

DOI:10.19651/j.cnki.emt.2519959

基于X射线单投影成像的木材智能鉴别系统^{*}黄承雷^{1,2,3} 薛艳玲^{2,3} 杜康^{1,2,3} 肖体乔^{2,3}(1.中国科学院上海应用物理研究所 上海 201800; 2.中国科学院上海高等研究院上海光源科学中心 上海 201204;
3.中国科学院大学 北京 100049)

摘要:本研究针对传统木材分类效率低、依赖人工经验,家具市场存在以假充真、以次充好等材质造假的行业痛点问题,同时瞄准X射线单投影成像技术在木材检测领域的研究空白,自主研制了一套木材材质可视化专用成像装置,并提出了一种基于X射线单投影成像与双重注意力机制的木材材质智能鉴别系统。系统性构建了10类典型商用树种的X射线单投影数据集,包括非洲紫檀等3种紫檀属木材、交趾黄檀等4种黄檀属木材、古夷苏木等3种其他科属木材,并提出了一种双重注意力模型EDMA-Net。该模型通过双重注意力机制的层级化协同设计,实现浅层全局纹理与深层通道特征的联合优化。实验结果表明,该模型在测试集上分类总体精度达98.04%;消融实验进一步验证其有效性,EDMA-Net在参数压缩至16.51 M的同时,其分类准确率较基础模型提升2.38%,单张图像平均推理时间仅为7.00 ms,推理速度达142.95 fps,体现出优异的计算效率与实用性。在实际家具板材测试中,所有样品准确率均超过95%。该系统利用X射线单投影成像技术,为家具市场材质鉴别、质量监控及木材加工管理提供了一种无损、快速、实用的技术解决方案。

关键词: X射线成像;木材检测;X射线图像分类;深度学习**中图分类号:** TP391;TN919.8 **文献标识码:** A **国家标准学科分类代码:** 410.3020Intelligent wood identification system based on X-ray
single-projection imagingHuang Chenglei^{1,2,3} Xue Yanling^{2,3} Du Kang^{1,2,3} Xiao Tiqiao^{2,3}(1. Shanghai Institute of Applied Physics, Chinese Academy of Sciences, Shanghai 201800, China;
2. Shanghai Synchrotron Radiation Facility, Shanghai Advanced Research Institute, Chinese Academy of Sciences,
Shanghai 201204, China; 3. University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: Traditional wood classification methods face significant challenges, including low efficiency, heavy reliance on manual expertise and prevalent material fraud in furniture markets. Additionally, there exists a research gap in the application of X-ray single-projection imaging for wood identification. To address these issues, a set of special imaging device for wood material visualization was independently developed and an intelligent wood authentication system that integrates X-ray single-projection imaging with a dual-attention mechanism was proposed. A systematic X-ray single-projection dataset comprising 10 typical commercial wood species was constructed, including three Pterocarpus species, four Dalbergia species, and three other woods. A key innovation of this study is the proposed EDMA-Net model. This architecture integrates a hierarchical GAM-ECA dual-attention mechanism that enables synergistic optimization of both shallow global texture features and deep channel characteristics. Experimental results indicate that the model achieves an overall classification accuracy of 98.04%. Ablation studies show that, compared to the baseline model, EDMA-Net boosts the classification accuracy by 2.38% while compressing the parameters to only 16.51 M. The average single-image inference time is only 7.00 ms, reaching an inference speed of 142.95 fps, thereby verifying the module's effectiveness. Furthermore, actual furniture panels tests were conducted and the accuracy for all samples exceeded 95%. By leveraging X-ray single-projection imaging technology, this system provides a non-destructive, rapid and practical technical solution for material authentication, quality monitoring, and wood processing management in the furniture market.

Keywords: X-ray imaging; wood detection; X-ray image classification; deep learning

0 引言

在木材加工与利用领域,高效准确的木材分类对于提

升生产效率、合理配置资源以及保障产品质量至关重要^[1-2]。然而传统木材鉴定存在显著瓶颈,依赖鉴定人员经验,主观性强,导致准确率较低;又因单样品检测耗时较长,

收稿日期:2025-09-29

^{*} 基金项目:国家重点研发计划课题(2021YFF0601203,2022YFA1603601)资助

效率难以适配规模化生产需求;且物理力学性能测试等手段需取样,会对木材造成不可逆破坏,尤其在家具市场中,难以应对以假充真、以次充好等乱象^[3-5]。部分商家将普通木材伪装成红木、紫檀等高端木材,或用存在隐蔽裂纹、虫蛀的劣质木材经表面处理后冒充优品,严重扰乱交易秩序,侵害消费者权益,也给市场监管带来极大挑战^[6]。

计算机与人工智能技术发展推动深度学习在图像识别领域突破,其无需复杂人工特征工程,能自动从数据中学习特征,提升识别准确性与效率。基于预训练模型的迁移学习在木材图像分类中成效显著:Kirbas 等^[7]通过对比分析 ResNet-50、Inception V3 等模型在 WOOD-AUTH 数据集上的表现,提出利用 Xception 模型实现木材物种高效分类;徐志扬等^[8]则以无人机可见光影像中的单木树冠为研究对象,提出融合注意力机制的残差网络,验证了深度学习方法的应用潜力;Liu 等^[9]构建 CITES-28 宏观图像数据集,将注意力机制融入 ResNet 开发 SE-ResNet 模型,为打击非法木材贸易提供技术支持。

随着 X 射线成像及同步辐射成像技术的持续革新与突破,物质材料显微结构的探索方法正日益丰富且不断向高精度、高分辨率方向发展^[10-12],其在木材鉴别领域的应用逐渐受到关注。X 射线计算机断层扫描(computed tomography,CT)成像可获取木材三维结构信息,利用 CT 对木材微观结构进行 3D 分析,为木材鉴定研究提供微观细节^[13];Vacek 等^[14]通过训练神经网络验证了 CT 扫描在木材识别中的潜力,但 CT 设备存在成本高、数据采集和处理复杂、辐射剂量大等问题,限制了其广泛应用。

综上所述,尽管在可见光与 X 射线领域,木材识别研究已取得诸多进展^[15],但基于 X 射线单投影成像构建完整的木材智能检测系统的研究仍属空白。X 射线单投影成像具有设备简单、操作便捷、成本较低的优势,适用于实际生产环境;其能够穿透木材表面,揭示内部纹理和密度分布等特征^[16],为家具木材鉴别和品质评估提供支持。基于该技术的智能检测系统可整合设备、算法与应用场景,通过自动化检测应对市场问题,提供监管技术方案。

针对上述研究问题,为提升木材种类识别的准确率与系统实用性,本文聚焦一种基于 X 射线成像的木材智能检测系统的构建。通过搭建的木材材质可视化 X 射线成像系统,构建了包含 10 种商业木材的 X 射线图像数据集。同时,提出了一种融合双重注意力机制的 X 射线投影图像木材分类算法——EDMA-Net (efficient dual-attention module attention network)。该方法基于 EfficientNetV2-S^[17]主干网络改进,主干网络改进,浅层引入全局注意力模块,深层引入高效通道注意力机制模块,形成轻量高效的注意力增强结构。实验表明,该算法在木材 X 射线投影图像分类中表现优异。

1 材料和方法

1.1 样 品

为构建适配 X 射线单投影成像木材识别研究、具备广泛代表性的样本体系,本研究围绕地理跨度、物种多样性与物理特征差异 3 个维度,系统性开展木材样品采集工作。在地理分布覆盖上,深入非洲、东南亚核心木材产区。这些区域是全球商用木材的主要输出地,不同产地的气候、土壤条件,会使同种木材在密度、纹理等微观结构上呈现差异,还原真实贸易、加工场景中的多元产地特征。

物种类别筛选聚焦使君子科风车藤属,豆科黄檀属、紫檀属、古夷苏木属,共纳入 10 种木材。其中,巴里黄檀、大果紫檀等属于商用珍稀木材,东非黑黄檀为名贵硬木代表。既利用黄檀属、紫檀属等属内物种“纹理近似但密度有别”的特点,又借助属间物种“结构差异显著”的特性,为模型训练创造丰富鉴别场景。针对物理参数控制,综合 X 射线穿透性、成像清晰度需求,主要设置 20 cm×10 cm×2 cm、12 cm×7 cm×1.2 cm 两类尺寸。大规格样本可保留更完整的木材径向、弦向结构信息,常规规格贴近实际生产中木材切割形态,模拟多样检测场景。

表 1 详细记录了各木材的标签、品种、所属类群、产地及尺寸参数,构建标准化基础数据库。标签与图 1 中的木材样品实物图对应,为后续 X 射线图像采集、特征提取、模型训练及物种鉴别分析,提供精准、可追溯的样本支撑。

表 1 木材样品信息
Table 1 Information of wood samples

标签	品种	种属	产地	尺寸(L×W×H)/cm
0	风车木	使君子科风车藤属	莫桑比克	20×10×2.0
1	巴里黄檀	豆科黄檀属	老挝	12×7×1.2
2	交趾黄檀	豆科黄檀属	老挝	12×7×1.2
3	阔叶黄檀	豆科黄檀属	印度尼西亚	12×7×1.2
4	东非黑黄檀	豆科黄檀属	坦桑尼亚	12×7×1.2
5	成对古夷苏木	豆科古夷苏木属	莫桑比克	20×10×2.0
6	爱里古夷苏木	豆科古夷苏木属	刚果	20×10×2.0
7	大果紫檀	豆科紫檀属	缅甸	12×7×1.5
8	非洲紫檀	豆科紫檀属	加蓬	20×10×2.0
9	染料紫檀	豆科紫檀属	赞比亚	12×7×1.2




图 1 木材样品实物

Fig. 1 Actual of wood samples


1.2 X射线成像系统

为了实现木材种类的鉴定,本研究采用了基于滨松 L12161-07 X 射线源和 Teledyne DALSA Shad-o-Box 6K HS 探测器的木材材质可视化 X 射线成像系统。图 2 为研制的木材材质可视化 X 射线无损检测仪,其中,图 2(a)为成像光路示意图,图 2(b)为仪器外观照片,X 射线源与探测器的高度均可调整以适应不同场景的检测需求,装置并配有相应的安全连锁系统,以保证测试过程中的辐射安全。该系统使用滨松 L12161-07 微焦点透射钨靶 X 射线管作为 X 射线源,支持 40~150 kV 的管电压,最小焦点尺寸为 5 μm 。探测器为 Teledyne DALSA Shad-o-Box 6K HS,基于 CMOS 技术,具有 2 304 $\times$ 2 940 pixels 阵列,单个像素尺寸为 49.5 μm ,活动区域为 114 mm $\times$ 145 mm。在该系统中,X 射线源、样品台和探测器同轴布置。通过调整射线源和探测器的位置,可以灵活修改成像系统的几何放大倍率,以适应不同尺寸和形状的木材样品。在实验过程中,根据木材的厚度和密度,将仪器参数设置为 50 kV 的管电压、130 μA 的管电流和 300 ms 的曝光时间。样品到 X 射线源的距离 SOD 为 100 mm,探测器到样品的距离 SDD 为 320 mm,以实现足够的对比度增强和 13.3 mm 的有效图像尺寸。

1.3 X射线图像预处理


X 射线木材图像的预处理工作流程依次包括 3 个关键步骤,以确保图像质量和后续分析的准确性。首先,通过暗电流和平场校正消除成像系统中的噪声干扰、探测器背景影响以及 X 射线照射的不均匀效应。接着,应用图像分割技术分离木材区域与背景。最后,通过自动对比度调整增强图像的可视化效果^[18]。

在 X 射线成像过程中,暗电流噪声和探测器固有的背景效应可能影响图像质量。为此,首先进行暗电流校正以消除探测器噪声。在采集数据之前,在无 X 射线照射的情况下采集暗场图像,计算平均暗电流强度 I_{dark} 。暗电流校正公式为:



(a) 仪器的成像光路示意图

(a) Diagram of the imaging optical path in the instrument



(b) 仪器外观

(b) Appearance of the instrument

图 2 仪器的成像光路图与外观

Fig. 2 Imaging optical path diagram and external appearance of the instrument

$$I_{\text{corrected}} = I_{\text{raw}} - I_{\text{dark}} \tag{1}$$

式中: I_{raw} 为原始 X 射线图像的像素灰度; $I_{\text{corrected}}$ 为校正后的图像灰度。此步骤逐像素减去暗电流值,消除噪声干扰。随后,执行平场校正以校正 X 射线源的非均匀照射以及探测器固有的背景效应。在无木材样本的情况下采集平场图像,记录均匀照射强度 I_{flat} 。并从中减去暗电流强度以得到校正后的平场图像 $I_{\text{flat, corrected}} = I_{\text{flat}} - I_{\text{dark}}$ 。平场校正公式为:

$$I_{normalized} = \frac{I_{corrected}}{I_{flat,corrected}} \tag{2}$$

此步骤旨在消除非均匀照射和背景干扰。

为增强木材图像的可视化效果和特征提取效率,通过对对比度调整自动调整图像的灰度范围,使木材纹理、缺陷等特征更加明显。对比度调整基于以下线性变换:

$$I_{adjusted} = \frac{I_{normalized} - I_{min}}{I_{max} - I_{min}} \times (I_{out,max} - I_{out,min}) + I_{out,min} \tag{3}$$

式中: I_{min} 和 I_{max} 为输入图像的最小和最大灰度值; $I_{out,min}$ 和 $I_{out,max}$ 为输出图像的灰度范围,此步骤确保后续裁剪和分割能够更好地聚焦于木材的内部结构。随后,进行边缘裁剪以聚焦于木材主体区域,裁剪掉木材样本边缘以外的 X 射线直接照射在探测器上的高强度背景成像区域,保留木材核心区域,裁剪尺寸根据样本大小灵活调整。接着,对裁剪后的图像进行统一分割,将其划分为多个如图 3 所示的 300×300 pixels 的子区域,生成精确的木材区域图像。




图 3 木材样品 X 射线图
Fig. 3 X-ray image of wood sample

1.4 EDMA-Net 网络结构

所提 EDMA-Net 网络结构整体框架如图 4 所示,该网络基于 EfficientNetV2-S 主干进行改进,融合了两种轻量级注意力机制:高效通道注意力(efficient channel

attention,ECA)与全局注意力(global attention module,GAM)模块。EDMA-Net 由多个改进的 MBConv 与 FusedMBConv 构成,分别在其中引入 ECA 与 GAM 模块,以增强模型对通道维度和空间维度的重要性建模能力。




图 4 EDMA-Net 网络整体结构
Fig. 4 Overall of the EDMA-Net

在网络前端,输入图像首先经过 Stem 模块完成初步特征提取与尺寸下采样,随后依次进入多个卷积模块。浅层采用 FusedMBConv 结构,主要负责纹理与边缘特征的提取,并在其尾部嵌入 GAM 模块。GAM 模块结合通道注意力分支与空间注意力分支,提升模型对图像中全局结构的感知能力。深层采用 MBConv 结构,用于提取高层语

义特征,并集成 ECA 模块以建模局部通道间的交互。ECA 模块由全局平均池化、1D 卷积及 Sigmoid 激活函数构成,通过去除冗余全连接操作实现高效通道建模,兼顾轻量性与表达能力。

EDMA-Net 采用了一种分层异构注意力策略,通过在网络的不同深度阶段策略性地部署两种不同的注意力模

块以实现特征的互补性精炼。

$$\mathbf{X}_{\text{mid}} = \mathbf{F}_{\text{GAM}}(\mathbf{X}_{\text{in}}) \quad (4)$$

$$\mathbf{X}_{\text{out}} = \mathbf{F}_{\text{ECA}}(\mathbf{F}_{\text{GAM}}(\mathbf{X}_{\text{in}})) \quad (5)$$

GAM在浅层阶段承担了繁重的空间定位和全局上下文建模任务,浅层GAM输出的全局注意力权重 $\mathbf{X}_{\text{mid}}$ 作为后续层的输入,其输出的特征图 $\mathbf{X}_{\text{mid}} = \mathbf{F}_{\text{GAM}}(\mathbf{X}_{\text{in}})$ 是一个已经过空间和全局通道优化的中间表征。随着网络深度的增加,特征图的空间维度降低,通道维度提升,在此深层

应用ECA模块,网络能够自适应地重校准通道间的特征响应,增强对分类任务最具判别力的语义通道,同时抑制噪声和冗余特征。二者通过网络的深度级联,实现了从全局纹理到核心语义的平滑且高效的特征提纯。

EDMA-Net的具体结构配置如表2所示。在保持较低计算复杂度和快速推理速度的前提下,该网络能够充分感知图像中的关键结构与纹理信息,适用于大规模木材图像的高效分类识别任务。

表2 EDMA-Net网络结构配置(输入尺寸为 300×300 pixels)

Table 2 Network structure configuration of EDMA-Net (Input size: 300×300 pixels)

层	结构说明	输出尺寸/pixel
Stem	3×3 Conv, stride 2	150×150
	3×3 Conv, stride 1+BN+SiLU	150×150
FusedMBConv Block 1	3×3 Conv $\times 2$, expansion ratio 1, GAM, stride 1	150×150
FusedMBConv Block 2	3×3 Conv $\times 4$, expansion ratio 4, GAM, stride 2	75×75
FusedMBConv Block 3	3×3 Conv $\times 4$, expansion ratio 4, GAM, stride 2	38×38
MBConv Block 4	3×3 DWConv+ 1×1 Conv+ECA $\times 6$, expansion ratio 4, stride 2	19×19
MBConv Block 5	3×3 DWConv+ 1×1 Conv+ECA $\times 9$, expansion ratio 6, stride 1	19×19
MBConv Block 6	3×3 DWConv+ 1×1 Conv+ECA $\times 15$, expansion ratio 6, stride 2	10×10
Head	1×1 Conv+BN+SiLU	10×10
Classification	Global Average Pooling (GAP)+Dropout+FC (10 classes)	$1 \times 1 \times 10$

1.5 ECA 模块

在深度神经网络中,通道注意力机制通过对特征图的通道维度进行加权,显著提升了模型的特征表达能力。然而,传统方法如挤压-激励(squeeze-and-excitation,SE)模块往往依赖复杂的全连接层,导致计算成本较高。为此,Wang等^[19]于2019年提出了高效通道注意力模块,以较低的计算复杂度实现对通道间重要性的精准建模,从而增强模型性能,将计算复杂度从 $O(C^2)$ 降至 $O(C)$ 。ECA模块原理如图5所示。




图5 高效通道注意力模块

Fig. 5 Efficient channel attention module

ECA模块通过全局平均池化、局部一维卷积和权重归一化3个步骤实现通道注意力加权。对于输入特征图 $\mathbf{X} \in \mathbb{R}^{C \times H \times W}$,其中 C 、 H 、 W 分别为通道数、高度和宽度,首先通过全局平均池化生成通道描述向量 $\mathbf{z} \in \mathbb{R}^C$,其计

算公式为:

$$z_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_c(i, j), c = 1, 2, \dots, C \quad (6)$$

式中: $x_c(i, j)$ 表示第 c 个通道在位置 (i, j) 的像素值; z_c 为第 c 个通道的全局平均值。随后,采用一维卷积捕捉通道间的局部依赖关系,生成注意力权重 $\mathbf{w} \in \mathbb{R}^C$,一维卷积操作定义为:

$$w_c = \sum_{m=-k/2}^{k/2} \omega_m z_{c+m}, c = 1, 2, \dots, C \quad (7)$$

式中:卷积核大小 k 根据通道数 C 自适应确定,其表达式为:

$$k = \left\lfloor \frac{\log_2(C)}{\gamma} + \frac{b}{\gamma} \right\rfloor \quad (8)$$

在实验中取 $\gamma = 2$, $b = 1$ 。权重 w_c 通过Sigmoid函数归一化,得到通道注意力权重:

$$a_c = \sigma(w_c) = \frac{1}{1 + e^{-w_c}} \quad (9)$$

将其与原始特征图逐通道相乘,生成加权特征图。

1.6 GAM 模块

GAM^[20]是一种用于提升卷积神经网络性能的高效注意力模块,特别适用于处理具有复杂结构和高维特征的数据,结构如图6所示。GAM通过捕捉输入特征的全局上下文信息以及各维度间的交互关系,有效增强了网络对显著区域和关键信息的建模能力。其核心结构由通道注意力子模块与空间注意力子模块构成。在通道注意力模块中,GAM引入三维置换(3D permutation)操作以充分保留

特征在通道、高度与宽度 3 个维度的全局信息,并通过两层多层感知器(multi-layer perception, MLP)^[21]强化通道间、通道与空间之间的交互关联。随后,空间注意力模块通过两个卷积层对通道增强后的特征图进行处理,从而进一步聚焦空间结构中具有判别性的区域。与传统注意力机制相比,GAM 在特征提取精度与计算效率之间实现了更优的平衡,在复杂模式识别与图像分析任务中表现出更强的泛化能力。




图 6 全局注意力模块

Fig. 6 Global attention module

首先,通过输入特征图 F_1 生成通道注意力图 $M_c(F_1)$,并计算中间特征图:

$$F_2 = M_c(F_1) \otimes F_1 \quad (10)$$

接着,对中间特征图 F_2 应用空间注意力图 $M_s(F_2)$,得到最终输出特征图:

$$F_3 = M_s(F_2) \otimes F_2 \quad (11)$$

式中: $\otimes$ 表示逐元素乘法; F_1 为输入特征图; F_2 为经过通道注意力增强后的中间特征图; F_3 为最终输出结果。

2 实验与分析

2.1 数据集构建

目前,基于 X 射线单投影成像的木材种类分类数据集存在显著缺失。为填补这一空白,本研究构建了一个整合木材物种标注与结构特征的标准化数据集。为确保实验真实性,木材样本源自不同木材产区,涵盖使君子科和豆科的 10 种典型木材,涉及黄檀属、紫檀属和古夷苏木属等常用且具有重要经济价值的物种。每种木材样品经标准化成像与预处理后,被分割为 50 267 个 300×300 pixels 的子区域。为保证数据划分的代表性与实验的可重复性,本研究采用分层随机抽样(stratified random sampling, SRS)策略,以木材物种为分层依据。在每个物种样品集合内独立执行随机打乱与划分,其中 90.5%(45 472 张)样本用于训练,9.5%(4 795 张)样本(来自未用于训练的独立木材)构成测试集,以模拟真实工业场景中的未知样本检测。为验证划分过程的随机性与代表性,对训练集与测试集在样本数量比例、灰度直方图特征均值参数上进行了 Kolmogorov-Smirnov 检验,灰度直方图均值的统计量 $D = 0.0217$, $p = 0.324$;灰度标准差的 $D = 0.0185$, $p = 0.412$ 。从统计意义上看, D 值均低于 0.03, p 值均大于显著性水平 $\alpha = 0.05$ 证实两集合在样本比例和灰度特征分布上高度一致,划分随机性强、无显著偏倚。

数据增强是图像分割后的关键步骤,旨在通过多样化变换丰富数据集。增强策略分为三大类:几何变换、灰度调整和滤波处理。几何变换包括水平翻转、垂直翻转和仿射变换,其中平移范围控制在 $-0.1 \sim 0.1$ 之间,以应对空间变异性和视角变化。灰度调整采用对比度受限自适应直方图均衡化、自动对比度优化和锐化处理,增强图像对比度并突出对缺陷检测至关重要的纹理细节。滤波处理包括高斯模糊、浮雕滤波和基于拉普拉斯核的高通滤波,以模拟成像噪声并强化高频纹理特征。对这些图像的对比度和饱和度进行随机增强,调整范围在 85%~115% 之间,并进行水平翻转以扩展数据。

2.2 实验设置

本实验硬件配置为 Intel (R) Core (TM) i9-10980XE CPU,搭载 NVIDIA GeForce RTX 3090 显卡,深度学习框架基于 PyTorch 1.12.1 构建,配合 CUDA 11.6 实现 GPU 加速计算。网络输入图像尺寸设定为 $300 \text{ pixel} \times 300 \text{ pixel}$,训练轮次为 50,基础学习率设为 1×10^{-4} ,批量大小为 32。

2.3 性能评价指标

本实验采用 5 项指标对模型性能进行综合评估,包括精确率(precision, Pre)、灵敏度(sensitivity, Sen)、准确率(accuracy, Acc)、总体精度(overall accuracy, OA)和 F1,具体公式为:

$$\text{Pre}_i = \frac{\text{TP}_i}{\text{TP}_i + \text{FP}_i} \quad (12)$$

$$\text{Sen}_i = \frac{\text{TP}_i}{\text{TP}_i + \text{FN}_i} \quad (13)$$

$$\text{Acc}_i = \frac{\text{TP}_i + \text{TN}_i}{\text{TP}_i + \text{TN}_i + \text{FP}_i + \text{FN}_i} \quad (14)$$

$$\text{OA} = \frac{\sum_{i=1}^N \text{TP}_i}{N} \quad (15)$$

$$F1_i = 2 \cdot \frac{\text{Pre}_i \cdot \text{Sen}_i}{\text{Pre}_i + \text{Sen}_i} \quad (16)$$

其中, Pre_i 反映模型正确预测某类样本占该类预测总数比例; Sen_i 衡量正确识别某类样本能力; Acc_i 体现对某类样本整体正确预测比例;OA 为所有类别正确预测样本占总样本比例,反映整体性能; $F1$ 是 Pre_i 和 Sen_i 的调和平均数,用于平衡精确性和召回率。

2.4 结果与分析

为直观呈现 EDMA-Net 模型在木材 X 射线单投影图像分类任务中的性能表现,本文对 10 种木材的分类结果进行了量化统计,具体数据如表 3 所示。该表格涵盖了每个类别的真正例、真负例、假正例、假负例,以及基于这些指标计算得到的精确率、灵敏度、准确率 $F1$,并在表格末尾给出了模型的总体精度。从表 3 中的数据可以看出,EDMA-Net 模型在 10 种木材的分类任务中整体表现优异,总体精度达到 98.04%。其中,类别 2(交趾黄檀)、类别 6(爱里古夷苏木)的 $F1$ 均超过 99.8%,表现最为突出,这得益于模型对其内

部纹理和密度分布特征的精准捕捉;类别 3(阔叶黄檀)和类别 8(非洲紫檀)的 $F1$ 相对较低,但仍保持在 95%以上,类别 3 与 8 的木材在显微结构上存在较高的相似性,尤其在 X 射线单投影图像中,其导管排列方向、径向射线分布以及孔

隙密度等纹理特征呈现出高度重叠的表现。由于这些细微的纹理特征在灰度空间中对对比度较低,模型在特征提取阶段难以形成具有足够区分性的高层语义特征,导致类间特征分布在嵌入空间中出现重叠,从而引发判别模糊。

表 3 EDMA-Net 模型对 10 种木材的分类性能指标

Table 3 Classification performance indicators of EDMA-Net model for 10 wood species									
类别	TP	TN	FP	FN	Pre/%	Sen/%	Acc/%	$F1$ /%	OA/%
0	374	3 435	17	10	95.65	97.40	99.30	96.52	98.04
1	372	3 451	9	4	97.64	98.94	99.66	98.28	
2	384	3 451	1	0	99.74	100.00	99.97	99.87	
3	363	3 439	13	21	96.54	94.53	99.11	95.53	
4	378	3 445	7	6	98.18	98.44	99.66	98.31	
5	384	3 443	9	0	97.71	100.00	99.77	98.84	
6	383	3 452	0	1	100.00	99.74	99.97	99.87	
7	381	3 446	2	7	99.48	98.20	99.77	98.83	
8	364	3 439	13	20	96.55	94.79	99.14	95.66	
9	378	3 448	4	6	98.95	98.44	99.74	98.69	

图 7 给出了不同模型的混淆矩阵,图 7 中对角线值代表真阳性率(TPR),即某类木材被正确识别的比例;每列非对角线值之和表示某一种木材的假阴性率(FNR),即真实属于该类的木材样本被误判为其他类别的比例。由图 7 可知,本文提出的改进模型 EDMA-

Net 的混淆矩阵对角线响应比原始 EfficientNetV2-S 模型的混淆矩阵平均值高,混淆矩阵整体分布表现更好,这代表着改进模型 EDMA-Net 具有更优的木材种类识别能力,验证了融合双重注意力机制的改进策略的有效性。





图 7 木材 X 射线投影图像数据集中对应 10 种木材的混淆矩阵

Fig. 7 Confusion matrix corresponding to 10 wood species in wood X-ray projection image dataset

从表 4 不同模型的分类指标对比可以看出,所提出的 EDMA-Net 在 5 项分类指标上均取得了最佳表现。其中,EDMA-Net 的平均精确率、平均召回率和平均 $F1$ 值显著高于其他对比模型;总体准确率也达到 98.04%,相比 EfficientNetV2-S 提升了约 2.4%。这充分说明了引入双重注意力机制在增强特征表达能力、抑制冗余信息方面的有效性。ShuffleNet 虽轻量化但总体准确率仅 94.49%,DenseNet121 和 ResNet50 特征建模能力有限,EfficientNet 系

列未引入注意力机制存在特征冗余,均不如 EDMA-Net 兼顾全局与局部特征建模。

2.5 消融实验与分析

为验证所提出的 EDMA-Net 模型中各模块的有效性,本研究通过对比不同模型变体的分类性能与参数规模开展消融实验。实验选取 EfficientNetV2-S 作为基础模型,并分别引入 ECA 注意力机制、GAM 注意力机制,与 EDMA-Net 进行性能对比,结果如表 5 所示。从表 5 中可

表 4 不同模型的分类指标对比

Table 4 Comparison of classification performance indicators among different models					%
模型	Average Pre	Average Sen	Average Acc	Average F1	OA
EDMA-Net	98.04	98.05	99.61	98.04	98.04
EfficientNetV2-S	95.86	95.46	99.13	95.65	95.66
DenseNet121	92.02	91.93	98.38	91.71	91.92
EfficientNetB3	94.08	94.01	98.80	93.88	94.01
ResNet50	90.81	90.35	98.08	90.26	90.39
ShuffleNet	94.68	94.50	94.50	94.38	94.49

表 5 不同模型的分类性能与参数规模对比

Table 5 Comparison of classification performance and parameter scale among different models				
模型	Acc/%	参数量/M	平均单张图像推理时间/ms	FPS/fps
EfficientNetV2-S	95.66	20.19	7.29	137.17
EfficientNetV2-S+ECA ^[22]	96.95	17.99	7.03	142.25
EfficientNetV2-S+GAM	97.87	16.99	7.21	138.70
EDMA-Net	98.04	16.51	7.00	142.95

知,相较于基础模型 EfficientNetV2-S,仅融合单一注意力机制的变体模型在分类准确率上均有所提升;引入 ECA 注意力后,准确率由 95.66%提升至 96.95%,参数量降低至 17.99 M,同时平均单张图像推理时间为 7.03 ms,对应推理速度为 142.25 fps;引入 GAM 注意力后,准确率进一步提升至 97.87%,参数量减少至 16.99 M,平均单张图像推理时间为 7.21 ms,推理速度为 138.70 fps。相比之下,EDMA-Net 通过通道注意力与空间注意力的互补融合及可配置模块化设计,在进一步压缩参数规模至 16.51 M 的同时,将分类准

确率提升至 98.04%,平均单张图像推理时间为 7.00 ms,推理速度达到 142.95 fps。上述结果表明,EDMA-Net 通过多注意力机制的协同优化,在保证模型轻量化的前提下有效提升了分类性能,验证了模型结构设计的合理性与优越性,为木材材质的精准识别提供了更高效的解决方案。

2.6 真实家具样品测试

为验证模型在实际应用场景中的有效性,本研究联合上海翰林家具厂获取了如图 8 所示的基于真实家具样品的板材以及模拟家具样品,其中模拟家具样品均按照常规



图 8 测试家具板材样品实物

Fig. 8 Physical images of tested furniture board samples

高值木家具的制作工艺进行加工制作,严格按照“双面油漆,两底三面”的制作工艺,其中板材样品尺寸为 10 cm×5 cm×2 cm,模拟家具样品尺寸为 7 cm×11.6 cm×1.5 cm、7 cm×15 cm×1.5 cm。基于已构建的材质可视化 X 射线无损检测仪及 EDMA-Net 模型开展测试。测试采用遍历单块家具木板多张预处理后的 X 射线投影图像的方式进行预测,具体测试结果如表 6 所示,展示了模型对 10 块真实家具板材样品的识别准确率。在每组 504 张图像的测试中,模型对所有样品的识别准确率均高于 96%,显示了出色的性能。具体来看,识别准确率最高的是样品 10,达到了 99.01%;准确率最低的是样品 5,为 96.23%。绝大多数样品的准确率集中在 96%~98%内。这些数据充分证明,所提出的模型对真实的家具板材具有很高的识别精度和良好的稳定性。

表 6 真实家具板材样品的模型识别准确率对比
Table 6 Comparison of model recognition accuracy for real furniture board samples

样品编号	实际材质	图像张数	P/%
1	非洲紫檀	504	98.21
2	成对古夷苏木	504	97.02
3	东非黑黄檀	504	98.41
4	巴里黄檀	504	97.81
5	交趾黄檀	504	96.23
6	阔叶黄檀	504	96.62
7	风车木	504	96.42
8	爱里古夷苏木	504	97.72
9	染料紫檀	504	97.81
10	大果紫檀	504	99.01

3 结 论

本研究首次提出了一种基于 X 射线单投影成像与双重注意力机制的木材智能鉴别系统,针对家具市场木材种类鉴别效率低、以假充真等问题,开发了融合 GAM 与 ECA 双重注意力机制的 EDMA-Net 模型。通过利用材质可视化 X 射线无损检测仪采集并预处理图像,构建包含 10 种代表性木材的 X 射线图像数据集,系统实现了高效、精准的木材种类分类。实验结果表明,EDMA-Net 模型在 10 种木材分类任务中总体精度达到 98.04%,其中对交趾黄檀和爱里古夷苏木的 F1 超过 99.8%,展现了优异的特征捕捉能力。消融实验进一步证明,融合 GAM 与 ECA 的 EDMA-Net 在参数量减少至 16.51 M 的同时,分类性能较基础 EfficientNetV2-S 提升 2.38%,单张图像推理速度达到 7.00 ms,展现了模型的高效性与轻量化优势。在真实家具板材测试中,模型对所有样品的识别准确率均高于 95%,显示了出色的性能。本研究的主要创新贡献包括:

首次提出 GAM-ECA 协同注意力机制,解决木材纹理的全局-局部特征融合难题;开发首个基于 X 射线单投影成像的端到端木材检测系统,在参数量减少 18.2%的同时,准确率提升 2.38%。

尽管改进模型在木材种类识别任务中精度显著提升,但 X 射线单投影图像在复杂纹理、多缺陷共存的木材检测中仍存在局限——难以精准区分纹理高度相似的近缘树种,可能影响市场中高端木材的鉴别可靠性。后续将聚焦于优化注意力机制的动态融合策略,探索基于多尺度特征交互的细粒度识别方法;同时扩充涵盖更多近缘树种、变异纹理的样本数据集,引入类似 Grad-CAM 的可视化技术解析模型决策依据,进一步提升系统对复杂场景的适配能力与结果可解释性。

参考文献

[1] DOCZEKALSKA B, STACHOWIAK-WENCEK A, ROSZYK E, et al. Thermochemical modification of beech wood with ammonium hydroxide[J]. European Journal of Wood and Wood Products, 2023, 82(2): 299-308.

[2] 郭灿志,潘琛,孙万,等. 木材缺陷双机械手空气耦合超声检测方法[J]. 电子测量技术, 2022, 45(22): 64-68.

GUO C Z, PAN C, SUN W, et al. Dual-robot air-coupled ultrasonic testing method for wood defects[J]. Electronic Measurement Technology, 2022, 45(22): 64-68.

[3] AMORIM DA SILVA J L, BORDALO R, PISSARRA J, et al. Computer vision-based wood identification: A review[J]. Forests, 2022, 13(12): 2041.

[4] LUKOVIC M, CIERNIK L, MÜLLER G, et al. Probing the complexity of wood with computer vision: From pixels to properties[J]. Journal of the Royal Society Interface, 2024, 21(213): 20230492.

[5] 黄鹏桂,赵璠,李晓平,等. 基于计算机的木材特征提取和分类识别技术研究综述[J]. 世界林业研究, 2020, 33(1): 44-48.

HUANG P G, ZHAO F, LI X P, et al. A review of computer-based wood feature extraction and classification recognition technology [J]. World Forestry Research, 2020, 33(1): 44-48.

[6] 何斐,张颖,李麟杰,等. 基于 GC-MS 的“花梨”木材微损快速鉴别方法[J]. 林业科技通讯, 2025(5): 78-81.

HE F, ZHANG Y, LI L J, et al. A rapid micro-destructive identification method for Huali wood based on GC-MS [J]. Forest Science and Technology Communications, 2025(5): 78-81.

[7] KIRBAS I, CIFCI A. An effective and fast solution

- for classification of wood species: A deep transfer learning approach[J]. *Ecological Informatics*, 2022, 69: 101633.
- [8] 徐志扬,陈巧,陈永富. 融合注意力和残差网络的无人机影像树种识别[J]. *激光与光电子学进展*, 2023, 60(2): 90-98.
- XU Z Y, CHEN Q, CHEN Y F. Tree species recognition using combined attention and ResNet for unmanned aerial vehicle images [J]. *Laser & Optoelectronics Progress*, 2023, 60(2): 90-98.
- [9] LIU S J, ZHENG C, WANG J J, et al. How to discriminate wood of CITES-listed tree species from their look-alikes: Using an attention mechanism with the ResNet model on an enhanced macroscopic image dataset[J]. *Frontiers in Plant Science*, 2024, 15: 1368885.
- [10] 曾德裕,谭淦,钟敏良,等. 锂电池 X 射线图像增强算法研究[J]. *电子测量技术*, 2025, 48(5):166-174.
- ZENG D R, TAN G, ZHONG M L, et al. Research on lithium battery X-ray image enhancement algorithm[J]. *Electronic Measurement Technology*, 2025, 48(5): 166-174.
- [11] 林子涵,张巧芬,王桂棠. 新型 PIS-YOLO 模型下的 X 射线注塑缺陷检测方法研究[J]. *电子测量与仪器学报*, 2025, 39(8):136-144.
- LIN Z H, ZHANG Q F, WANG G T. Research on improved automatic defect detection method of X-ray injection parts under PIS-YOLO model[J]. *Journal of Electronic Measurement and Instrumentation*, 2025, 39(8): 136-144.
- [12] 吕瑞宏,李大玮,沈红博. 基于 CT 图像的煤矸元素成分分析算法研究[J]. *仪器仪表学报*, 2025, 46(3): 170-179.
- LYU R H, LI D W, SHEN H B. Research on coal gangue elemental composition analysis algorithm based on CT imaging [J]. *Chinese Journal of Scientific Instrument*, 2025, 46(3): 170-179.
- [13] 许明伟,薛艳玲,陈荣昌,等. 基于相位衬度成像的 X 射线生物特征识别仪[J]. *核技术*, 2021, 44(8): 29-38.
- XU M W, XUE Y L, CHEN R C, et al. A biometrics recognition instrument using X-ray phase contrast imaging for biosafety inspection [J]. *Nuclear Techniques*, 2021, 44(8):29-38.
- [14] VACEK O, GERGEL' T, BUCHA T, et al. Automatic wood species classification and pith detection in log CT images[J]. *Forests*, 2024, 15(12): 2207.
- [15] AN H, LIANG Z H, QIN M M, et al. Wood defect detection based on the CWB-YOLOv8 algorithm[J]. *Journal of Wood Science*, 2024, 70(1): 26.
- [16] KOBAYASHI K, HWANG S W, 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.
- [17] TAN M X, LE Q. EfficientNetV2: Smaller models and faster training[C]//38th International Conference on Machine Learning, 2021: 10096-10106.
- [18] DU K, XU M W, XUE Y L, et al. Time varying flat field correction of X-ray microtomography with an improved deep-learning method[J]. *Optics Express*, 2024, 32(23): 40134-40149.
- [19] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11531-11539.
- [20] LIU Y C, SHAO Z R, HOFFMANN N. Global attention mechanism: Retain information to enhance channel-spatial interactions[J]. *ArXiv preprint arXiv: 2112.05561*, 2021.
- [21] TOLSTIKHIN I, HOULSBY N, KOLESNIKOV A, et al. MLP-mixer: An all-MLP architecture for vision[J]. *ArXiv preprint arXiv: 2105.01601*, 2021.
- [22] PACAL I, CELIK O, BAYRAM B, et al. Enhancing EfficientNetv2 with global and efficient channel attention mechanisms for accurate MRI-based brain tumor classification[J]. *Cluster Computing*, 2024, 27(8): 11187-11212.

作者简介

黄承雷, 硕士研究生, 主要研究方向为 X 射线图像智能识别。

E-mail: huangchenglei@sinap. ac. cn

薛艳玲(通信作者), 博士生导师, 研究员, 主要研究方向为 X 射线无损检测与智能识别。

E-mail: xueyl@sari. ac. cn

杜康, 博士研究生, 主要研究方向为 X 射线成像平场校正以及 X 射线图像智能识别。

E-mail: dukang@sinap. ac. cn

肖体乔, 博士生导师, 研究员, 主要研究方向为成像光学、X 射线光学以及图像重构与处理。

E-mail: tqxiao@sari. ac. cn