

基于特征重建的无监督木材图像异常检测

李洋

武汉信息传播职业技术学院

DOI: 10.12238/jpm.v5i10.7324

[摘要] 本研究针对木材工业中的缺陷检测问题，提出了一种基于无监督学习的木材图像异常检测方法。通过构建 MVTec Wood AD、Wood Defect AD 和 Wood Surface AD 三个数据集，设计了 IRNet 模型，并引入了记忆模块和融合模块，以提高检测的精度和鲁棒性。实验结果表明，IRNet 在图像级和像素级的 AUROC 评分上均显著优于现有方法，尤其在处理复杂纹理和多样化异常时表现突出。这一方法为提高木材工业中的缺陷检测效率和产品质量控制提供了重要的技术支持。

[关键词] 木材图像异常检测；无监督学习；深度特征重建；多尺度特征生成

Unsupervised wood image anomaly detection based on feature reconstruction

Li Yang

Wuhan Vocational and Technical College of Information Communication

[Abstract] In this study, an unsupervised learning-based wood image anomaly detection method is proposed for the defect detection problem in the wood industry. By constructing three datasets, MVTec Wood AD, Wood Defect AD and Wood Surface AD, IRNet model is designed and memory module and fusion module are introduced to improve the accuracy and robustness of detection. Experimental results show that IRNet significantly outperforms existing methods in both image-level and pixel-level AUROC scores, especially when dealing with complex textures and diverse anomalies. This method provides important technical support for improving defect detection efficiency and product quality control in the wood industry.

[Key words] wood image anomaly detection; unsupervised learning; deep feature reconstruction; multi-scale feature generation

木材是工业生产中广泛使用的基础材料，然而木材缺陷对产品质量和经济效益有着严重影响。因此，如何快速、准确地检测木材中的缺陷成为了工业生产中的重要问题。现有的方法主要依赖于人工检测和机器视觉手段，但由于木材缺陷的多样性和复杂性，这些方法往往存在效率低、识别效果不佳的问题。为此，本文提出了一种基于无监督学习的木材图像异常检测方法，旨在通过深度学习技术自动检测和定位木材中的缺陷，从而提高工业生产中的检测效率和产品质量。

1 研究背景

近年来，随着深度学习技术的快速发展，图像异常检测领域取得了显著进展。传统的异常检测方法，如基于统计学的异常检测、支持向量机 (SVM) 以及孤立森林 (Isolation Forest) 等，通常依赖于有标签的数据，这在实际应用中面临着标注成本高、数据不平衡等问题。因此，越来越多的研究开始关注无监督学习在异常检测中的应用。无监督学习不需要预先标注的数据，能够通过学习正常样本的特征分布来检测异常，在大规

模工业场景中具有广泛的应用前景。

在木材图像异常检测领域，由于木材缺陷的多样性和复杂性，基于传统机器视觉和人工检测的方法难以满足实际需求。这些方法在面对纹理复杂、形状多变的木材图像时，往往表现出较低的检测效率和准确性。因此，研究者们开始探索如何将深度学习技术，特别是无监督学习方法应用于木材图像异常检测。

目前，基于深度自编码器 (Autoencoder)、生成对抗网络 (GAN) 等模型的异常检测方法已经取得了一定成果。这些方法通过学习正常木材图像的低维特征表示，在重建过程中检测出异常区域。然而，现有方法仍然存在一定的局限性，如对异常的泛化能力不足、重建误差大不稳定等问题。

针对这些问题，研究者们提出了基于多尺度特征生成和深度特征重建的新型方法，通过引入预训练网络、记忆模块和融合模块，显著提升了模型的检测精度和鲁棒性。这些进展不仅提高了木材图像异常检测的效果，也为其他工业领域的异常检

测提供了新的思路。本研究针对木材工业中常见的木材缺陷检测问题，提出了一种基于无监督学习的木材图像异常检测方法。通过构建 MVTec Wood AD、Wood Defect AD 和 Wood Surface AD 三个数据集，研究设计了 IRNet 模型，并在此基础上引入了记忆模块和融合模块，以提升模型的检测精度和鲁棒性。实验结果表明，IRNet 模型在图像级和像素级的 AUROC 评分上均显著优于传统的图像重建方法，尤其在处理复杂纹理和多样化异常时表现突出。这一方法为提高木材工业中的缺陷检测效率和产品质量控制提供了重要的技术支持。

2 实验方法

2.1 层次化特征提取

层次化特征提取是异常检测中至关重要的一步，旨在从图像的不同层次中提取出能够区分正常与异常的特征。在该方法中，使用预训练的 VGG19 网络模型进行多层次特征提取。通过对图像的不同卷积层进行处理，可以捕捉到从低级边缘信息到高级语义特征的丰富信息。具体来说，低层次卷积层提取图像的边缘和纹理等细节信息，而高层次卷积层则提取图像的全局结构和语义信息。这样，层次化特征提取不仅可以有效捕捉图像中的局部异常，还能保证对全局异常的准确检测。这一过程的核心是利用深度卷积神经网络的多层次特性，确保在检测任务中既能识别出显著的异常特征，又不丢失细节。

2.2 多尺度特征生成

为了更全面地捕捉图像中的异常信息，本研究提出了多尺度特征生成的方法。该方法的关键在于使用多尺度特征生成器，能够生成图像在不同尺度和层次的特征表示。通过这一过程，网络模型可以对图像进行多尺度的分析，确保不同大小和形状的异常都能被有效检测到。具体实现过程中，采用了多级卷积操作，并通过调整卷积核的大小和池化层的参数，生成了




图1 木材异常数据集标注示例

3.2 超参数

在实验中，IRNet 网络的训练参数设定为 300 个迭代次数 (epoch)，每次迭代选择的样本数 (Batch size) 为 4。训练过程中使用 Adam 优化器，初始学习率设定为 1×10^{-4} ，并在经过 250 个 epoch 后将学习率降低十倍。此外，采用 early stop 策略，当验证集的损失不再减少时，训练将在 20 个 epoch 后停止。为了增强模型的泛化能力，实验中使用了均值滤波器和多尺度特征生成的方式，并对遮蔽区域的大小和数量进行调整，以验证这些超参数对检测结果的影响。

3.3 评价指标

为了评估模型的性能，本研究采用了受试者工作特性曲线下的面积 (AUROC) 这一广泛应用于异常检测领域的指标。该

多种尺度的特征表示。这些特征表示能够覆盖从小到大的异常区域，特别适用于木材图像中常见的大小不一的缺陷检测。此外，这种方法还引入了跨层连接，确保在特征生成过程中不同层次的信息可以有效融合，提高了异常检测的准确性和鲁棒性。

2.3 深度特征重建

深度特征重建是本研究中用于异常检测的核心步骤之一。在这一方法中，通过自编码器网络对提取到的多尺度、多层次特征进行重建。具体来说，利用卷积自编码器对从预训练网络提取到的特征进行重构，以此来判断输入图像是否存在异常。重建过程中，通过比较重建图像与原始图像之间的差异，可以识别出图像中的异常区域。尤其是在处理木材图像中的细微纹理或复杂边缘时，深度特征重建显示出其强大的能力。该方法的优势在于，通过有效的特征重建，可以最大限度地保留图像中的关键信息，从而提高对异常区域的识别精度。同时，设计的跳跃连接结构保证了特征重建过程中不会丢失重要的高频信息，进一步增强了模型对异常检测的敏感性。

3 实验结果与分析

3.1 数据集构建

为了验证提出的异常检测方法，本研究构建了三个木材异常检测数据集，分别是 MVTec Wood AD 数据集、Wood Defect AD 数据集和 Wood Surface AD 数据集。这些数据集涵盖了多种常见的木材缺陷类型，如颜色异常、划痕、孔洞、节疤、裂纹等。每个数据集包含用于训练的正常木材图像和用于测试的正常及异常木材图像，并为每张异常图像提供了像素级的异常定位标签。图像的分辨率分别为 256×256 和 1024×1024 ，适应不同的检测任务。这些数据集不仅能测试算法在小样本情况下的性能，还能检验其在大样本情况下的泛化能力。

指标从图像级和像素级两个层面进行评价。在图像级评价中，主要考察模型对正常和异常图像的分类准确性；而在像素级评价中，则计算每个像素的异常得分与标签的匹配程度。通过计算混淆矩阵的真阳性率和假阳性率，可以绘制 ROC 曲线，并以其下的面积作为最终评价指标。较高的 AUROC 值表示模型具有更好的检测性能。

3.4 实验结果对比

为了验证所提出的 IRNet 模型在木材图像异常检测中的效果，本文将其与当前几种主流的图像异常检测方法进行了对比，包括基础的 U-Net 模型 (Backbone)、加入了记忆模块的模型 (Memory Module) 以及融合模块的模型 (Fusion Module)。实验结果表明，IRNet 在所有数据集上的表现均优于其他模型，尤

其是在图像级别 (Img.) 和像素级别 (Pix.) 的 AUROC 评分方面。具体实验数据如下：

表1 实验数据

模型	数据集	图像级 AUROC	像素级 AUROC
Backbone	MVTec Wood AD	0.930	0.858
Memory Module	MVTec Wood AD	0.935	0.887
Fusion Module	MVTec Wood AD	0.955	0.893
IRNet	MVTec Wood AD	0.961	0.896
Backbone	Wood Defect AD	0.833	0.736
Memory Module	Wood Defect AD	0.913	0.768
Fusion Module	Wood Defect AD	0.976	0.953
IRNet	Wood Defect AD	0.978	0.957
Backbone	Wood Surface AD	0.853	0.699
Memory Module	Wood Surface AD	0.859	0.731
Fusion Module	Wood Surface AD	0.963	0.888
IRNet	Wood Surface AD	0.964	0.893

从表中可以看出，IRNet 在三个数据集上的表现均优于其他模型，尤其在 Wood Defect AD 数据集上，图像级 AUROC 达到了 0.978，像素级 AUROC 达到了 0.957。相比之下，基础的 U-Net 模型在图像级和像素级的表现较弱，说明 IRNet 中的记忆模块和融合模块对于提升模型的异常检测能力至关重要。这

表2 消融实验结果

模型组合	数据集	图像级 AUROC	像素级 AUROC
IRNet (完整模型)	MVTec Wood AD	0.961	0.896
无记忆模块	MVTec Wood AD	0.935	0.887
无融合模块	MVTec Wood AD	0.955	0.893
无记忆和融合模块	MVTec Wood AD	0.930	0.858
IRNet (完整模型)	Wood Defect AD	0.978	0.957
无记忆模块	Wood Defect AD	0.913	0.768
无融合模块	Wood Defect AD	0.976	0.953
无记忆和融合模块	Wood Defect AD	0.833	0.736
IRNet (完整模型)	Wood Surface AD	0.964	0.893
无记忆模块	Wood Surface AD	0.859	0.731
无融合模块	Wood Surface AD	0.963	0.888
无记忆和融合模块	Wood Surface AD	0.853	0.699

些消融实验数据表明，记忆模块和融合模块在提高 IRNet 模型的性能方面起到了关键作用，特别是在处理木材图像中的复杂异常时，这些模块能够显著提高检测的准确性和鲁棒性。

4 结束语

本研究通过构建木材图像异常检测数据集，并提出 IRNet 模型，有效解决了木材图像异常检测中存在的检测精度低、泛化能力差等问题。实验结果表明，IRNet 在多个数据集上均表现出色，尤其是在处理复杂异常和多样化缺陷时具有明显优势。未来的研究可以进一步优化模型结构，并尝试将该方法应用于其他工业领域的缺陷检测，以验证其在不同应用场景中的广泛适用性。通过不断优化和推广，该方法有望在实际工业生产中得到广泛应用，提高产品质量和经济效益。

[参考文献]

[1]谢佳利, 亢新刚, 孔雷, 等.2020年我国的木材需求预

些结果进一步证明了所提出的模型在无监督木材图像异常检测任务中的有效性。

3.5 消融实验

为了进一步验证 IRNet 模型中各个组件的贡献，本研究设计并进行了消融实验。通过逐步移除模型中的关键模块，并观察其对检测性能的影响，能够明确各模块在整体性能提升中的作用。

首先，移除记忆模块后，模型在所有数据集上的性能均有所下降。在 MVTEC Wood AD 数据集上，图像级 AUROC 从 0.961 下降到 0.935，像素级 AUROC 从 0.896 下降到 0.887。这表明记忆模块在捕捉木材图像中的特征模式，尤其是在异常定位时，起到了重要的作用。

接着，移除融合模块后，模型的性能进一步下降。在 Wood Defect AD 数据集上，图像级 AUROC 从 0.978 下降到 0.913，像素级 AUROC 从 0.957 下降到 0.768。这一结果显示，融合模块能够有效地结合输入图像与特征图的高维信息，从而提升重建图像的质量，提高异常区域的检测精度。

最后，当同时移除记忆模块和融合模块时，模型退化为基础的 U-Net 架构。此时，在 Wood Surface AD 数据集上，图像级 AUROC 下降到 0.853，像素级 AUROC 下降到 0.699。这一结果进一步验证了记忆模块和融合模块对于提升模型检测性能的必要性。具体消融实验结果如下表所示：

测[J].中南林业科技大学学报, 2011, 31(12): 154-158.

[2]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, 2022, 35(03), 12-18.

[3]赖菲, 罗廷芳, 丁锐, 等.图像处理技术在木材表面缺陷检测中的应用[J].林业机械与木工设备, 2021, 49(02): 16-21.

[4]范佳楠, 刘英, 杨雨图, 等.机器视觉在木材缺陷检测领域应用研究进展[J].世界林业研究, 2020, 33(03): 32-37.

[5]姚建平, 肖江, 闫磊, 等.基于 3D 结构激光的木材表面缺陷检测的研究[J].林业机械与木工设备, 2017, 45(03): 20-25.

[6]肖雨晴, 杨慧敏, 王柯欣, 等.卷积神经网络在木材缺陷检测应用中的研究进展[J].木材科学与技术, 2021, 35(03): 12-18.