

DOI:10.3979/j.issn.1673-825X.202408150220

## 基于深度学习的木板激光散斑图像分类研究

杜艳秋,李鑫,康辉,孙辉

(黑龙江科技大学 电子与信息工程学院,哈尔滨 150022)

**摘要:**提出一种激光散斑技术和深度学习技术相结合的木板识别方法。利用常规照相技术和激光散斑技术获取木板改性处理前后在常规照明和恶劣环境(黑暗环境、虚焦状态)下的木板图像及其激光散斑图像,并建立相应的数据集。采用 ResNet34 深度学习网络模型对数据集进行分类实验,结果表明,ResNet34 模型对激光散斑数据集进行分类时能够达到较高的识别准确率,并在恶劣环境下,使用激光散斑图像数据集分类时,能够取得较好的分类效果。同时,引入混合注意力机制(convolutional block attention module,CBAM)模块对 ResNet34 卷积神经网络进行优化,用于激光散斑图像分类,识别正确率达到 93.29%。利用激光散斑技术及深度学习模型进行木板种类识别对环境要求较低,是一种新颖的、有前途的高效技术方法。

**关键词:**激光散斑;ResNet34;图像分类;木板识别;深度学习

中图分类号:TP391.4

文献标志码:A

文章编号:1673-825X(2025)05-0677-11

## Classification of wood board laser speckle images based on deep learning

DU Yanqiu, LI Xin, KANG Hui, SUN Hui

(School of Electronic and Information Engineering, Heilongjiang University of Science and Technology, Harbin 150022, P. R. China)

**Abstract:** This study proposes a wood board recognition method that integrates laser speckle technology with deep learning. Conventional photography and laser speckle imaging were employed to capture wood board images before and after modification treatments under both normal lighting and adverse conditions (including darkness and defocusing). A corresponding dataset was then constructed. Classification experiments were conducted using the ResNet34 deep learning model. The results show that the ResNet34 model achieves high recognition accuracy when classifying laser speckle datasets and maintains good performance even under adverse environmental conditions. Furthermore, by introducing a convolutional block attention module (CBAM) to optimize the ResNet34 convolutional neural network, the classification accuracy for laser speckle images reached 93.29%. The combination of laser speckle technology and deep learning provides a low-environmental-requirement, efficient, and promising approach for wood board classification.

**Keywords:** laser speckle; ResNet34; image classification; wood board recognition; deep learning

收稿日期:2024-08-15 修订日期:2025-05-29 通讯作者:杜艳秋 hellen\_q@126.com

基金项目:黑龙江省自然科学基金项目(LH2023F049);黑龙江省博士后科研启动基金项目(2023BSH02);黑龙江省省属本科高校基本科研业务费项目(2024-KYYWF-1083)

Foundation Items: Heilongjiang Provincial Natural Science Foundation (LH2023F049); Heilongjiang Provincial Postdoctoral Startup Research Fund (2023BSH02); Fundamental Research Funds for the Provincial Universities in Heilongjiang Province (2024-KYYWF-1083)

## 0 引言

激光散斑是当激光穿过波长尺度上的粗糙物体或被物体反射后,由于光的强度分布被调制,从而形成的高对比度且尺寸细微的颗粒图样。在现代生物医学领域,利用激光穿过机体组织形成的激光散斑图像可以实现机体的非接触感知,能够无创、实时地监测脑血流量<sup>[1]</sup>、术中血流量<sup>[2]</sup>等血液微循环。在农业领域,利用激光散斑动力学可对农业害虫-蚜虫的摄食行为进行直接、非侵入式、遥感监测<sup>[3]</sup>,还可以对木瓜叶片的活性<sup>[4]</sup>,以及甜菜根须部分进行检测<sup>[5]</sup>,进而研究植物组织的动态变化,以便实时监测生长区的生理过程。另外,在传感及检测领域,利用激光散斑还可实现应力<sup>[6]</sup>、位移<sup>[7]</sup>、磁场<sup>[8]</sup>、振动<sup>[9]</sup>、粗糙度<sup>[10]</sup>等物理参量的无接触测量,以及结构中隐性损伤的可视化探测<sup>[11]</sup>。最近,激光散斑技术成功地用于图像分类识别领域,已经实现了黑暗环境下铜和不锈钢的识别<sup>[12]</sup>,以及煤矸石和煤的分类<sup>[13]</sup>。

木材作为我国国民经济建设中的重要自然资源,在国计民生中占据着重要的地位。对木材种类的鉴定和识别对于木材工业及贸易的规范化、濒危木材种类的保护、(古)建筑的保护及修复,以及犯罪学、考古学、生态学<sup>[14]</sup>等相关学科的发展具有重大的科学研究价值和实际应用意义。

传统的木材识别通常采用木材的颜色、光泽等物理特性和截面上的宏观解剖结构等信息,并依靠肉眼进行鉴别。在实验室中,木材识别通常是通过观察显微镜下木材薄片的各种解剖特征来进行。随着 AI 技术的迅猛发展,采用机器视觉和深度学习技术的分类模型及方法在木材识别领域拥有了前所未有的机会。2014 年, Hafemann 等<sup>[15]</sup>将卷积神经网络(convolutional neural networks, CNN)用于森林木材种类识别,对 41 种物种的树木横截面宏观图像和 112 种物种的微观图像数据进行分类,分别取得了 95.77% 和 97.32% 的准确率,表明 CNN 模型的性能优于基于纹理特征训练的模型。之后,基于卷积神经网络的深度学习模型广泛地应用于木材识别领域<sup>[14,16-17]</sup>。目前,利用深度学习的木材种类分类研究大部分是以木材的宏观表面图像<sup>[18-19]</sup>、宏观截面图像<sup>[20-21]</sup>、显微镜放大的微观解剖图像<sup>[22]</sup>建立数据集,部分文献采用近红外光谱图像<sup>[23-24]</sup>、高光谱图像<sup>[25]</sup>、x 射线荧光光谱图像<sup>[26]</sup>等作为数据集,采

用 AlexNet<sup>[27]</sup>、VGG<sup>[28]</sup>、MobileNet<sup>[29]</sup>、ResNet<sup>[18,30]</sup>、InceptionNet、XceptionNet<sup>[31]</sup>、GoogLeNet、DenseNet、EfficientNet<sup>[32]</sup>、ShuffleNet 等卷积神经网络<sup>[21]</sup>进行特征提取和分类。

相对于直接成像而言,形成激光散斑的光源为特定的激光,其高方向性和高单色性使其不仅适合于通常条件下的图像分类,而且特别适用于恶劣环境(如:夜间)中、及改性物体的远程监测及分类识别。木材的激光散斑图像是通过激光照射木材表面而形成的散斑图案,具有高分辨率特性,携带着木材表面独特的纹理特征,如年轮、裂纹、节子、颜色变化等,不但能够对木材进行高精度、无破坏性检测和识别,而且能够反映出木材的生长环境、处理工艺等信息。通过高分辨率的激光散斑图像,可以更加准确地识别木材种类、判断木材的质量和等级,进而确定其用途,为木材的合理利用、木材产业的可持续发展提供有力支持,尤其对珍贵木材或需要保持完整性的木材进行识别时,具有更加显著的优势。利用激光散斑技术,建立木材的激光散斑数据集,并利用深度学习技术进行训练和识别,可以实现更加高效、准确的木材识别,在木材产业的智能化、自动化和数字化方面具有重要意义。

目前,尚没有公开的木材激光散斑数据集,因此,本研究利用波长为 632.8 nm 的红色激光作为相干光源,建立不同条件下木材及改性木材的非散斑图像和激光散斑图像数据集,采用 ResNet 网络及优化的模型,对激光散斑技术在木材识别领域的应用进行探索性研究。

## 1 数据集的建立

为了研究木板激光散斑数据集的分类效果,首先利用常规照相技术,建立木板图像数据集。然后,引入激光,获取木板的激光散斑图像,建立激光散斑数据集。

### 1.1 数据集图片采集系统

木材激光散斑图像采集系统如图 1 所示,该系统主要由激光器、扩束器、CMOS 相机以及计算机组成。其中选用的激光器为氩氦激光器,波长为 632.8 nm,功率为 2 mW;扩束器中包含一个放大倍数为 15 倍扩束镜和一个准直透镜;计算机主要用来存储和显示 CMOS 相机传输的图像数据。在采集过程中,关闭激光器后,采集到的木板图像用于建立常规木板图像数据集。




图 1 激光散斑图像采集示意图

Fig.1 Schematic diagram of the laser speckle image acquisition

### 1.2 图像采集及预处理

实验中选用 10 种常用家具木材作为样本,分别为北美红橡木、榉木、北美白蜡木、樱桃木、南美胡桃木、南美柚木、红花梨木、枫木、桦木和松木。每块木板加工为 8 cm×8 cm×2 cm 大小,每个材种的木板数量为 20 块。分别采集木板没有激光照射的图像以及激光散斑图像,每种木板各采集 240 张常规图

像及激光散斑图像,对 10 种木材共采集木板常规图像和激光散斑图像各 2 400 张,作为部分数据,分别用于构建数据集①和数据集②,相关信息如表 1 所示。作为示例,图 2 给出了一组相同条件下得到的 10 种木材的常规图像(第 1、3 行)及激光散斑图像(第 2、4 行)。

表 1 数据集相关数据

Tab.1 Dataset related data

采集条件	常规照相图像	激光散斑图像
原木板(未做改性处理)	240	240
①泡水处理	200	200
②铅笔涂画	220	220
改性处理 ③砂纸打磨	200	200
④粉刷白漆	240	240
⑤粉刷黑漆	240	240
10 种木板合计	13 400①	13 400②
恶劣环境下	黑暗环境下	200
	虚焦状态下	200
10 种木板合计	4 000	4 000
所有总计	17 400③	17 400④

注:①②③④表示对应建立的 4 个数据集图片数量。




图 2 木板常规图像和其对应的激光散斑图像

Fig.2 Wood board images and their laser speckle images

考虑到木板在运输、保存、加工等过程中可能受到的外界环境影响,人为对 10 种木板分别进行了如下改性处理:①泡水处理。每个品种的木板随机选取其中的几块进行泡水,泡水时间基本保持一致,大约为 12 h,用来模拟被雨水淋湿的木板;②铅笔涂画处理。有些木板表面会有一些污渍,影响对木板的识别判断,将用铅笔涂画后的木板代替有污渍的木板;③砂纸打磨处理。用砂纸将木板表面打磨,使其表面变粗糙;④粉刷白漆。将砂纸打磨好的木板随机排列,粉刷油漆时使用油漆刷沿着一个方向进行刷漆,刷完一遍后放置 3~4 h 待其晾干,再刷一遍油漆,重复此操作;⑤粉刷黑漆。与④操作步骤相同。

木板经过改性处理后,分别采集常规图像及激光散斑图像。改性处理①和改性处理③的每种木板

以 2 种方式分别采集图像各 200 张;改性处理②的每种木板分别采集图像 220 张;改性处理④和改性处理⑤的木板分别采集图像各 240 张,这些图像构成数据集①和数据集②的另一部分,相关信息见表 1。图 3 给出了白蜡木及改性后的常规图像和激光散斑图像。

同时,为了研究恶劣环境下利用激光散斑图像进行木板分类的优越性,分别在黑暗环境中和镜头虚焦状态下采集木板的常规图像及激光散斑图像,每种条件下每种木板分别采集 200 张常规照相图像和 200 张激光散斑图像,将常规图像和激光散斑图像分别添加至数据集①和数据集②中,构成数据集③和数据集④,相关信息列于表 1。同样,以白蜡木为例,2 种情况下采集到的常规图像和散斑图像如图 4 所示。




图 3 白蜡木改性后的常规图像及激光散斑图像

Fig.3 Processed wooden board images and their laser speckle images




图 4 白蜡木在恶劣环境下的常规图像和激光散斑图像

Fig.4 Wood board images and laser speckle images of wax wood under different environmental conditions

在图像的采集过程中,外部环境的不稳定性会对工业相机中的图像传感器造成干扰,同时 CMOS 相机中的电子电路噪声也会引入椒盐噪声,进而影响木板图像的质量。因此,在训练模型之前,必须对

木板图像进行降噪处理,以符合 CNN 对输入图像的要求,并进一步提升 CNN 模型的泛化能力。本研究中选择中值滤波法对木板图像和激光散斑图像进行降噪处理,以提高后续对图像分析的准确性。中值

滤波算法计算过程如图 5 所示。




图 5 中值滤波算法

Fig.5 Median filtering algorithm

其计算过程为首先将待处理像素的邻近区域内的像素值按照递增或递减的顺序排列,形成一个序列。确定这个序列的中位数,这个数便是实验所需的中值。然后,将这个中值作为新的像素值,用以替换原先待处理的像素值。最后,会在下一个待处理的像素上重复上述步骤,直至所有的像素点都被遍历。由于像素值的突变对中值滤波的影响较小,因此,中值滤波在处理激光散斑图像中的椒盐噪声时表现出色,能够有效地去除噪声,提升图像质量。图 6 为激光散斑图像去噪前后的示例。




图 6 图像示例

Fig.6 Example of image

### 1.3 图像数据集的建立

数据集相关信息见表 1,最终共采集 10 种原木木板(未做改性处理的木板)及其改性处理木板的常规图像和激光散斑图像各 13 400 张,从而建立木板常规图像数据集①和木板激光散斑图像数据集②。将每一个数据集划分为 2 部分,其中 90%作为训练集,共 12 060 张图像;10%作为测试集,共 1 340 张,详细信息如表 2 所示。

进一步,将恶劣环境下采集到的木板图像和激光散斑图像分别添加至已建立的数据集中形成新的数据集③和④,其中的木板常规图像和激光散斑图像分别达到 17 400 张,分别用于对比研究在环境影

响下的木板识别效果。将该数据集中图像的 90% (共计 15 660 张图像)作为训练集,剩余部分(共计 1 740 张图像)为测试集,详细划分信息如表 3 所示。

表 2 训练集和测试集划分

Tab.2 Partition of training and testing sets

数据集	训练集	测试集
激光散斑图像	12 060	1 340
常规木板图像	12 060	1 340

表 3 训练集和测试集划分

Tab.3 Division of training set and test set

数据集	训练集	测试集
激光散斑图像	15 660	1 740
常规木板图像	15 660	1 740

## 2 网络架构及实验原理

### 2.1 ResNet 网络及优化

ResNet34 网络是一种深度卷积神经网络模型,网络结构如图 7 所示<sup>[33]</sup>,依次包括 7×7 的卷积层,3×3 的池化层、16 个残差块(每个残差块中包含 2 个 3×3 的卷积层)、全局平均池化层及全连接层。该模型通过引入“残差块”(residual block)和跳跃链接方式(shortcut connections)来解决深层神经网络训练过程中的梯度消失和梯度爆炸问题,以便高效提取图像更多细节特征,从而实现更深层次的网络训练。同时,ResNet34 网络需要的计算资源和训练时间较少,且 ResNet34 对硬件要求较低。ResNet 网络的这些特性使其非常适合于对具有诸多细节特征的激光散斑图像进行分类识别处理。

为了进一步提高模型对激光散斑图像的分类能力,本文在 ResNet34 模型中引入混合注意力机制(convolutional block attention module, CBAM)模块进行改进和优化。CBAM 模块<sup>[34]</sup>包括通道注意力模块和空间注意力模块,属于混合注意力机制,易于嵌入深度学习网络中,获取图像不同维度的特征信息,提高图像分类的能力。本研究中,在每个残差单元中嵌入混合注意力模块 CBAM,构建了 ResNet-CBAM 网络模型,强化网络在通道和空间上对细节特征的提取能力。优化后的 ResNet34-CBAM 网络模型如图 8 所示。首先,输入的激光散斑会通过卷积层进行初步的特征提取,然后,这些特征图会经过

池化处理,以进一步减少数据的维度并增强特征的鲁棒性。接着,这些特征图会依次经过 4 种残差学习单元,这些单元能够有效地提取并整合激光散斑

图像中的多层次特征。最后,网络会采用池化和全连接层对特征进行汇总和分类,从而实现对激光散斑图像的精确识别。

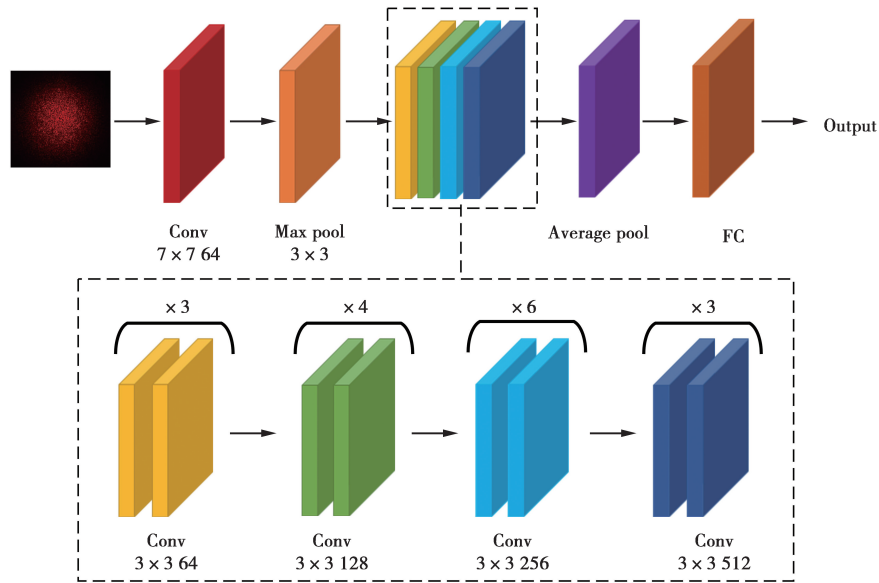


图 7 ResNet34 网络结构

Fig.7 ResNet34 networks structure

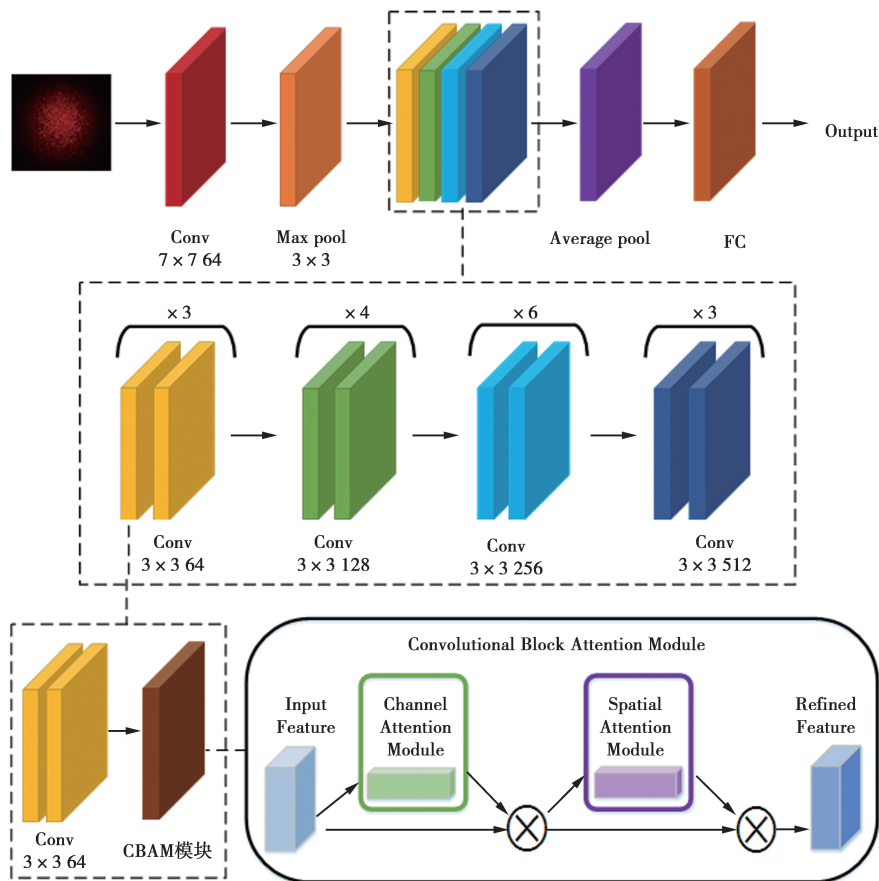


图 8 优化的 ResNet34 网络结构

Fig.8 Improved ResNet34 networks structure

总之, ResNet34 模型及其改进的 ResNet-CBAM 模型具有深层次的网络结构,并融合了混合注意力机制,能够更加关注激光散斑图像中的重要通道和区域,从而提高特征提取的准确性和效率,实现对激光散斑图像特征的全面捕捉和有效利用。并且,改进模型具有更强的泛化能力,保证了激光散斑图像识别的准确率。

### 2.2 激光散斑图像分类原理

激光散斑图的分类流程如图 9 所示,先利用卷积部分对激光散斑图执行特征提取操作,以获取图像中的关键信息,然后,这些提取的特征在全连接部分进一步地被处理和整合,进而生成分类的预测结果。接着,将预测结果与真实结果作为误差函数的输入,计算出一次迭代过程中的误差值,基于这一误差,优化算法会计算误差梯度,并据此对卷积神经网络的参数进行更新。最后,若误差降至预设的阈值以下或迭代次数达到设定的上限,则算法终止迭代过程;否则,将继续进行迭代并更新网络参数,直至满足停止的条件。

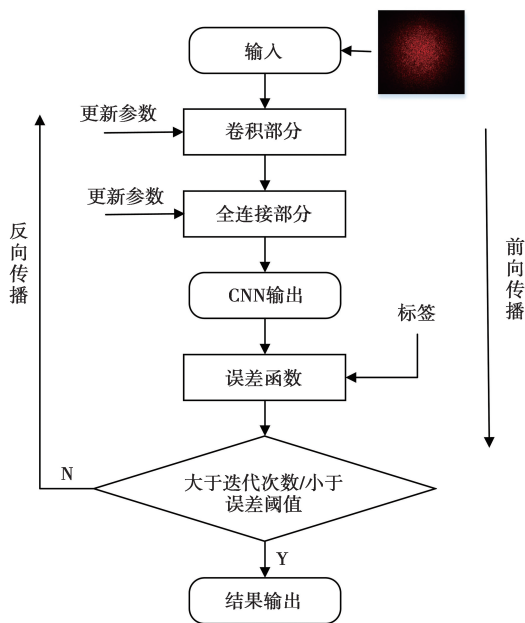


图 9 激光散斑图像分类流程

Fig.9 Classification process of laser speckle pattern

## 3 实验及结果讨论

本文共开展了 3 组实验研究,首先采用 ResNet 模型对常规木板图像数据集和激光散斑数据集进行对比研究,进一步利用 ResNet 模型研究了在恶劣环境下对木板激光散斑图像的分类效果,然后利用优化的 ResNet-CBAM 模型对木材的激光散斑数据集

进行分类实验。

### 3.1 常规图像及散斑图像的分类对比研究

本实验中使用了 i5-12400 CPU 和 RTX 3070 显卡,软件方面选择了 PyTorch 1.8 框架和 Python 3.8 编程语言,并在 Windows 操作系统上运行,选用了 PyCharm 作为开发环境。

采用 ResNet34 网络模型对常规木板图像和激光散斑数据集进行分类实验。实验中设定批量为 32,学习率为 0.001,并设定 300 个训练轮次,选择随机梯度下降(stochastic gradient descent,SGD)算法为优化器。

图 10 呈现了 ResNet34 网络在测试集上的准确率(Accuracy)的变化趋势;图 11 展示了损失函数(Loss)的变化曲线。从图 10 和图 11 中可以看出, ResNet34 网络在木板图像数据集和激光散斑图像数据集上的测试效果较好, Loss 曲线能较快收敛,网络模型在 2 个数据集上展现出了较高的准确度。 ResNet34 网络在激光散斑测试集上的准确率为 90.13%,在木板图像的测试集上的准确率为 89.05%,与模型在激光散斑图像上的识别准确率相比,大约低 1.08%,相关数据见表 3。实验结果说明,利用深度学习能够完成对激光散斑图像的分类,从而完成对木板材种的分类识别。




图 10 2 个数据集上的 Accuracy 曲线

Fig.10 Accuracy curve on two datasets

### 3.2 恶劣环境下的分类研究

进一步,使用 ResNet34 网络对恶劣环境下的数据集进行分类实验,损失函数变化曲线图和准确率变化曲线如图 12—图 13 所示。可以看出,添加环境影响后, ResNet34 网络在两个数据集上依然能取得较好的效果, Loss 曲线能较快收敛,准确率变化曲线波动较小。虽然激光散斑图像测试集上的准确率

变化曲线比木板图像测试集上的准确率变化曲线波动大,但是比不添加激光的木板图像分类准确率大约高 5 个百分点,其中测试集上木板图像的分类准确率为 85.30%,激光散斑的图像分类准确率为 90.36%,如表 4 所示。




图 11 2 个数据集上的 Loss 曲线  
Fig.11 Loss curve on two datasets




图 12 2 个数据集上的 Accuracy 曲线  
Fig.12 Accuracy curve on two datasets

与不添加环境影响的数据进行比较,恶劣环境下木板常规图像数据集的分类准确率由 89.05%下降到 85.30%;而在激光散斑图像数据中,分类准确率由 90.13%略微上升到了 90.36%,详细对比见表 4。出现这种结果的原因是,不添加激光的木板图像数据集中,黑暗环境下以及虚焦状态下,图像质量受到影响,使图片的相关性变差,分类效果降低;而激光具有高度的方向性和亮度,使得散斑图像受外部环境影响较小,在黑暗环境中,仍能获取高质量的激光散斑图像。从图 4 可以看出,在虚焦状态下,激光散斑图像依然清晰。所以,在激光散斑数据集中添加环境影响后的图像质量较高,随着数据集中包含

的数据增多,这有助于模型更好地学习和泛化。所以即使在恶劣环境下,模型在激光散斑图像上依然能保持较高的分类准确率。实验证明,使用激光散斑技术的木板识别过程不易受到外部环境变化的影响。




图 13 2 个数据集上的 Loss 曲线  
Fig.13 Loss curve on two datasets

表 4 实验效果对比

Tab.4 Comparison of experimental effects

图像采集环境	数据集	准确率/%
常规照明	常规木板图像	89.05
	激光散斑图像	90.13
恶劣环境	常规木板图像	85.30
	激光散斑图像	90.36

### 3.3 优化的网络模型分类研究

改进后的 ResNet34-CBAM 模型在激光散斑测试集上结果如图 14—图 15 所示,可看出,准确率变化和损失函数曲线变化都较为稳定,改进的 ResNet34 网络 Loss 曲线收敛速度较快,网络在测试集上的准确率为 93.29%,相比于 ResNet34 网络在测试集上的准确率提高了 2.93%,对比结果如表 5 所示。实验结果表明,改进的 ResNet34 网络在添加环境影响后的测试集上仍有很高的准确率。

表 5 ResNet34 模型及 ResNet34-CBAM 模型的准确率对比  
Tab.5 Comparison of accuracy based on ResNet34 and ResNet34-CBAM

模型 (Model)	准确率 (Accuracy) / %
ResNet-CBAM	93.29
ResNet34	90.36

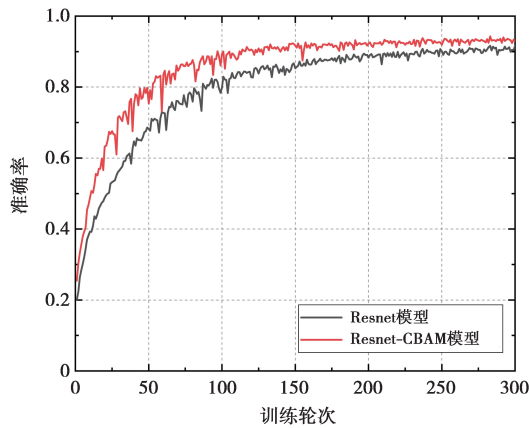


图 14 ResNet34 模型及其改进模型 ResNet34-CBAM 的 Accuracy 曲线

Fig.14 Accuracy curves based on ResNet34 and ResNet34-CBAM

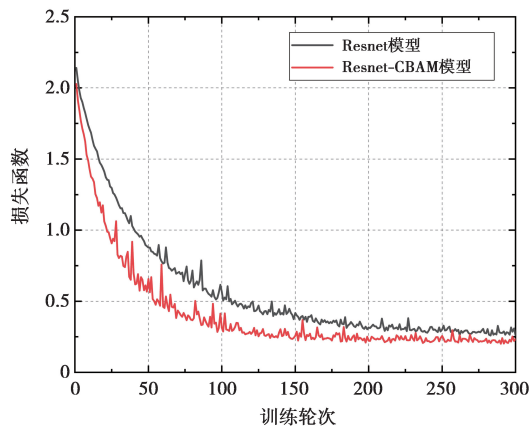


图 15 ResNet34 模型及其改进模型 ResNet34-CBAM 的 Loss 曲线

Fig.15 Loss curves based on ResNet34 and ResNet34-CBAM

## 4 结束语

本文提出了一种结合激光散斑技术和卷积神经网络的木板材种分类识别方法。实验中,采集了 10 种木板及改性后的常规图像以及激光散斑图像,建立了相应图像数据集。采用 ResNet34 网络对分别对常规照相获取的木板图像数据集和激光散斑数据集进行分类实验,其中在木板图像上的准确率为 89.05%,在激光散斑图像上的准确率为 90.13%,两者准确率相当,这说明利用激光散斑技术结合深度学习模型实现木材识别是可行的。另外,在相对较黑暗环境或虚焦状态下采集木板图像以及激光散斑图像,添加到数据集中,使用 ResNet34 网络模型再次进行分类实验,在木板图像数据集和激光散斑数

据集的分类准确率分别为 85.30%和 90.36%。结果表明,使用激光散斑技术识别木板,对环境的要求较低。除此之外,利用残差单元中添加混合注意力机制 CBAM 模块,对 ResNet34 网络进行了优化,其在激光散斑数据集上的分类准确率为 93.29%,达到较好的分类效果。本文将 ResNet 深度学习网络用于木板激光散斑数据集的分类研究,该方法为物体分类及自动识别提供了一条可行的、有前途的途径;进一步通过扩展数据集、改变卷积神经网络模型能够实现更多物体、更高精度的分类识别。

## 参考文献:

- [1] MILLER D, ASHOUR R, SULLENDER C, et al. Continuous blood flow visualization with laser speckle contrast imaging during neurovascular surgery [J]. *Neurophotonics*, 2022, 9(2): 021908.
- [2] KONOVALOV A, GADZHIAGAEV V, GREBENEV F, et al. Laser speckle contrast imaging in neurosurgery: A systematic review[J]. *World Neurosurgery*, 2023(171): 35-40.
- [3] YORDANOV S, DRUCKER M, BUTT H J, et al. Real-time monitoring of biomechanical activity in aphids by laser speckle contrast imaging[J]. *Optics Express*, 2021, 29(18): 28461-28480.
- [4] KUMAR N, NIRALA A K. A novel computational method for dynamic laser speckle and its application to analyze water activity during photosynthesis in papaya leaf[J]. *Optik*, 2023(274): 170518.
- [5] SCHOTT C, BLEY T, WALTER T, et al. Monitoring the apical growth characteristics of hairy roots using non-invasive laser speckle contrast imaging [J]. *Engineering in Life Sciences*, 2022, 22(3-4): 288-298.
- [6] HU W, XIONG C, FU Y, et al. Direct strain measurement method based on the correlation of defocused laser speckle pattern [J]. *Optics and Lasers in Engineering*, 2024(176): 108051.
- [7] 陈梁友, 闫浩. 基于数字全息和数字图像相关方法的面内位移测量[J]. *光子学报*, 2022, 51(4): 124-133.  
CHEN L Y, YAN H. In-plane displacement measurement based on digital holography and digital image correlation [J]. *Acta Photonica Sinica*, 2022, 51(4): 124-133.
- [8] TRIVEDI V, MAHAJAN S, JOGLEKAR M, et al. Optomechanical magnetometer based on laser speckle correlation [J]. *Measurement*, 2022(189): 110490.
- [9] ETCHEPAREBORDA P, MOULET M H, MELON M. Random laser speckle pattern projection for non-contact vibration measurements using a single high-speed camera

- [J]. *Mechanical Systems and Signal Processing*, 2021 (158): 107719.
- [10] 郜魏柯, 杜小平, 王阳, 等. 微粗糙表面参数对激光散斑场的影响规律分析[J]. *光学学报*, 2021, 41(11): 43-53.  
GAO W K, DU X P, WANG Y, et al. Analysis of influences of micro-rough surface parameters on laser speckle Field[J]. *Acta optica sinica*, 2021, 41(11): 43-53.
- [11] van WELZEN J, YUAN F G, FONG R Y. Hidden damage visualization using laser speckle photometry[J]. *NDT & E International*, 2022(131): 102700.
- [12] LU Y, HU M, ZHAI G, et al. LSNet: Identification of copper and stainless steel using laser speckle imaging in dismal surroundings[J]. *International Journal of Robotics and Automation*, 2021, 36(4): 1-8.
- [13] 李鹤群, 郑予菲, 杨涵夕, 等. 基于激光散斑成像的煤矸特征提取与识别方法研究[J]. *光学学报*, 2024, 44(21): 1-20.  
LI H Q, ZHENG Y F, YANG H X, et al. Research on feature extraction and recognition method of coal and gangue based on laser speckle imaging[J]. *Acta Optica sinica*, 2024, 44(21): 1-20.
- [14] SILVA J L, BORDALO R, PISSARRA J, et al. Computer vision-based wood identification: A review[J]. *Forests*, 2022, 13(12): 2041.
- [15] HAFEMANN L G, OLIVEIRA L S, CAVALIN P. Forest species recognition using deep convolutional neural networks[C]//2014 22nd International Conference on Pattern Recognition. Piscataway, N.J, USA: IEEE, 2014: 1103-1107.
- [16] HWANG S W, SUGIYAMA J. Computer vision-based wood identification and its expansion and contribution potentials in wood science: A review[J]. *Plant Methods*, 2021, 17(1): 47.
- [17] HE X, PELT D M, GAO J, et al. Machine learning-based wood anatomy identification: Towards anatomical feature recognition[J]. *Iawa Journal*, 2024, 45(4): 457-475.
- [18] 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.
- [19] FABIJAŃSKA A, DANEK M, BARNIAK J. Wood species automatic identification from wood core images with a residual convolutional neural network[J]. *Computers and Electronics in Agriculture*, 2021(181): 105941.
- [20] YONGKE S, QIZHAO L, XIN H, et al. Wood species recognition with small data: A deep learning approach [J]. *International Journal of Computational Intelligence Systems*, 2021, 14(1): 1451-1460.
- [21] ERGUN H. Wood identification based on macroscopic images using deep and transfer learning approaches [J]. *PeerJ*, 2024(12): 17021.
- [22] NIERADZIK L, SIEBURG-ROCKEL J, HELMLING S, et al. Automating wood species detection and classification in microscopic images of fibrous materials with deep learning[J]. *Microscopy and Microanalysis*, 2024, 30(3): 508-520.
- [23] PAN X, YU Z AND YANG Z. A deep learning multimodal fusion framework for wood species identification using near-infrared spectroscopy GADF and RGB image [J]. 2023, 77(11-12): 816-827.
- [24] 李振宇, 赵鹏, 王承琨. 改进模糊推理分类器进行木材树种近红外光谱开集分类识别研究[J]. *光谱学与光谱分析*, 2024, 44(7): 1868-1876.  
LI Z Y, ZHAO P, WANG C K. Tree class recognition in open set based on an improved fuzzy reasoning classifier [J]. *Spectroscopy and Spectral Analysis*, 2024, 44(7): 1868-1876.
- [25] CHENG-KUN W, PENG Z. Wood species recognition using hyper-spectral images not sensitive to illumination variation[J]. *Journal of Infrared and Millimeter Waves*, 2020, 39(1): 72-85.
- [26] SHUGAR A N, DRAKE B L, KELLEY G. Rapid identification of wood species using XRF and neural network machine learning[J]. *Scientific Reports*, 2021, 11(1): 17533.
- [27] 杨楠楠, 白岩, 姜苏译, 等. 基于 AlexNet 优化的板材材种识别方法[J]. *林业科学*, 2022, 58(3): 149-158.  
YANG N N, BAI Y, JIANG S Z, et al. Recognition method of plate and wood based on ALexNet optimaization [J]. *Scientia Silvae Sinicae*, 2022, 58(3): 149-158.
- [28] FIGUEROA-MATA G, MATA-MONTERO E, VALVERDE-OTÁROLA J C, et al. Using deep learning to identify costarican native tree species from wood cut images [J]. *Frontiers in Plant Science*, 2022(13): 789227.
- [29] 苗宇杰, 祝诗平, 普京, 等. 基于卷积神经网络的家具木材图像种类识别[J]. *林业科学*, 2023, 59(8): 133-140.  
MIAO Y J, ZHU S P, PU J, et al. Recognition of furniture wood image species based on convolutional neural networks[J]. *Scientia Silvae Sinicae*, 2023, 59(8): 133-140.
- [30] 宿恒硕, 吕军, 丁志平, 等. 基于改进残差神经网络的木材识别算法[J]. *林业科学*, 2021, 57(12): 147-154.  
SU H S, LU J, DING Z P, et al. Wood identification al-

- gorithm based on improved residual neural network [J]. *Scientia Silvae Sinicae*, 2021, 57(12): 147-154.
- [31] KIRBA İ, ÇİFCİ A. An effective and fast solution for classification of wood species: A deep transfer learning approach [J]. *Ecological Informatics*, 2022 (69): 101633.
- [32] 戴天虹, 翟冰. 基于改进 EfficientNet 的木材识别研究 [J]. *森林工程*, 2023, 39(4): 93-100.
- DAI T H, ZHAI B. Wood recognition research based on improved efficientNet [J]. *Forest Engineering*, 2023, 39 (4): 93-100.
- [33] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, N.J, USA: IEEE, 2016: 770-778
- [34] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [C]//15th European Conference on Computer Vision (ECCV). Chan, Switzerland: Springer, 2018: 3-17.

#### 作者简介:

杜艳秋,副教授,硕士生导师,博士后,国家公派访问学者,主要研究方向为人工智能模式识别、微腔激光有源器件及传感、中红外晶体激光器技术等。E-mail:hellen\_q@126.com。

李鑫,硕士,主要研究方向为人工智能模式识别。E-mail:1124202456@qq.com。

康辉,讲师,主要研究方向为人工智能模式识别、时频分析、图像处理。E-mail:qihang1601@sina.com。

孙辉,讲师,主要研究方向为人工智能模式识别、图像处理。E-mail:15385444@qq.com。

(编辑:刘勇)