

基于深度学习的胶合板缺陷在线检测系统

张伟平 任亚恒 霍占奎 康尧星

河北省科学院应用数学研究所 河北 石家庄 050081

摘要：目前大多数胶合板生产企业依然沿用人工方式进行胶合板表面缺陷检测，人工检测受视觉疲劳、主观判断等影响会出现漏检、误检等情况。本文针对胶合板表面缺陷检测的复杂性和多样性，提出一种基于深度学习技术的胶合板缺陷在线检测系统，实验结果表明，该系统经过在自建数据集进行训练可有效检测出胶合板表面缺陷特征，大大提高了产品质量。

关键词：胶合板；缺陷检测；深度学习

河北省正定县素有“家具之乡”的美誉，该地有千余家板材家具企业，从原料生产到家具制作均已成熟，板材加工市场规模巨大。随着板材加工行业的发展，板材加工逐渐进入自动化大规模加工时代。由于胶合板相比其他人造板更接近于天然实木，更加符合环保要求，在衣橱柜、地板、卫浴柜等家居产品中有较为广泛应用，若其表面存在缺陷，在后续的加热压合工序会直接影响家具板材表面起鼓、变形，降低产品质量。在胶合板的缺陷检测中，人工检测需要在流水线生产过程中配备多名员工，人员成本高昂且检测效率低下；检测人员受劳动时间、生产环境不同等影响，极易出现疲劳导致漏检、误检、错检等现象；且不同员工检测有不同的标准，无法实现完全统一，这也影响了最终成品的质量性能。近年来，基于卷积神经网络、机器学习、模式识别等技术的木板缺陷识别技术逐渐进入大众视野，缺陷检测智能化也在板材缺陷检测行业逐渐使用。李孟歆^[1]等人提出了一种基于粗糙集和神经网络的模式分类方法，该方法在胶合板缺陷识别中精度达到 90.93%。石佳浩^[2]改进 Mask R-CNN 模型，引入伸进网络架构搜索算法和遗传算法，构建一种 Glance Network，提取活/死节和裂缝缺陷特征，实木板材表面缺陷检测平均准确率达到 98% 以上；王萍^[3]改进 YOLOv3 模型，提出一种基于深度迁移学习的木材表面缺陷检测和识别模型，可有效识别虫眼、腐烂等缺陷；武文一^[4]改进 YOLOv3 网络，加入阈值分割，该算法训练时间更短，漏检率更低，定位更加准确，检测速度更快；朱豪^[5]等人提出一种基于改进 YOLOv5s 的木材表面缺陷检测算法，改进后模型的 mAP 可达到 84.4%。综合上述基础，虽然已有很多学者采用不同的方法对木材表面缺陷特征进行了深入的研究，但都存在缺陷检测自适应能力不足、时间长等问题，无法实现胶合板缺陷检测过程自动化、数字化。本文采用 YOLO v8 模型，优化损失函数，对自建数据集进行训练，并和 YOLO v5 算法作比较，结果表明该算法对胶合板表面缺陷检测效果优于 YOLO v5。

1 视觉系统整体设计

视觉系统主要采用高分辨率工业相机、LED 光源作为图像输入设备采集模块，将采集图像经过预处理后输入基于深度学习的胶合板缺陷检测模型进行分析检测，完成胶合板表面缺陷检测功能，同时完成表面有缺陷的胶合板产品分拣，并记录缺陷类型，形成分析报告，视觉检测整体结构如图 1。

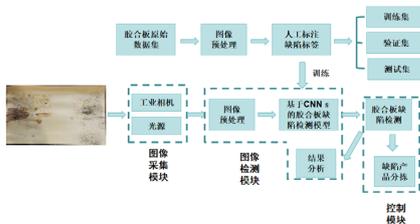


图 1 视觉检测系统整体结构图

其中，图像采集模块负责采集图像；图像检测模块负责采

集到的图像进行预处理、识别、检测、形成分析报告；控制模块负责缺陷产品分拣。

2 模型介绍

2.1 网络介绍

YOLO 目标检测算法是一种端到端的一阶目标检测算法，该系列算法核心思想是将图像划分为若干网格，通过卷积神经网络进行特征提取和目标检测。YOLO 算法的输出是一个特征图，包含每个网格对应的边界框和类别置信度的信息^[6]。每个网格可预测多个边界框和多个目标类别，可根据不同的需要设置不同的边界框和类别数量。

YOLO v8 作为最新的 YOLO 模型，可应用于目标检测、图像分类以及任务分割等。YOLO v8 算法秉承 YOLO v3、YOLO v5 算法思想，网络模型主要由输入端（Input）、骨干网络（Backbone）、颈部网络（Neck）和输出端（Head）四部分组成^[7]。网络结构如图 2 所示：

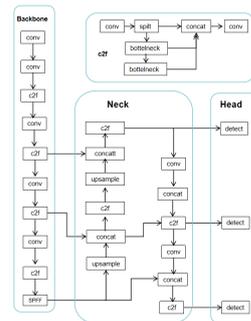


图 2 YOLO v8 网络结构图

骨干网络主要用于对目标进行特征提取，其中包含 Conv、c2f、SPPF 等模块。用梯度流更加丰富的 C2f 模块替换掉 YOLO v5 中的 C3 模块，C2f 结构拥有更多的分支跨层链接，对残差特征进行学习，反馈的梯度流信息更加丰富；SPPF 模块能够将任意大小的特征图转换为固定大小的特征向量。

颈部网络主要作用是进行多尺度特征融合，生成特征金字塔，依然采用 FPN-PAN 结构，C3 模块被替换为 C2f 模块，实现了网络上下信息流的充分融合，提升了网络的检测性能。FPN 首先在卷积神经网络中提取特征图来构建特征金字塔，随后自顶向下利用上采用与更粗粒度的特征图融合来实现不同层次的特征融合；PAN 作为 FPN 的结构补充，自底向上利用一个卷积层来融合来自不同层次的特征图，精确的保留了空间信息。

Head 部分使用解耦头，将目标分类和目标检测分离，根据不同尺寸的特征图获取不同大小目标的类别和位置信息。

2.2 损失函数

损失函数采用 DFL^[8] 与 Wise-IoU^[9] 相结合作为回归损失，有效增加模型收敛能力，更好的实现边界框预测回归效果。

DFL 以点到预测框四条边的距离作为回归目标其定义为：

作者简介：张伟平（1989— ），女，汉族，河北邯郸，研究生，助理研究员，模式识别。

河北省科学院基本科研业务费项目：基于深度学习的胶合板缺陷检测系统（项目编号：2022PF01-2）

$$DFL(Y_i, Y_{i+1}) = ((y_{i+1} - y) \log(Y_i) + (y - y_i) \log(Y_{i+1}))$$

其中, $Y_i = \frac{y_{i+1}-y}{y_{i+1}-y_i}$, $Y_{i+1} = \frac{y-y_i}{y_{i+1}-y_i}$ 。但 DFL 在计算损失时只是将锚点框向着标注框回归, 不能确定锚点框与标注框之间的包含关系, 因此引入 Wise-IoU 损失来计算锚点框与标注框的重叠损失。

Wise-IoU 通过对预测框和真实框之间的 IoU 进行加权来降低预测结果时可能存在的偏差问题, 其定义为:

$$\mathcal{L}_{WIoU} = 1 - \frac{\sum_{i=1}^n \omega_i \text{IoU}(b_i, g_i)}{\sum_{i=1}^n \omega_i}$$

其中, n 表示目标框的数量, b_i 表示第 i 个目标框的坐标, g_i 表示第 i 个目标的真实标注框的坐标, ω_i 表示权重值。

文中最终的损失函数为:

$$\mathcal{L} = \mu \cdot \text{DFL} + \nu \cdot \mathcal{L}_{WIoU}$$

通过实验分析, 最终取 $\mu = 0.2$, $\nu = 0.8$, 通过不断的调整参数和数据集训练, 最终形成一种基于 YOLO v8 的胶合板缺陷检测模型。

3 实验

3.1 数据集

本文在自建的胶合板缺陷数据集 Plywood-Z 上进行研究。在胶合板生产线完成图像采集, 经过人工初步筛选, 选取 800 幅作为数据集图片, 数据集中每张图片至少有 1 种缺陷目标, 经过对图片进行分割、提取、数据增强等预处理, 最终选定样本数 9440。该数据集中包括了胶合板常见的 5 种缺陷图像, 分别是死结 (Dead knot)、活结 (Live knot)、树皮 (Bark)、霉变 (Mildew) 以及裂缝 (Crack), 如图 3 所示。其中 80% 用于训练集, 10% 用于验证集, 10% 用于测试集。



图 3 胶合板缺陷类型

3.2 实验评价标准

通过对胶合板缺陷检测数据集 Plywood_Z 进行训练和测试, 以精确率 AP 来评价模型。

(1) 召回率 (Recall) 又称查全率, 表示检测出的正确样本个数占测试集中总样本总数的比值。

$$\text{Recall} = \frac{TP}{TP + FN}$$

(2) 精确率 (Precision) 表示检测出的正确样本的个数占总检测样本总数的比值。

$$\text{Precision} = \frac{TP}{TP + FP}$$

AP 是 P-R 曲线 (召回率为横轴, 精确率为纵轴) 与坐标轴围城的面积, 是单个目标的平均精度。

3.3 实验结果与分析

将本文算法与 YOLO v5 在相同的实验环境下对数据集 Plywood-Z 进行实验对比。AP 统计结果如表 1 所示。

表 1 胶合板缺陷检测统计表

类别	YOLO v5	YOLO v8
Dead knot	0.53	0.65
Live knot	0.64	0.71
Bark	0.72	0.73
Mildew	0.89	0.93
Crack	0.51	0.56

由表 1 可以看出, 在选定的 5 种检测目标中, 检测精确率从高到底依次为霉变、树皮、活结、死结和裂缝, 5 种缺陷目标的检测精确率都有所提升, 霉变这种缺陷相较于其他四种目标面积较大, 更容易被检出, 精确率更高, 且均在 90% 左右, 但树皮这种缺陷目标检测精确率提升不明显。

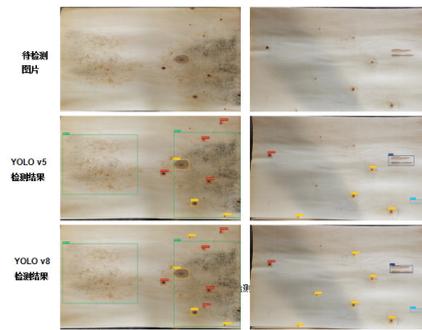


图 4 部分检测结果

从图 4 可以直观看出 YOLO v8 和 YOLO v5 经过训练集训练后都可以检测出缺陷目标, 对霉变这种大目标检测精确率较高, 活结、死结等小目标检测精确率相对没那么高。同时两种模型均存在漏检、误检等情况, 但 YOLO v8 在数据集 Plywood-Z 上准确率更高, 误检率、漏检率较 YOLO v5 也更低。综合比较, YOLO v8 模型更适合用于数据集 Plywood-Z。

4 结束语

传统的人工检测方法已完全不能满足胶合板生产线需求。本文针对胶合板表面缺陷检测的复杂性和多样性, 基于 YOLO v8 网络模型, 通过不断调整参数, 优化损失函数, 提出一种基于深度学习技术的胶合板缺陷在线检测模型, 该模型在自建数据集 Plywood-Z 上效果良好, 可有效检测出胶合板表面缺陷特征, 大大提高了产品质量。接下来将继续研究其他缺陷检测方法, 不断完善胶合板缺陷检测系统。

参考文献

- [1] 李孟歆, 吴成东, 韩中华, 夏兴华, YongYue. 胶合板缺陷识别方法比较研究 [J]. 沈阳建筑工程学院学报 (自然科学版), 2003, vol19 (3): 224-228.
- [2] 石佳浩. 基于深度学习的实木板材缺陷检测算法研究 [D]. 南京林业大学, 2021.
- [3] 王萍. 基于深度学习的木材表面缺陷检测 [D]. 广西科技大学, 2021.
- [4] 武文一. 基于 Yolov3 网络的木板缺陷识别 [D]. 沈阳工业大学, 2021.
- [5] 朱豪, 周顺勇, 曾雅兰, 李思诚, 刘学. 基于改进 YOLOv5s 的木材表面缺陷检测算法 [J/OL]. 木材科学与技术. https://kns.cnki.net/kcms/detail/10.1732.S.20230419.1142.001.html
- [6] 熊恩杰, 张荣芬, 刘宇红, 彭靖翔. 面向交通标志的 Ghost-YOLOv8 检测算法 [J/OL]. 计算机工程与应用, 2023, 59 (20).
- [7] 高伟锋. 基于 YOLOv8 的柑橘病虫害识别系统研究与设计 [J]. 智慧农业导刊, 2023, 15: 27-30.
- [8] LinTY, GoyalP, GirshickR, et al. Focal loss for dense object detection [C]//2017 IEEE International Conference on Computer Vision. 2017: 2980-2988.
- [9] 高昂, 梁兴柱, 夏晨星, 张春炯. 一种改进 YOLOv8 的密集行人检测算法 [J/OL]. 图学学报. https://kns.cnki.net/kcms2/detail/10.1034.T.20230731.0913.002.html.