业奖成果奖二等奖、2024年度福建省科技进步三等奖等。