

DOI: 10.12326/j.2096-9694.2025128

基于 YOLO11-SDP 模型的饰面人造板表面缺陷检测研究

韩佳锴¹, 吕斌¹, 王晓欢¹, 张伟^{1,2}, 须恺³, 刁兴良¹,
纪敏¹, 王禾¹

(1. 中国林业科学研究院木材工业研究所, 北京 100091; 2. 中国林业科学研究院木材工业研究所林草装备研究开发中心, 北京 100091; 3. 苏州华翔木业机械有限公司, 江苏苏州 215000;)



摘要: 饰面人造板作为家居行业的核心原材料, 其表面缺陷检测是质量管控的关键环节。当前基于机器视觉与YOLO系列深度学习检测方法已得到广泛应用, 但在精确率、召回率等关键指标上仍有提升空间, 且在设备资源受限场景下, 难以兼顾推理速度与检测性能。为进一步优化模型综合性能, 将其应用于饰面人造板表面缺陷检测场景, 研究提出YOLO11-SDP检测模型, 通过采用数据集Mosaic增强、BiFPN模块替换原有FPN模块、损失函数中引入尺度权重因子等3项组合策略对原有模型进行改进。试验结果表明, 改进模型YOLO11-SDP精确率达98.0%、召回率达91.3%, 较原始模型YOLO11s分别提升6.8%和6.1%。3项改进措施可有效增强模型对小目标的检测能力, 提升模型泛化性与鲁棒性; 在综合检测性能提升与资源消耗增加的权衡下, 尺度权重因子的优化效果优于BiFPN模块, 优于Mosaic增强。同时, YOLO11-SDP模型推理速度满足工业实时检测要求, 可用于饰面人造板生产中干花、湿花、污斑、裂缝等常见缺陷的在线检测, 为家居建材高质量发展提供技术支撑。

关键词: 饰面人造板; 表面缺陷; YOLO11-SDP; 机器视觉; 模型精度

中图分类号: TS653; TP29 文献标识码: A 文章编号: 2096-9694 (2026) 02-0088-10

Surface Defect Detection of Surface-Decorated Wood-Based Panels Based on YOLO11-SDP Model

HAN Jiakai¹, LYU Bin¹, WANG Xiaohuan¹, ZHANG Wei^{1,2}, XU Kai³, DIAO Xingliang¹,
JI Min¹, WANG He¹

(1. Research Institute of Wood Industry, Chinese Academy of Forestry, Beijing 100091, China; 2. Research and Development Center for Forestry and Grassland Equipment, Research Institute of Wood Industry, Chinese Academy of Forestry, Beijing 100091, China; 3. HAPCO Machinery Co., Ltd, Suzhou 215000, Jiangsu, China)

Abstract: Surface-decorated wood-based panels serve as a core raw material in the furniture industry, and surface defect detection is a critical step in quality control. Current detection methods commonly adopt YOLO-based machine vision, yet their performance in terms of precision and recall leave room for

收稿日期: 2025-11-22; 修改日期: 2026-01-24

基金项目: “十四五”国家重点研发计划项目“基于数字化协同的林木产品智能制造关键技术”(2023YFD2201500); 国家木竹产业技术创新战略联盟“平面素色饰面板在线视觉检测系统研发”(TIAWBI2025)。

作者简介: 韩佳锴(2000—), 男, 硕士研究生。Email: 952944857@qq.com

通讯作者: 王晓欢, 女, 副研究员。Email: wangxiaohuan@caf.ac.cn

improvement. In resource-constrained deployment scenarios, the balance between inference speed and detection accuracy remains unresolved. To enhance the overall performance of existing detection models and apply the algorithm to surface defect detection of decorated wood-based panels, this study proposed an improved YOLO11-SDP (You Only Look Once11-Surface Decorated Panels) detection model. The original detection model was improved via three complementary measures: performing Mosaic augmentation on the dataset, replacing the original Feature Pyramid Network (FPN) module with a BiFPN module, and introducing a scale weight factor into the loss function. Experimental results showed that the improved model achieved a precision of 98.0% and a recall of 91.3%. Compared with the original model, the precision and recall rate were increased by 6.8% and 6.1%, respectively. These three enhancements significantly improved the model's capacity to detect small targets, yielding greater generalization and robustness. When balancing the performance gains against the increased computational cost, the scale weight factor was proved superior to BiFPN, followed by Mosaic augmentation. Furthermore, the detection speed satisfied real-time processing requirements. Consequently, the YOLO11-SDP model was well-suited for the online detection of common defects—including frosting mark, water mark, spots, and crack—in the manufacturing of surface decorated wood-based panels, thereby providing technical support for the high-quality development of home furnishing and building materials.

Key words: surface-decorated wood-based panels; surface defects detection; YOLO11-SDP; computer vision; model precision

饰面人造板是家具制造和室内装修的主要材料，三聚氰胺浸渍胶膜纸饰面刨花板是饰面人造板的主流产品之一。然而，饰面人造板在生产过程中易产生干花、湿花、污斑、裂缝等表面缺陷^[1]。当前，生产现场缺陷检测效率与饰面板高速生产节奏存在明显不匹配问题^[2]，传统方式以人工目视检测为主，易受主观判断干扰、检测精度不稳定、检测速度难以匹配生产线节拍，制约了高品质饰面板的高效连续化生产^[3]。

深度学习技术在处理背景复杂、缺陷类别多样、目标差异明显的工业图像时表现出显著优势，已逐渐成为表面缺陷检测领域的主流技术^[4]。随着工业成像与深度学习算法的持续发展，基于机器视觉的表面缺陷检测在工业生产中得到广泛应用与快速推广。YOLO11作为2024年发布的YOLO系列新一代目标检测模型，继承了该系列检测速度快、识别精度高的特点，并在网络结构、任务拓展性与工程部署效率方面实现进一步优化^[5]，其核心改进体现在网络结构深度优化，骨干网络采用更高效的C3k2模块替代部分C2f结构，通过优化卷积核尺度与通道维度提升特征提取能力，并

引入动态注意力机制，实现对关键目标区域的自适应聚焦^[6]；颈部PAN-FPN结构完成轻量化改进；检测头采用统一设计，结合可变形卷积增强对不规则目标的捕获能力，同时简化训练与推理流程^[7]。在功能拓展上，YOLO11不仅支持常规目标检测，还原生集成实例分割、姿态估计、目标跟踪等多任务能力，通过统一网络架构与训练策略降低了实际开发与部署的门槛^[8]。YOLO11在COCO公共数据集上的平均精度均值较YOLOv8提升2%~3%，且具备多任务扩展能力^[9]。

利用机器视觉对饰面人造板表面缺陷进行检测具有良好的应用前景，但现有方法存在两点不足。一是对微小缺陷的特征提取能力较弱，小目标浅层细节在特征传递过程中易丢失，导致漏检、误检率偏高。YOLO系列检测损失通常由定位损失、分类损失和置信度损失三部分加权组成^[10]，分别表征预测框回归精度、类别判别准确度与目标存在概率^[11]。YOLO11采用的尺度感知交并比(scale-aware intersection over union, SIoU)，是针对目标尺度差异优化的IoU改进损失函数，重点解决小目标因尺度小、特征弱导致的定位精度低、

损失贡献不足等问题，但其在实际饰面板缺陷检测任务中仍存在优化潜力，其精确率、召回率等关键指标仍有提升空间。二是在工业生产线实际部署中，边缘端设备普遍存在算力有限、资源紧张等问题，如何在保证检测精度的前提下，平衡推理速度与模型复杂度，仍是工业缺陷检测模型落地应用中亟待解决的关键问题。目前，对微小、密集目标的特征学习借助图像增强技术强化模型学习能力，相比于传统单一增强方式（翻转、缩放、裁剪等），Mosaic数据增强可在单张图像中融合多幅图像信息，其拼接过程可使部分小目标放大或呈密集分布，显著提升样本丰富度，强化模型对微小目标特征的学习。

浸渍胶膜纸饰面人造板表面大多呈现高度逼真的仿木纹纹理。这些纹理提升了产品的视觉美感的同时，其复杂的纹理结构也极大提升了缺陷检测的难度。木纹特征在像素级表现上与细微裂缝等缺陷具有高度的相似性，极易形成强背景噪声。传统的检测模型往往难以将缺陷特征从复杂的仿木纹背景中分离，导致在实际生产线场景下误检率较高。因此，增强模型对背景干扰的鲁棒性也是实现饰面人造板表面缺陷检测的难点。

本研究以YOLO11s为基础网络，提出一种面向饰面人造板表面缺陷的专用检测模型YOLO11-SDP（You Only Look Once11-Surface Decorated Panels），实现对干花、湿花、污斑、残胶等典型缺陷的高效识别。模型主要创新点包括3个方面：1）在数据预处理阶段引入Mosaic数据增强，通过多场景图像融合扩充样本多样性，强化模型对微小、密集目标的特征学习能力；2）在网络颈部替换为BiFPN（Bidirectional Feature Pyramid Network）双向特征金字塔网络，构建多尺度双向特征融合路径，减少目标浅层空间信息丢失；3）重点对损失函数中的定位损失进行改进。在损失函数中引入目标尺度权重因子，加大对微小目标定位误差的惩罚力度，引导模型更专注于小目标边界框优化。本研究旨在实现检测精度与推理速度的有效平衡，为饰面人造板表面缺陷在线检测提供一种高精度、高鲁棒性的技术方案，为工业自动化质量检测提供支撑。

1 材料及方法

1.1 图像采集系统

图像采集自广州索菲亚家居股份有限公司的三聚氰胺浸渍胶膜纸饰面人造板生产线中的成品板检测环节，取完整板面图像。饰面板表面缺陷图像采集系统如图1所示。




图1 饰面人造板表面缺陷图像采集平台

Fig.1 Image acquisition platform for surface defects of decorative wood-based panels

平台由相机、光源、传送装置和计算机等组成，其中包含一台4 K彩色相机、一套白色光源和一台图形工作站。相机被垂直固定于传送设备上方800 mm处，光源倾斜安装于相机同一高度处并打亮相机正下方。待采集的板材由传送带运输至检测区域，触发光电传感器并发出拍摄信号，当板材运输至相机正下方时被光源照亮，同时线阵相机开始拍摄，获取到的图像被保存在电脑中。该平台可以在1 m/s的传送速度下满足家具部件生产中1 220 mm幅面宽度饰面人造板图像的在线实时采集，为研究数据获取提供条件。硬件及环境配置列于表1。

1.2 数据集预处理与统计

研究使用的数据集包括浅色素色、深色素色、浅色纹理、深色纹理等4大类三聚氰胺浸渍胶膜纸饰面人造板，将缺陷区域统一裁剪为512像素×512像素，并对裁剪后的图像进行灰度处理。

表1 图像采集平台硬件及环境配置

Tab.1 Hardware configuration and software details of image acquisition platform

硬件及环境	型号
GPU	Intel(R) UHD Graphics 770 NVIDIA GeForce RTX3090
CPU	12th Gen Intel(R) Core i9-12900K
pytorch	3.10
工业相机	MV-CL042-91CC
工业相机镜头	MVL-AF2045M-M42
光源	LNH-400W-FN

单张图像基础增强：由于同一种饰面板表面缺陷在面积、形状、颜色等方面均存在差异，对样本图像进行垂直翻转、水平翻转、随机旋转 90° 等预处理，使图像数据集数量扩展到原来的4倍。

Mosaic 图像增强：原理如图2所示，随机选取多张图像，对每张图像进行随机缩放并随机裁剪一部分，得到不同尺寸的子图，然后按一定规则拼接成一张新的图像。对多张图像进行融合，在一个样本中让模型同时学习多个场景的特征。研究选择单次融合随机4张图像，对每张图像随机放大1~1.5倍，然后截取一张大小为256像素×256像素的子图，并与其他3张经过相同处理的子图以 2×2 网格的形式拼接成一张512像素×512像素的新图像，可以在保证输入图像尺寸不变的前提下，生成包含多场景、多目标的复合样本。




图2 Mosaic图像增强原理

Fig.2 Principle of Mosaic image enhancement

传统图像增强与Mosaic增强处理后的图像使用labelImg工具进行标注，生成包含缺陷位置与种类的目标检测信息标签。经预处理后得到饰面板表面缺陷样本图像数据集共2 560张图像，其中干花和湿花492处、污斑2 152处、裂缝1 344处。部分数据集图像与Mosaic图像增强技术预处理后缺陷样本图像如图3所示。




图3 预处理后常见缺陷样本图像与Mosaic图像增强结果

Fig.3 Preprocessed images of sample with common defects and Mosaic image augmentation results

1.3 模型训练

基于数据集进行训练，数据集按7:2:1的比例随机划分为训练集、验证集和测试集^[12]。其中，训练集用于模型的参数学习，验证集用于衡量模型训练过程中参数设定的合理性，测试集用于最终的性能分析。所有试验在图形处理站上进行，训练参数列于表2。

表2 模型训练参数

Tab.2 Model training parameter

训练参数	设置
初始学习率	0.01
批处理大小 batchsize	16
遍历次数 epochs	150
置信度阈值	0.5

批处理大小（批次容量）指的是单次梯度更新所使用的样本数量，负责平衡训练稳定性和显存带宽利用率。较大的批次容量能提供更稳定的梯度，加速训练，但需要更强的GPU显存。较小的批次容量，如本研究设置的16，虽然会引入一定的梯度噪声，但是这种噪声有时能帮助检测模型跳出局部最优解，在复杂纹理识别中表现更好。迭代次数指的是整个数据集被模型完整学习的次

数, 直接决定模型学习的充分程度。迭代次数过少会导致模型还未完全掌握缺陷特征就停止学习, 导致发生欠拟合的情况; 迭代次数过多则会导致模型对缺陷特征的认知被限定于训练集, 失去处理新板材的能力, 导致发生过拟合的情况。本研究将迭代次数设为 150 次。初始学习率可以说是模型训练中最重要超参数, 代表了模型更新参数的最小步长, 负责控制损失函数递减的速度。学习率过高会导致模型中的参数和权重在最优解附近震荡, 过低则会导致训练速度大幅降低, 甚至无法跳出局部最优的范围。基于对模型收敛速度和特征复杂度的考虑, 本研究将初始学习率设置为 0.01。

1.4 评价指标

模型性能评价指标主要从检测精度、浮点运算量与推理时间三个方面进行比较。

检测精度评价指标^[13]主要包括: 1) 精确率 (precision, P), 即模型预测为目标的结果中真正正确的比例, 反映模型预测结果的可靠性; 2) 召回率 (recall, R), 所有真实目标样本中, 被模型成功预测为目标的比例, 反映模型对目标的检出能力; 3) 平均精度均值 (mean average precision, mAP), 对以精确率为纵坐标、召回率为横坐标的 PR 曲线进行积分求曲线下的面积, 得到平均精度, 再计算每个类别平均精度的算数平均值^[14]。

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

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

$$AP = \int_0^1 \text{Precision}(R) dR \quad (3)$$

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i \quad (4)$$

式中: TP (true positive) 真正例, 指的是模型预测为目标且真实标签确实为目标, 即正确判断; FP (false positive) 假正例, 指的是模型预测为目标但真实标签不为目标, 即误判; FN (false negative) 假负例, 指的是模型预测不为无目标但真实标签为目标, 即漏判。

mAP@0.50 指的是 IoU 阈值设置为 0.50 时计算得到的 mAP, 是目标检测最常用的基础指标; mAP@0.50 : 0.95 指的是多 IoU 阈值下的平均

mAP, 依次将 IoU 阈值设置为 0.50、0.55、0.60、0.65、0.70、0.75、0.80、0.85、0.90、0.95, 共 10 个值, 分别计算每个阈值下的 mAP, 最后求平均值即为 mAP@0.50 : 0.95。

2 YOLO11s 模型改进

2.1 引入 BiFPN 模块

针对小目标检测, 对检测模型进行优化。在 YOLO11s 的 neck 部分引入 BiFPN 这一金字塔网络结构旨在优化多尺度特征融合, 如图 4 所示。首先找到位于骨干网络 (backbone) 与检测头 (head) 之间的颈部 (neck) 部分, 移除原有的单一自上而下的路径聚合结构, 同时建立自上而下与自下而上的双向循环特征传递路径。通过这种双向路径, 模型可以同时捕捉到高层的抽象语义和底层的精细细节。在同一层级的特征提取过程中, 将输入节点与输出节点直接相连来增强特征的复用性, 又可以更有效地融合不同尺度的特征, 减少信息丢失。在特征融合时引入可学习的权重因子, 通过训练模型可以自动学习不同尺度特征的重要性。让模型在整体收敛的基础上, 更优化小目标的定位误差等浅层特征图的损失, 在不影响大目标检测的前提下, 显著增强对小目标的学习能力^[15]。通过使用 BiFPN 模块来平衡计算量和精度, 大约可减少 25% 的计算量^[16]。




图 4 YOLO11s neck 部分结构: (a)改进前; (b)改进后

Fig.4 Structure of YOLO11s neck:

(a) before improvement; (b) after improvement

2.2 引入目标尺度权重因子

针对定位损失，通过引入目标尺度权重因子，对小目标的定位误差赋予更高权重，增强小目标的几何误差惩罚。小目标的边界框即使轻微偏移也会导致IoU大幅下降，迫使模型优先优化小目标的边界框，从而提高模型对小目标的检测能力。定位损失公式见式(5)。

$$\text{box_loss} = \omega(s) \times [1 - \text{IoU} + \Delta_{xy} + \Delta_{wh} + \Delta_{dir}] \quad (5)$$

式中： $\omega(s)$ 为尺度权重因子；IoU为预测框与真实框的交集与并集之比； Δ_{xy} 为中心点距离偏差项，用于衡量预测框中心与真实框中心的距离偏差； Δ_{wh} 为宽高比偏差项，用于衡量预测框与真实框的宽高比例差异； Δ_{dir} 为方向一致性偏差项，用于衡量预测框与真实框的方向趋势的偏差。

尺度权重因子 $\omega(s)$ 的计算公式见式(6)。

$$\omega(s) = \exp\left(k \times \frac{s}{s_{\min}}\right) \quad (6)$$

式中： k 为调节系数，用于控制权重的增长幅度； s 为当前真实框的面积； $s_{\min}$ 为数据集中最小检测目标的面积。

首先函数 $f(x) = \exp(x)$ 是一个单调递增的指数函数，当真实框面积 s 越小， $s/s_{\min}$ 越接近1，尺度权重因子的值越接近 $\exp(x)$ ，整体定位损失越小；反之当真实框面积 s 越大， $s/s_{\min}$ 也随之增大，由于函数 $f(x) = \exp(x)$ 本身的性质，尺度权重因子的值会迅速增大，整体定位损失也会被迅速放大。如果对所有目标使用相同的损失权重，模型会倾向于重点关注那些数量多、面积大、更容易优化的目标，而忽略了对小目标的精确检测，导致小目标的检测效果很差。目标尺度权重因子 $\omega(s)$ 的核心目的就是解决目标尺度不平衡问题，让模型更加关注小目标的检测效果。

IoU预测框与真实框的交集与并集的面积之比称为IoU，按公式(7)计算IoU，计算示意如图5所示。1-IoU即交并集损失，IoU具有尺度不变性，无论框大框小，相同的IoU值代表相同的重合度^[19]。在目标检测中，是判断一个预测框是否为“有效检测”的核心标准之一，此外mAP等核心指标也基于不同IoU阈值计算，直接反映了检测任务最关心的最终指标。

$$\text{IoU} = \frac{S}{w_{\text{pred}} \times h_{\text{pred}} + w_{\text{gt}} \times h_{\text{gt}} - S} \quad (7)$$

式中： $w_{\text{pred}}, h_{\text{pred}}$ 为预测框宽、高； $w_{\text{gt}}, h_{\text{gt}}$ 为真实框宽、高； S 为二者重叠部分面积。




图5 IoU计算示意

Fig.5 Schematic diagram of IoU calculation

中心坐标偏差项 Δ_{xy} 起到衡量预测框中心坐标 $(x_{\text{pred}}, y_{\text{pred}})$ 与真实框中心坐标 $(x_{\text{gt}}, y_{\text{gt}})$ 偏差的作用，可以直接约束预测框的中心位置接近真实框中心。针对小目标检测的要求，中心坐标偏差项 Δ_{xy} 按公式(8)计算。

$$\Delta_{xy} = (x_{\text{pred}} - x_{\text{gt}})^2 + (y_{\text{pred}} - y_{\text{gt}})^2 \quad (8)$$

式中：宽高比偏差项 Δ_{wh} 起到衡量预测框宽高 $(w_{\text{pred}}, h_{\text{pred}})$ 与真实框宽高 $(w_{\text{gt}}, h_{\text{gt}})$ 偏差的作用，为了能对小目标检测的宽高比的偏差更加敏感，本实验选择对宽高差值做对数变换后计算偏差，具体按公式(9)计算。

$$\Delta_{wh} = |\lg(w_{\text{pred}}) - \lg(w_{\text{gt}})| + |\lg(h_{\text{pred}}) - \lg(h_{\text{gt}})| \quad (9)$$

方向一致性偏差项 Δ_{dir} 起到衡量预测框旋转角度 (θ_{pred}) 与真实框旋转角度 (θ_{gt}) 偏差的作用，用于约束模型准确预测目标的朝向，是旋转边界框核心组成部分之一。由于该偏差项主要针对的是裂缝等不分首尾的细条状缺陷，所以本实验设定的角度范围为 $[0^\circ, 180^\circ]$ ，即 $[0, 2\pi]$ ，因此该偏差项的计算是通过角度差的正弦值确定，可以保证在 90° 时偏差最大， 0° 和 180° 时偏差最小，具体按公式(10)计算。

$$\Delta_{dir} = \sin(|\theta_{\text{pred}} - \theta_{\text{gt}}|) \quad (10)$$

该尺度权重因子公式通过 $\omega(s)$ 放大小目标的损失权重，再通过 $1 - \text{IoU}$ （重叠度）、 Δ_{xy} （中心偏移）、 Δ_{wh} （形状偏差）以及 Δ_{dir} （方向偏差）四个维度优化小目标的定位误差，提升检测精度。

3 分析与讨论

3.1 Mosaic 图像增强技术效果对比

在使用消融实验对模型改进措施进行评估之前，首先需要评估 Mosaic 图像增强技术对模型性能的影响。本实验将仅使用基础增强（翻转、缩放、裁剪）的效果与添加 Mosaic 图像增强技术组合使用的效果进行比较。

由表 3 可知，对数据集进行 Mosaic 增强，模型的精确率和召回率分别提升了 1.8% 和 1.9%，mAP@0.50 值和 mAP@0.50：0.95 值分别提升 2.7% 和 3.2%，但是在浮点运算量和推理速度这两项并无增加，说明对数据集进行 Mosaic 增强可以在不消耗更多资源的情况下提升模型对小目标检测的表现。

表 3 Mosaic 图像增强实验检测结果						
Tab.3 Detection results of Mosaic image augmentation						
分组	检测精度				浮点运算量/ ×10 ⁹	推理时间/ ms
	P/%	R/%	mAP@0.50/%	mAP@0.50：0.95/%		
基础增强	91.7	86.1	86.6	77.2	24.5	4.5
Mosaic 增强	93.3	87.7	88.9	79.7	24.5	4.5

通过将 4 张不同背景、不同纹理方向的图像进行拼接，主动破坏木纹纹理的规律，使 YOLO11-SDP 模型在进行特征提取时，必须从复杂的木纹干扰中识别出不符合自然木材纹理规律的异常特征，从而提升模型对木纹背景的抗干扰能力。

3.2 消融实验分析

利用消融实验分析 BiFPN 特征金字塔结构模块与尺度权重因子两个部分对模型检测性能的影响。研究采用 YOLO11s 作为基础，将引入 BiFPN 特征金字塔结构模块、引入尺度权重因子、同时引入 BiFPN 特征金字塔结构模块和尺度权重因子与基础模型作比较，消融实验结果列于表 4。

由表 4 可知，Mosaic 增强、BiFPN 特征金字塔结构模块与尺度权重因子均能在一定程度上提高 YOLO11s 对小目标的检测效果。

对比第 1 组与第 8 组可知，对模型同时使用 Mosaic 增强、BiFPN 特征金字塔结构模块与尺度权重因子这三个措施，模型的精确率和召回率分别提升了 6.8% 和 6.1%，mAP@0.50 值和 mAP@

表 4 消融实验检测结果									
Tab.4 Detection results of ablation experiment									
序号	措施			检测精度				浮点运算量/ ×10 ⁹	推理速度/ ms
	Mosaic 增强	BiF-PN	尺度权重因子	P/%	R/%	mAP@0.50/%	mAP@0.50：0.95/%		
1	√	√	√	98.0	91.3	95.3	87.2	30.1	5.2
2		√	√	97.2	91.2	93.9	87.8	30.1	5.1
3	√		√	94.9	89.2	92.0	83.1	24.9	4.5
4	√	√		95.9	90.1	93.2	86.4	28.2	5.1
5	√			93.3	87.7	88.9	79.7	24.5	4.5
6		√		96.9	90.5	93.4	86.2	28.2	5.1
7			√	94.3	88.8	89.6	81.4	24.9	4.5
8				91.7	86.1	86.6	77.2	24.5	4.5

0.50：0.95 值分别提升了 10.0% 和 13.0%，浮点运算量和推理速度也分别增加了 20.8% 和 15.6%，说明这三种改进措施可以在较大程度上提升模型对小目标检测的表现。

对比第 6 组与第 8 组可知，在模型的 neck 部分使用 BiFPN 模块替换掉原有的 FPN 模块，模型的精确率和召回率分别提升了 5.7% 和 5.1%，mAP@0.50 值和 mAP@0.50：0.95 值分别提升了 7.9% 和 11.6%，浮点运算量和推理速度也分别增加了 15.1% 和 13.3%，说明引入 BiFPN 模块可以在一定程度上提升模型对小目标检测的表现。

对比第 7 组与第 8 组可知，在模型的损失函数中引入尺度权重因子，模型的精确率和召回率分别提升了 2.8% 和 3.1%，mAP@0.50 值和 mAP@0.50：0.95 值分别提升了 3.5% 和 5.5%，浮点运算量增加了 1.6%，推理速度并未明显增加。说明在模型的损失函数中引入尺度权重因子，可以在少量增加消耗资源的情况下提升模型对小目标检测的表现。

对比第 5、6、7 组数据可以得出，在检测小目标时，三种改进措施对模型检测效果提升的作用是 BiFPN>尺度权重因子>Mosaic 增强。综合考虑三个措施对模型的提升和增加消耗的资源，尺度权重因子优于 BiFPN，优于 Mosaic 增强。

消融实验结果证实了 BiFPN 模块与尺度权重因子在小目标检测中的协同作用。BiFPN 网络结构通过多尺度双向路径传递，将保留了完整物理轮廓的浅层特征与具备全局上下文信息的深层特征

进行融合,对于边缘细微、易被木纹信号淹没的裂缝等缺陷至关重要;尺度权重因子则从损失函数的角度解决缺陷稀疏的问题,在标准尺寸的宏观板面上,微小缺陷的损失贡献在传统损失函数计算中极易被忽略,尺度权重因子通过指数级的权重放大,使模型在梯度下降过程中着重处理小尺寸目标区域,能够做到在复杂背景下对微小缺陷的检测。

3.3 检测速度与实时性验证

以2 440 mm×1 220 mm规格的饰面板为例,需拍摄一张像素尺寸为8 192像素×4 096像素的图像才能包含一张完整的人造板,按照实验中要求的尺寸分割可得到128张尺寸为512像素×512像素的子图,根据表4中第1组实验的数据可知,在同时使用BiFPN特征金字塔结构模块与尺度权重因子的情况下处理一张子图的耗时为5.1 ms,处理一张完整图像的耗时为 $(8\ 192 \times 4\ 096) / (512 \times 512) \times 5.1 = 652.8$ ms,即0.65 s。与采集图像的生产线相比,成品板检测环节的传送带最大运行速度为1.2 m/s,运行至检测位置时使用8只吸盘将板材抬起由人工肉眼检查,每块板材整体耗时为8~10 s,故判断满足生产线实时性需求。

3.4 检测结果对比与可视化

为验证改进前后模型性能的差异,统计YOLO11s和YOLO11-SDP两个模型检测结果,并以真实类型为横坐标,预测类型为纵坐标绘制混淆矩阵,如图6所示。由混淆矩阵可以看出YOLO11-SDP比YOLO11s在检测效果上明显提升,尤其减少了将背景误判为污斑的情况。在原始模型中,较深颜色木纹节子常被误认为污斑,而YOLO11-SDP模型通过BiFPN网络结构的多尺度双向特征融合,能够对污斑缺陷和自然生长的木纹纹理有效区分,显示对复杂背景有更好的识别能力。

结果显示,改进后的模型针对干花、湿花、污斑与裂缝的正确检测数量分别是89、392和250,相较于改进前模型,正确检测的数量分别提升了4.1%、9.1%和5.8%,优于原模型,表明改进后模型对小目标,尤其是污斑的检测效果明显提升。如图7中分割后的单幅图像所示,原模型在检测小目标缺陷时存在一定漏检现象,未能完整识别所有缺陷;而改进模型在相同条件的检测场景下能够更加精确识别出目标缺陷,表现出更高的可靠性。综合上述分析,本研究提出的改进方法可有效降低原有模型的误检率,提升检出率。




图6 YOLO11-SDP与YOLO11s的混淆矩阵对比

Fig.6 Comparison of confusion matrix between YOLO11-SDP and YOLO11s

3.5 鲁棒性验证

为了验证模型的泛化能力与鲁棒性,仅对数据集集中的测试集进行高斯模糊,再叠加高斯噪声,模拟真实场景中“模糊+噪声”的复合干扰,模拟传感器热噪声、低光环境下的图像噪声,相比单

一噪声,更接近实际拍摄中的图像退化过程^[20]。仅对测试集进行干扰是为了避免模型在对测试集预测前就学习到了干扰后的图像特征,更能体现模型在复杂检测环境下的鲁棒性。

由表5可知,YOLO11s在面对原始数据集和




图7 YOLO11-SDP与YOLO11s对饰面人造板缺陷检测结果对比

Fig.7 Detection comparison between YOLO11-SDP and YOLO11s on surface decorative wood-based panel defects

干扰数据集，精确率和召回率分别下降了6.1%和8.9%， $mAP@0.50$ 值和 $mAP@0.50:0.95$ 值分别下降了8.6%和8.8%。而YOLO11-SDP在面对原始数据集和干扰数据集，精确率和召回率分别下降了3.5%和3.9%， $mAP@0.50$ 值和 $mAP@0.50:0.95$ 值分别下降了4.5%和4.8%。这说明改进后的YOLO11-SDP模型相较于YOLO11s在面对复杂环境、噪声干扰的情况下，更能保持较好的检测性能，证明了YOLO11-SDP模型的泛化能力与鲁棒性高于YOLO11s模型。

表5 鲁棒性验证结果

Tab.5 Results of robustness validation

模型	数据集	检测精度			
		P/%	R/%	$mAP@0.50$ /%	$mAP@0.50:0.95$ /%
YOLO11s	原数据集	91.7	86.1	86.6	77.2
YOLO11-SDP		98.0	91.3	95.3	87.2
YOLO11s	模糊+噪声	86.1	78.4	79.1	70.9
YOLO11-SDP		94.6	87.7	91.0	83.1

本研究提出的YOLO11-SDP模型在饰面人造板表面缺陷检测任务中展现出显著优势。实验数据表明，各改进模块对模型性能的提升具有明确的科学逻辑：BiFPN模块通过构建双向路径并引入可学习的权重分配机制，强化了浅层空间信息与深层语义信息的跨尺度融合，使得精确率相比基准模型提升了5.7%；尺度权重因子通过对小面积

目标的定位误差赋予更高的指数级惩罚权重，强制模型关注微小区域的特征，从而使召回率提升了3.1%；Mosaic增强则通过复合样本策略扩充了模型对复杂背景下小目标特征的感知维度，将 $mAP@0.5:0.95$ 值提升了3.2%。横向对比前人提出的R-CNN算法、SSD算法或其他YOLO变体^[17-20]，本研究提出的YOLO11-SDP模型实现的98.0%精确率与91.3%召回率，均优于上述算法。

4 结论

1) 针对饰面人造板表面缺陷检测，通过对缺陷图像数据集进行Mosaic增强，使用BiFPN模块替换原有FPN模块，在损失函数中引入尺度权重因子这三个措施对原有YOLO11s模型进行组合改进，提出YOLO11-SDP检测模型。

2) 相较于基准模型YOLO11s，改进模型YOLO11-SDP强化了对微小、点状缺陷的特征捕捉与定位能力，在面对叠加高斯模糊与高斯噪声的复合干扰时的精确率和召回率仅下降3.5%和3.9%，表现出更高的稳定性和鲁棒性，能够有效应对实际生产中传感器热噪声与复杂光照的干扰。虽然浮点运算量有所增加，但其推理速度在复杂网络环境下依然表现稳定，可在兼顾检测精度的同时满足在线检测的实时性需求。

3) 改进模型YOLO11-SDP虽然实现较高精度的检测，但还存在一定不足，未来研究可以从两个方向上进行优化与改进：一是目前的网络模型结构仍相对复杂，还需要对模型进一步剪枝压缩来实现轻量化，降低硬件门槛并更好的部署到位于产线上的边缘设备上；二是针对横向宽度仅约5像素的极细微裂缝，目前的特征网络结构仍存在一定的下采样信息损耗，后续应探讨设计一种保留更多浅层空间信息的专用小目标检测头，以进一步降低模型对极小尺寸目标的定位误差。

YOLO11-SDP模型不仅能够为解决传统人工目测效率低、精确率低、稳定性差的问题提供解决方法，还为饰面人造板表面质量检测的自动化升级提供可行的技术方案，也为同类微小目标的工业视觉检测任务提供参考路径。

参考文献:

- [1] 彭晓瑞, 吕斌, 李伟光, 等. 我国板式家具先进制造技术研发与应用进展[J]. 木材科学与技术, 2023, 37(2): 1-7, 15.
PENG X R, LYU B, LI W G, et al. Development and application progress of advanced manufacturing technology for China's panel furniture[J]. Chinese Journal of Wood Science and Technology, 2023, 37(2): 1-7, 15.
- [2] 李博, 吕斌, 王兵, 等. 大数据技术在木材工业中的应用前景分析[J]. 中国人造板, 2022, 29(6): 1-6.
LI B, LYU B, WANG B, et al. Application prospect analysis of big data technology in wood industry[J]. China Wood-Based Panels, 2022, 29(6): 1-6.
- [3] 张超, 吴智慧, 刘海波. 机器视觉系统在家居木制品制造工业机器人中的应用[J]. 家具, 2022, 43(4): 37-41, 50.
ZHANG C, WU Z H, LIU H B. Application of machine vision system in the industrial robot for furnishing and wood products manufacturing[J]. Furniture, 2022, 43(4): 37-41, 50.
- [4] 杨渊. 机器视觉在刨花板表面缺陷检测中的应用现状与建议[J]. 中国人造板, 2024, 31(5): 33-37.
YANG Y. Application of machine vision in particle board surface defect detection: status and recommendations[J]. China Wood-Based Panels, 2024, 31(5): 33-37.
- [5] 王雪, 高雅, 陶桂香, 等. 基于CBLP-YOLO 11n的无人机稻穗轻量化检测方法[J]. 农业机械学报, 2025, 56(11): 461-470.
WANG X, GAO Y, TAO G X, et al. Lightweight detection method of rice panicles based on CBLP-YOLO 11n[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(11): 461-470.
- [6] XU Y, WU H, LIU Y, et al. PCB Electronic component soldering defect detection using YOLO11 improved by retention block and neck structure[J]. Sensors, 2025, 25(11). <https://doi.org/10.3390/s25113550>.
- [7] BAI J, ZHU W, NIE Z, et al. HFC-YOLO11: A lightweight model for the accurate recognition of tiny remote sensing targets[J]. Computers, 2025, 14(5): 195.
- [8] HE H L, ZHOU Z Y, LIU L, et al. Research on the directional bounding box algorithm of YOLO11 in tailings pond identification[J]. Measurement, 2025. DOI:10.1016/j.measurement.2025.117674.
- [9] Ultralytics. YOLO11[EB/OL]. (2024-09-10). <https://docs.ultralytics.com/zh/models/yolo11>.
- [10] JIE C, JOO M E. Dynamic YOLO for small underwater object detection[J]. Artificial Intelligence Review, 2024, 57(7). DOI:10.1007/s10462-024-10788-1.
- [11] 王品博, 王雨晨, 王双永, 等. 基于改进YOLOv8的树木年轮实例分割及信息检测方法[J]. 木材科学与技术, 2025, 39(3): 7-18.
WANG P B, WANG Y C, WANG S Y, et al. Study on tree ring instance segmentation and information detection based on improved YOLOv8[J]. Chinese Journal of Wood Science and Technology, 2025, 39(3): 7-18.
- [12] JI M, ZHANG W, WANG G, et al. Online measurement of outline size for *Pinus densiflora* dimension lumber: maximizing lumber recovery by minimizing enclosure rectangle fitting area[J]. Forests, 2022, 13(10). <https://doi.org/10.3390/f13101627>.
- [13] 乔澍祎, 林秀仪, 章伟伟, 等. 基于YOLOv5的人造板板材种类识别[J]. 林业工程学报, 2023, 8(2): 138-143.
QIAO S Y, LIN X Y, ZHANG W W, et al. Identification of the type of wood-based panels using YOLOv5[J]. Journal of Forestry Engineering, 2023, 8(2): 138-143.
- [14] 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.
- [15] 惠永永, 赵春雨, 宋昭漾, 等. 基于BiFPN和Triplet注意力机制的YOLOv5s缺陷苹果识别算法[J]. 华南农业大学学报, 2025, 46(3): 419-428.
HUI Y Y, ZHAO C Y, SONG Z Y, et al. A YOLOv5s algorithm based on BiFPN and Triplet attention mechanism for identifying defective apple[J]. Journal of South China Agricultural University, 2025, 46(3): 419-428.
- [16] 李文, 叶坤涛, 舒蕾蕾, 等. 基于高斯模糊逻辑和ADCSCM的红外与可见光图像融合算法[J]. 红外技术, 2022, 44(7): 693-701.
LI W, YE K T, SHU L L, et al. Infrared and visible image fusion algorithm based on gaussian fuzzy logic and adaptive dual-channel spiking cortical model[J]. Infrared Technology, 2022, 44(7): 693-701.
- [17] URBONAS A, RAUDONIS V, MASKELIŪNAS 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, 22(9). <https://doi.org/10.3390/app9224898>.
- [18] ZHOU W J, LI Y, LIU L, et al. Cork classification based on multi-scale faster-RCNN with machine vision[J]. Measurement, 2023, 217. DOI: 10.1016/j.measurement.2023.113089.
- [19] 朱婷婷, 李岩, 杨茜, 等. 基于YOLOv9-DSConv桉树旋切单板缺陷识别方法[J]. 林业工程学报, 2025, 10(5): 138-144.
ZHU T T, LI Y, YANG Q, et al. Defect recognition method for eucalyptus rotary-cut veneer based on YOLOv9-DSConv[J]. Journal of Forestry Engineering, 2025, 10(5): 138-144.
- [20] 江兴旺, 赵兴强. 改进YOLOv7的木材表面缺陷检测算法[J]. 计算机工程与应用, 2024, 60(7): 175-182.
JIANG X W, ZHAO X Q. Improved YOLOv7 algorithm for wood surface defect detection[J]. Computer Engineering and Applications, 2024, 60(7): 175-182.

(责任副主编 方长华/编校 向琴)

广告索引

封二: 国家竹产业研究院

广1: 中国国际地面材料及铺装技术
展览会

广2: 北京欧立华科技发展有限公司

广3: 杭州太克干燥设备有限公司

封三: 苏州苏福马机械有限公司

封底: 第五届全国木材科学与技术
学术大会