

面向木材缺陷的全局与局部协同感知检测方法

张 伟*, 王巍霖, 张群利#

东北林业大学家居与艺术设计学院, 黑龙江 哈尔滨

收稿日期: 2026年4月18日; 录用日期: 2026年5月14日; 发布日期: 2026年5月26日

摘 要

针对木材表面缺陷检测中存在的缺陷形态多变、微小缺陷易漏检以及复杂背景纹理干扰等核心挑战。文章提出了一种全局与局部协同感知的检测方法。该方法以Swin Transformer作为主干网络, 利用其移位窗口注意力机制构建层次化特征金字塔, 有效捕获图像的全局上下文信息与长距离依赖关系; 与之协同, 构建CTGFusion颈部网络, 该网络中, MSF模块通过轻量化MetaFormer架构与深度可分离卷积实现多尺度特征的高效融合, CWA模块则利用具备空间感知能力的门控机制对细微缺陷特征进行自适应增强, 有效抑制了特征丢失与平滑问题。实验结果表明, 本方法在精确率、召回率和mAP50上分别达到0.895、0.874和0.916, 性能优于多个主流检测模型。在微小、低对比度缺陷的检出与复杂背景适应方面表现优异, 为木材表面缺陷的自动化质检提供了可靠解决方案。

关键词

木材缺陷检测, 全局与局部协同, 特征融合, 无损检测, 智能制造

Global and Local Synergistic Perception Method for Wood Defect Detection

Wei Zhang*, Weilin Wang, Qunli Zhang#

College of Home and Art Design, Northeast Forestry University, Harbin Heilongjiang

Received: April 18, 2026; accepted: May 14, 2026; published: May 26, 2026

Abstract

Aiming at the core challenges in wood surface defect detection, such as significant morphological diversity, the vulnerability of micro-defects to missed detection, and interference from complex

*第一作者。

#通讯作者。

文章引用: 张伟, 王巍霖, 张群利. 面向木材缺陷的全局与局部协同感知检测方法[J]. 计算机科学与应用, 2026, 16(5): 172-182. DOI: 10.12677/csa.2026.165174

background textures, this paper proposes a detection method based on global and local synergistic perception. The method adopts Swin Transformer as the backbone network, utilizing its shifted window attention mechanism to construct a hierarchical feature pyramid, which effectively captures global contextual information and long-range dependencies of images. In synergy with the backbone, a CTGFusion neck network is developed. Within this network, the Multi-Scale Fusion module achieves efficient integration of multi-scale features through a lightweight MetaFormer architecture and depth-wise separable convolutions. Meanwhile, the Channel-Wise Attention module utilizes a gating mechanism with spatial awareness to adaptively enhance fine defect features, effectively suppressing feature loss and smoothing issues. Experimental results demonstrate that the proposed method achieves a precision of 0.895, a recall of 0.874, and an mAP50 of 0.916, outperforming several mainstream detection models. The proposed method exhibits superior performance in detecting tiny, low-contrast defects and adapting to complex backgrounds, providing a reliable solution for the automated quality inspection of wood surface defects.

Keywords

Wood Defect Detection, Global and Local Synergy, Feature Fusion, Non-Destructive Testing (NDT), Smart Manufacturing

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

作为一种可再生、可循环利用的重要材料,木材在建筑、家具制造、地板铺设、装饰工程以及纸浆生产等诸多领域中具有广泛应用[1]。然而,木材在生长过程中易产生裂纹、节子、虫眼和腐朽等天然缺陷,在加工过程中也常引入毛刺、锯痕、热压裂纹与颜色不均等问题,这些缺陷直接影响木材的最终质量与使用寿命[2][3]。在此背景下,实施木材缺陷检测成为提高材料利用效率的重要途径。传统的人工检测方法易受视觉疲劳、环境干扰等主观因素影响,效率有限且一致性难以保障[4]。为解决这一问题,木材缺陷无损检测技术应运而生。该技术能够在保持木材结构与性能完整的前提下,准确识别与评估其表面的各类缺陷[5]。目前,木材缺陷检测技术主要可分为基于物理信号分析的传统无损检测方法与基于机器视觉[6]分析的检测方法两大类。前者通过捕捉并分析超声、应力波、射线及近红外光谱等物理信号在木材中的传播或响应特性来判别缺陷[7]-[12];后者则主要依托机器视觉技术,通过对木材表面图像进行分析处理来实现缺陷的识别与分类。在机器视觉分析方法中,多种机器学习技术已被应用于木材表面缺陷的自动化检测。例如,BP神经网络能够通过学习大量样本数据建立缺陷识别模型。这些算法的应用不仅简化了检测流程,减少了人工干预的需求,还在一定程度上提高了检测的效率和准确性。

近年来,基于深度学习的计算机视觉技术在木材缺陷检测中的应用已成为研究热点[13]。特别是在目标检测领域,单级算法[14]-[17]和双级算法[18][19]的发展显著提升了检测的速度和准确性,使得完全自动化的木材缺陷检测成为现实。例如,Ling等[20]构建了一种基于ResNet-v2的混合模型,通过融合GooLeNet与ResNet的模块,能够有效识别虫洞、活节与死节三类典型缺陷。然而,该模型的局限性在于仅支持单一缺陷的分类,无法对同一木板图像中可能并存的多类缺陷进行同步检测与定位。针对多缺陷检测问题,Meng等[21]在YOLOv5框架基础上提出了SGN-YOLO模型,通过增强网络的表征学习与

上下文感知能力,显著提升了检测精度。然而需要指出的是,该模型的平均精度(mAP)相较于基准模型仅提高了3.1%,尤其在复杂环境下的小目标缺陷检测中仍存在一定的漏检风险。进一步地,Wang等[22]对YOLOv8模型进行了一系列改进,在主干网络中引入DWR模块以增强多尺度特征提取与融合能力,并替换了动态检测头,同时采用MPDIoU损失函数进行优化,最终将模型平均精度(mAP)提升至77.7%。尽管如此,多尺度缺陷特征在融合过程中仍存在效率不足的问题,相关研究仍有持续改进的空间。针对上述问题,本文的主要贡献如下:

- 1) 针对木材缺陷形态多变、背景纹理复杂导致特征提取困难的问题,提出采用Swin Transformer作为主干网络,利用其全局注意力机制增强模型对长距离依赖和复杂上下文的建模能力。
- 2) 针对多尺度缺陷特征在融合过程中效率低下、语义信息丢失的问题,提出构建基于MSF模块的层级融合网络,通过轻量化的MetaFormer架构实现高效跨尺度特征交互与整合。
- 3) 针对微小、低对比度缺陷在特征图中响应微弱、易被平滑滤除的问题,提出引入具备空间感知能力的CWA注意力模块,通过门控与深度卷积相结合的方式动态增强细微特征,有效提升模型对瑕疵的敏感度。

2. 模型构建

针对木材表面缺陷检测中缺陷形态多变、尺度差异大、微小缺陷易漏检等核心挑战,本文构建一种面向木材缺陷的全局与局部协同感知检测方法,如图1所示。该模型通过Swin Transformer作为主干网络,利用其层次化金字塔架构和移位窗口注意力机制,从复杂木材纹理中捕获具有丰富语义的全局上下文信息;与之协同,设计CTGFusion颈部网络,包含MSF模块和CWA模块。其中MSF模块通过基于深度可分离卷积的MetaFormer架构实现高效多尺度特征融合,而CWA模块则利用具备空间感知能力的门控注意力机制对细微缺陷特征进行针对性增强,二者协同工作,系统性地提升了模型对从宏观缺陷模式到微观瑕疵特征的全面感知能力。




Figure 1. Overall network architecture
图 1. 整体网络结构

2.1. Backbone 网络改进

针对传统卷积神经网络在木材表面缺陷检测任务中存在的缺陷形态多变、背景纹理复杂以及多尺度特征提取机制效率有限等核心瓶颈问题,本文采用 Swin Transformer [23]作为特征提取主干网络。该网络通过其独特的层次化金字塔架构与移位窗口自注意力机制,系统性地构建了高效的多尺度特征表示体系。其主干网络以一种层次化的方式处理输入图像,如图 2 所示。Swin Transformer 主干网络遵循一种层次化的四阶段设计:首先,输入图像被分割为 4×4 的非重叠块并经过线性嵌入转换为初始特征图(Stage 1);随后,通过三个阶段(Stage 2 至 Stage 4)的操作,每个阶段首先通过块合并层将特征图分辨率减半、通道维翻倍,再经由一系列核心的 Swin Transformer 模块进行深度特征提取,该块通过交替使用常规与移位窗口划分策略,在保证计算效率的同时实现了有效的全局上下文建模;最终,该流程输出一个不同尺度特征图构成的金字塔。




Figure 2. Swin Transformer network architecture

图 2. Swin Transformer 网络架构

2.2. Neck 网络改进

针对现有目标检测模型在木材缺陷检测任务中存在的多尺度特征融合效率不足、微小缺陷特征易丢失、局部上下文信息利用不充分等核心问题,本文提出了一种名为 CTGFusion (Global-Local Transformer Fusion)的复合颈部网络结构。该结构创新性地融合了基于 MetaFormer 的 MSF (Multi-Scale Features)模块和引入深度卷积的 CWA (Channel-Wise Attention)门控注意力机制,实现了全局上下文整合与局部特征增强的协同优化。

2.2.1. MSF 结构

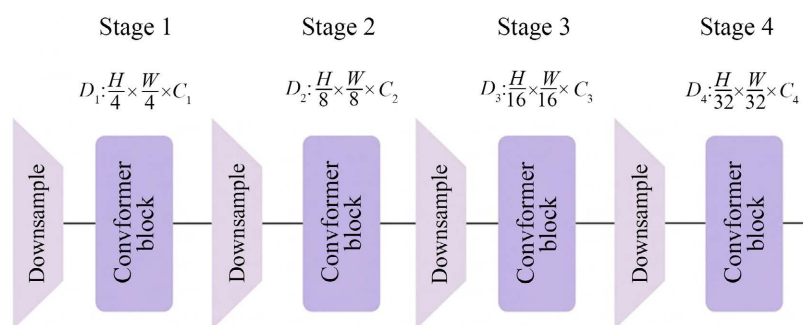


Figure 3. MSF network architecture

图 3. MSF 网络架构

针对现有目标检测模型中颈部网络在全局上下文信息整合与跨尺度特征交互能力上的不足,提出了一种基于 MSF 架构的层级特征融合颈部网络。该设计的核心创新在于:摒弃了传统颈部网络中标准卷积

块或复杂注意力机制，转而采用以深度可分离卷积为令牌混合器的 MetaFormer 通用架构作为基本构建单元。此举旨在为模型注入强大的模型能力，使其在无需引入大量计算开销的前提下，对多尺度特征进行融合与增强。MSF 的整体架构采用分层式设计，共包含四个阶段，如图 3 所示。输入图像依次通过四个阶段，特征图的空间分辨率逐级减半，而通道数则相应增加，从而构建出一个蕴含多尺度信息的特征金字塔。每个阶段均由一个下采样模块和一系列相同的 MSF 基本构建块堆叠而成。

2.2.2. CWA 结构

为了解决木材缺陷检测任务中微小、低对比度缺陷特征在颈部网络融合过程中易被丢失或平滑，以及现有通道注意力机制对局部缺陷特征响应不足的核心问题，引入卷积门控线性单元(CWA)。如图 4 所示，该模块在传统门控机制中创新性地引入深度可分离卷积，使其具备局部空间感知能力，能够基于邻域特征生成动态自适应的通道权重。

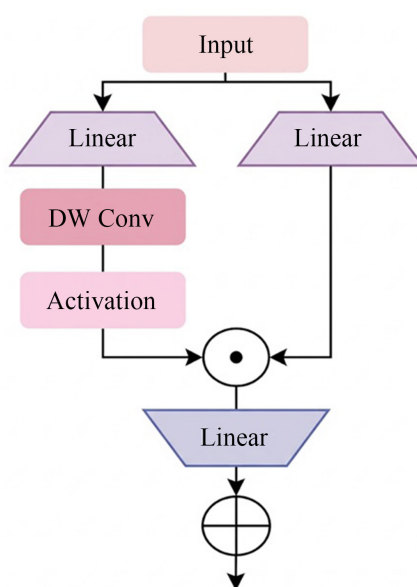


Figure 4. CWA network architecture
图 4. CWA 网络架构

CWA 是一种用于神经网络中通道混合机制的设计方法，能够在不显著增加计算成本的前提下提升模型的表达能力与建模效率。该模块基于传统的门控线性单元(GLU)结构，并在其基础上引入深度卷积操作，进一步增强模型对局部上下文信息的建模能力。由于深度卷积具有天然的空间感知特性，使得 CWA 能够根据不同位置的邻域信息动态调整通道权重，从而提升特征表示的鲁棒性和判别能力。具体来说，CWA 通过在输入端进行通道划分，分别经过两个并行分支处理：一个分支负责生成激活信号，另一个分支则引入深度卷积以提取局部空间信息，最终通过逐元素融合两路信息，实现更精细的通道注意力控制。CWA 的设计思想融合轻量化卷积与门控机制的优势，在保持整体结构简洁的前提下，有效增强了模型对多尺度特征和复杂模式的学习能力。在训练阶段，CWA 通过多分支结构提升模型的表达能力和性能；而在推理阶段，其核心操作可被等效转换为标准的线性变换，因此不会引入额外的计算，具备良好的部署友好性。这一特性使 CWA 特别适用于资源受限或对推理效率有较高要求的实际应用场景。尤其是在视觉 Transformer 与卷积相结合的混合模型中，CWA 展现出更优的泛化能力和适应性，能够有效提升模型的整体性能。

3. 实验结果与分析

3.1. 数据集收集及处理

本研究使用的数据集来源于 VSB-Technical University of Ostrava 发布的木材表面缺陷部分数据集 [24]。所有图像均采用 LabelImg 工具对缺陷目标进行标注，初始共计 1711 张图片，四种缺陷类型，分别是 Marrow、Dead Knot、Knot with Crack 以及 Live Knot，如表 1 所示。为提升模型在复杂场景下的适应能力并改善样本不平衡问题，我们对数据集进行了针对性处理：针对样本稀少的缺陷类别，采用贴图增强技术，将种类少的缺陷合理移植到其他缺陷种类实木板材表面，有效扩充了稀缺样本量，使得整体的缺陷样本相对平衡。同时引入多种图像变换策略，包括 HSV 色彩空间变换、欧氏变换等方法。这些增强手段不仅将训练数据量进行扩充，更重要的是构建了覆盖不同光照条件。最终，数据集被扩展至 3711 张图像，并按照 8:2 的比例分为训练集和测试集，图像分辨率为 640×640 。

Table 1. Statistics of defect categories in the dataset

表 1. 数据集缺陷类别统计

缺陷类型	缺陷数量
Live Knot	5986
Knot with Crack	3019
Dead Knot	3615
Marrow	2106

3.2. 实验环境

本实验所采用的软硬件参数如表 2 所示，使用深度学习进行模型实验训练时，利用 GPU 模块提高训练速度来加快对网络的训练。

Table 2. Experimental environment configuration

表 2. 实验环境配置

配置名称	环境参数
System Environment	Windows 11
Central Processing Unit (CPU)	13th GenIntel (R) Core (TM) i5-13400 2.50 GHz
Memory	16 GB
Python	3.8.8
PyTorch	2.4.1 + cu121
CUDA	12.1
GPU	NVIDIA GeForce RTX 2080 Ti

3.3. 结果与分析

3.3.1. 消融实验结果分析

为系统验证本文所提改进模块的有效性，我们基于自建的木材表面缺陷数据集进行了一系列消融实

验。实验以 YOLOv11n 模型作为基准，并逐步引入 MSF 模块、CWA 模块以及 Swin Transformer 主干网络，构建了 Variant 1、Variant 2 和 Variant 3 三个对比模型。详细的实验结果如表 3 所示。

Table 3. Comparison of ablation study results

表 3. 消融实验结果对比

模型	精准率(%)	召回率(%)	mAP (0.5) (%)
YOLOv11n	0.587	0.637	0.877
Variant 1	0.878	0.857	0.892
Variant 2	0.891	0.854	0.897
Variant 3	0.895	0.874	0.916

结合图 5 和图 6 可以看出本文改进方法的有效性。各变体模型的具体性能指标见表 3，分析如下：首先，对基准模型 YOLOv11n 的性能分析表明，该模型在实木板材表面缺陷检测任务中面临严峻挑战。实验结果显示，其精确率(0.587)与召回率(0.637)均较低，证实了传统卷积神经网络在该类任务中的局限性：由于实木背景纹理复杂且缺陷形态多变，标准卷积受限于局部感受野，难以有效提取多尺度特征并建立全局上下文联系，从而导致微小缺陷的漏检与误检率较高。在基准模型中引入基于 MetaFormer 的 MSF 模块后(Variant 1)，模型性能实现了本质提升。精确率由 0.587 增至 0.878，召回率由 0.637 增至 0.857。性能的飞跃验证了 MSF 模块设计的有效性：该模块采用以深度可分离卷积为令牌混合器的 MetaFormer 架构，实现了高效的全局信息整合与跨尺度特征交互。其分层式设计构建的多尺度特征金字塔，增强了模型对异形缺陷的表征能力，在提升识别精度的同时，显著降低了对复杂背景的误判。

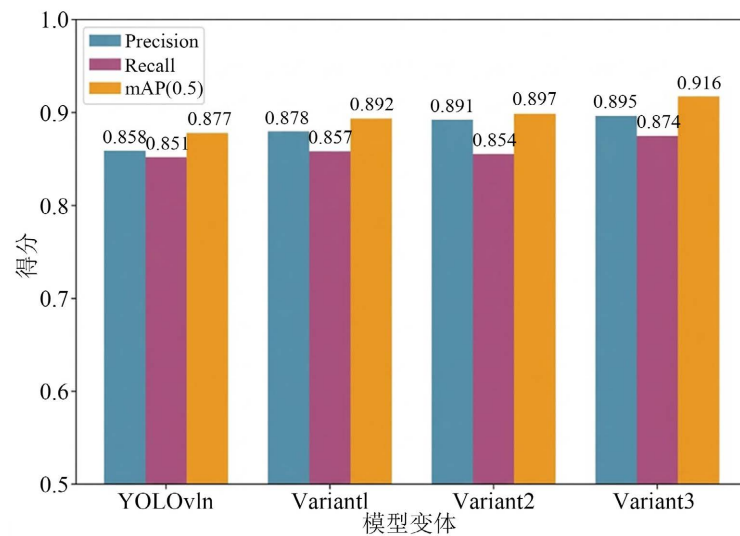


Figure 5. Performance comparison of ablation studies

图 5. 消融实验性能对比图

在 Variant 1 的基础上引入具备局部空间感知能力的 CWA 门控注意力机制(Variant 2)，实验结果显示性能得到持续优化。精确率从 0.878 提升至 0.891，mAP50 达到 0.897。尽管提升幅度较第一阶段有所放缓，但其验证了 CWA 模块在细粒度特征提取方面的价值。该模块通过在门控机制中嵌入深度卷积，使模型能依据邻域空间信息动态调整通道权重，强化了对微小、低对比度缺陷特征的保留，实现了更精确的缺陷定位。最终，通过采用 Swin Transformer 替换主干网络构建 Variant 3 模型，各项评估指标均达到

最优水平。其中 mAP50 提升至 0.916，召回率提升至 0.874。实验结果证明了 Swin Transformer 在特征提取方面的优越性：其独特的移位窗口自注意力机制与层次化金字塔架构，系统性地解决了长距离依赖建模的难题。该架构通过跨窗口的信息交互实现全局上下文感知，并为后续 Neck 网络提供兼顾局部细节与全局语义的表征特征，最终实现了模型检测性能的全面领先。

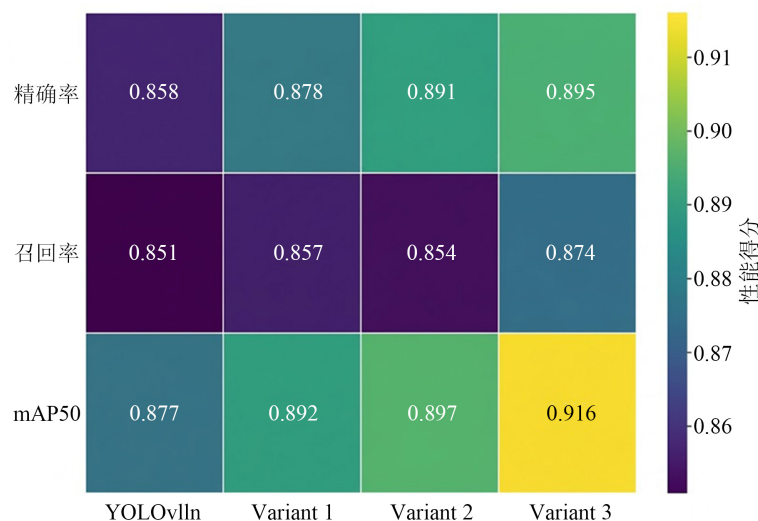


Figure 6. Model performance matrix
图 6. 模型性能矩阵

如图 7 所示，对部分检测结果进行可视化分析。对于形态多变、尺度较大的宏观缺陷。基准方法的热力图激活区域呈现出零散、不规则且亮度分布不均的现象，无法完整覆盖缺陷的物理全貌。这表明传统卷积神经网络受限于局部的感受野，在面对大跨度异形缺陷时，难以建立起长距离的上下文依赖关系。与之形成鲜明对比的是，本文方法的热力图高亮区域高度集中、饱满，且严密契合了缺陷的真实几何轮廓。这得益于 Swin Transformer 主干网络强大的全局上下文建模能力，其独特的移位窗口自注意力机制打破了空间邻域的限制，成功捕获了缺陷在全局范围内的长距离依赖特征。

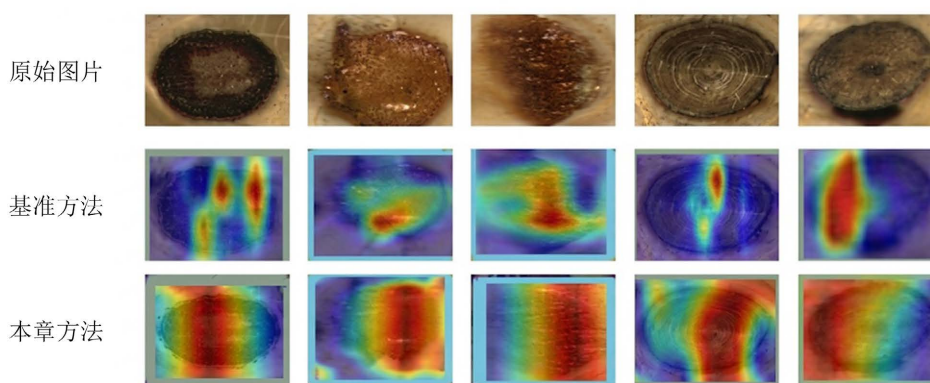


Figure 7. Heatmap visualization
图 7. 热力图可视化

对于细微、低对比度的微小缺陷，基准方法出现背景噪声误激活，高亮区域甚至偏离了缺陷核心。这是因为在深层特征融合过程中，微弱的局部瑕疵特征极易被密集的正常木材纹理所平滑或掩盖。而本

文方法依然保持了极强的抗干扰能力，在缺陷中心形成了高亮且集中的热力点。这一方面依托于 CWA 门控注意力模块的空间感知能力，通过引入深度可分离卷积动态调整了通道权重，另一方面，MSF 模块通过基于 MetaFormer 架构的高效层级金字塔融合，确保了这些浅层的精细化局部特征在传递至检测头时不发生语义丢失。

综上所述，热力图的可视化结果从视觉特征表征的层面，有力地证明了本文所提出模型的有效性。模型不仅能够从宏观上自适应捕获复杂背景下的多尺度缺陷，更在微观上表现出对细粒度、低对比度边缘特征的超强敏感度。

3.3.2. 对比实验结果分析

为了保证实验的严谨性与可复现性，本研究在模型训练阶段严格统一了各项超参数设置。输入图像尺寸统一规范为 640×640 像素，总训练轮数设定为 200 轮；批次大小设置为 4，学习率为 0.01。将提出的完整模型与多个主流检测模型进行了对比实验，涵盖了近年来提出的新型网络架构及 YOLO 系列的不同版本，结果见表 4。

Table 4. Comparison of experimental results
表 4. 对比实验表

模型	精准率/%	召回率/%	mAP (0.5) (%)
KAN	0.895	0.857	0.894
PPA	0.885	0.859	0.892
Fasternet	0.885	0.856	0.892
YOLOv5	0.885	0.871	0.88
YOLOv7	0.867	0.846	0.875
YOLOv8	0.893	0.841	0.877
YOLOv10	0.886	0.83	0.869
YOLOv12	0.865	0.877	0.889
Ours Method	0.895	0.874	0.916

实验结果表明，本文方法在实木板材表面缺陷检测任务中具有显著优势。在精确率指标方面，本文方法达到了 0.895，与 KAN 方法并列第一，优于其他对比模型。这一结果证明本文方法在减少误检方面表现出色，能够有效区分真实缺陷与复杂的板材纹理背景。相较于 YOLOv7 的 0.867 和 YOLOv12 的 0.889，本文方法显示出更强的复杂场景识别稳定性。在召回率指标上，本文方法取得了 0.874 的成绩，超过了 KAN 的 0.857、PPA 的 0.859 等方法，也显著优于 YOLOv8 的 0.841 和 YOLOv10 的 0.830。这表明本文方法在避免漏检方面具有明显优势，对微小及低对比度目标的捕捉能力更强。在核心指标 mAP50 上，本文方法以 0.916 的成绩显著超越了所有对比模型。与性能次优的 KAN 的 0.894 相比提升了 2.2 个百分点；与传统 YOLOv5 的 0.880 相比提升了 3.6 个百分点。图 8 的模型性能矩阵揭示了本文方法与主流算法的差异。通过对比可见，传统的 YOLO 系列模型在实木检测任务中虽表现稳定，但面对复杂板材纹理时，其 mAP50 普遍受限于 0.88 左右。值得注意的是，尽管最新发布的 YOLOv12 表现出了较强的竞争力，但在本任务中仍逊色于本文方法。

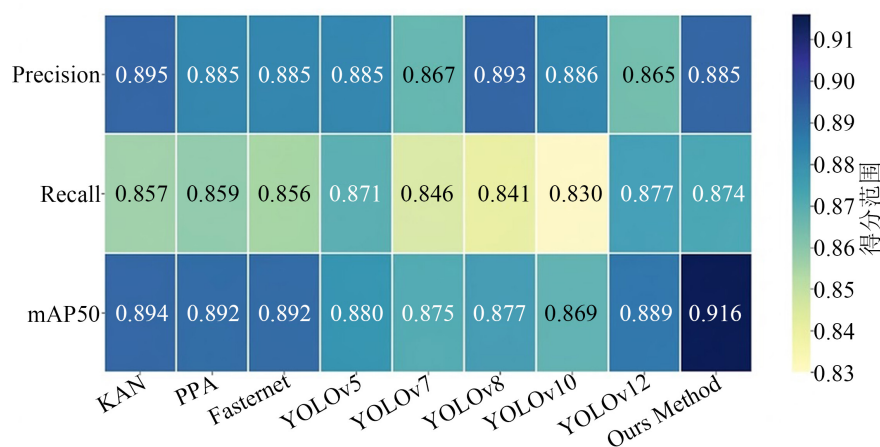


Figure 8. Comparison of comprehensive performance

图 8. 综合性能对比

4. 结论

本文针对实木板材表面缺陷检测中存在的样本分布不均、背景纹理复杂及微小缺陷易漏检等核心问题，提出并实现了面向木材缺陷的全局与局部协同感知检测方法。研究通过引入贴图技术优化了数据分布，并深度改进网络架构：采用 Swin Transformer 强化长距离依赖建模，配合设计具备空间感知能力的 CTGFusion 颈部结构，显著提升了模型对低对比度微小特征的捕获精度。实验结果表明，该方法在自建数据集的精确率、召回率及 mAP50 等关键指标上均优于主流模型，展现出极强的工业环境适应性，并为未来实现更深层次的缺陷细粒度识别奠定了坚实基础。

5. 局限性与未来展望

尽管本文提出的全局与局部协同感知检测方法在多项指标上均取得了显著提升，但通过对极端复杂样本的失效案例进行分析，发现本模型在特定工业场景下仍存在一定的局限性。

首先，对于与正常木材天然纹理极度相似的超低对比度缺陷，如极浅色活节或伴生天然矿物线，模型偶有误检或漏检现象。这是由于木材作为天然生物质材料，其深色年轮与某些缺陷在光学灰度、边缘梯度及局部纹理特征上具有极高的物理重叠度。即使本文的 CWA 模块具备较强的空间感知与特征动态增强能力，但在纯二维可见光成像受限的极端低对比度输入下，模型仍难以彻底剥离背景噪声的干扰。其次，由于本模型引入了 Swin Transformer 的自注意力机制以捕获全局长距离依赖，虽然通过移位窗口设计大幅降低了计算复杂度，但相比于纯轻量化卷积网络，其在边缘嵌入式设备上的推理功耗与显存占用仍有进一步优化的空间。

针对上述局限性，未来的研究将从以下两个方向展开深入探索：一是引入多模态无损检测技术。计划在可见光图像的基础上，融合近红外光谱或激光三维轮廓等多源异构数据，利用材料物理属性的差异提供更深层的区隔度，从而彻底解决极端隐蔽瑕疵的细粒度识别难题；二是进行模型的极致轻量化与边缘端部署研究。拟采用知识蒸馏或结构重参数化技术，在不牺牲检测精度的前提下，进一步压缩模型体积并提升推理速度，以更好地满足木材加工生产线高吞吐量、低时延的实时质检需求。

参考文献

- [1] 谢永华. 数字图像处理技术在木材表面缺陷检测中的应用研究[D]: [博士学位论文]. 哈尔滨: 东北林业大学, 2013.

- [2] 郭明辉, 刘祎. 木材固碳量与含碳率研究进展[J]. 世界林业研究, 2014, 27(5): 50-54.
- [3] 宋林书, 王浩, 杨超. 新发展格局下中国木材加工及家具制造业高质量发展探析[J]. 中国林业产业, 2022(2): 50-54.
- [4] 刘强, 袁云梅, 夏雪, 等. 基于人工智能的木材缺陷检测研究进展[J]. 世界林业研究, 2023, 36(1): 66-71.
- [5] Gupta, M., Khan, M.A., Butola, R., *et al.* (2022) Advances in Applications of Non-Destructive Testing (NDT): A Review. *Advances in Materials and Processing Technologies*, **8**, 2286-2307. <https://doi.org/10.1080/2374068X.2021.1909332>
- [6] 文韬, 代兴勇, 李浪, 刘豪. 基于机器视觉与光谱融合的柑橘品质无损检测分级系统设计与试验[J]. 江苏大学学报(自然科学版), 2024, 45(1): 38-45.
- [7] 方益明, 蔺陆军, 鲁植雄, 冯海林. 基于空气耦合超声波的木材无损检测系统研制[J]. 浙江农林大学学报, 2017, 34(2): 355-360.
- [8] 杨佳彬, 武广涛, 张彬, 陈忠加, 傅万四, 周建波. 超声波技术在林木无损检测中的应用[J]. 林业和草原机械, 2020, 1(4): 28-33.
- [9] 孙丽萍, 许述正, 魏喜雯, 岳琪, 王一凡. 应力波木材无损检测技术应用及研究进展[J]. 世界林业研究, 2020, 33(6): 39-43.
- [10] 熊海贝, 龙有为, 陈琳, 丁叶蔚. 木结构无损检测技术研究与应用综述[J]. 结构工程师, 2023, 39(1): 191-201.
- [11] 胡峰, 杨文卓, 冯俊雄, 王嘉晨, 等. 基于射线的无损检测技术综述[J]. 中国金属通报, 2021(7): 201-202.
- [12] 汪紫阳, 尹世逵, 李颖, 李耀翔. 基于可见/近红外光谱识别东北地区常见木材[J]. 浙江农林大学学报, 2019, 36(1): 162-169.
- [13] Cheng, D., Cheng, G. and Wang, X. (2022) Real-Time Detection Method of Wood Defects Based on Deep Learning. *2022 IEEE 8th International Conference on Computer and Communications (ICCC)*, Chengdu, 9-12 December 2022, 2192-2197. <https://doi.org/10.1109/ICCC56324.2022.10066017>
- [14] Liu, W., Anguelov, D., Erhan, D., *et al.* (2016) SSD: Single Shot MultiBox Detector. In: *Computer Vision—ECCV 2016: 14th European Conference*, Springer, 21-37. https://doi.org/10.1007/978-3-319-46448-0_2
- [15] Redmon, J. and Farhadi, A. (2017) YOLO9000: Better, Faster, Stronger. *Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, 21-26 July 2017, 7263-7271. <https://doi.org/10.1109/CVPR.2017.690>
- [16] Bochkovskiy, A., Wang, C.Y. and Liao, H.Y.M. (2020) YOLOv4: Optimal Speed and Accuracy of Object Detection.
- [17] Redmon, J., Divvala, S., Girshick, R., *et al.* (2016) You Only Look Once: Unified, Real-Time Object Detection. *Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, 27-30 June 2016, 779-788. <https://doi.org/10.1109/CVPR.2016.91>
- [18] Ren, S., He, K., Girshick, R., *et al.* (2016) Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **39**, 1137-1149. <https://doi.org/10.1109/TPAMI.2016.2577031>
- [19] Girshick, R., Donahue, J., Darrell, T., *et al.* (2015) Region-Based Convolutional Networks for Accurate Object Detection and Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **38**, 142-158. <https://doi.org/10.1109/TPAMI.2015.2437384>
- [20] Ling, J.X. and Xie, Y.H. (2022) Research on Wood Defects Classification Based on Deep Learning. *Wood Research*, **67**, 147-156. <https://doi.org/10.37763/wr.1336-4561/67.1.147156>
- [21] Meng, W. and Yuan, Y. (2023) SGN-YOLO: Detecting Wood Defects with Improved YOLOv5 Based on Semi-Global Network. *Sensors*, **23**, Article 8705. <https://doi.org/10.3390/s23218705>
- [22] Wang, R., Liang, F., Wang, B., *et al.* (2024) An Efficient and Accurate Surface Defect Detection Method for Wood Based on Improved YOLOv8. *Forests*, **15**, Article 1176. <https://doi.org/10.3390/f15071176>
- [23] Liu, Z., Lin, Y., Cao, Y., *et al.* (2021) Swin Transformer: Hierarchical Vision Transformer Using Shifted Windows. *2021 IEEE/CVF International Conference on Computer Vision (ICCV)*, Montreal, 10-17 October 2021, 9992-10002. <https://doi.org/10.1109/ICCV48922.2021.00986>
- [24] Kodytek, P., Bodzas, A. and Bilik, P. (2022) A Large-Scale Image Dataset of Wood Surface Defects for Automated Vision-Based Quality Control Processes. *F1000 Research*, **10**, Article 581. <https://doi.org/10.12688/f1000research.52903.2>