

基于深度学习的试验检测图像智能识别算法优化研究

陈嘉豪

重庆路航工程检测有限公司，重庆 400000

摘要：随着深度学习技术的发展，图像识别在试验检测中的应用日益广泛，但仍面临识别精度不高、模型过重与数据不足等多重挑战。本文基于工程检测图像的实际需求，提出一套融合轻量主干网络、注意力机制与多尺度特征结构的识别算法优化方法。通过构建高质量数据集，采用迁移学习与数据增强技术，优化了模型在低质图像、复杂背景与小目标检测场景中的识别能力。对比实验证明，该方法在准确率、检测速度与资源占用方面均优于传统模型，具有良好的工程适配性。研究为试验检测图像识别的智能化提供了有效技术路径，也为工业检测系统的智能升级提供支持。

关键词：深度学习；图像识别；试验检测；轻量化模型；多尺度特征；注意力机制

DOI: 10.63887/ssrp.2025.1.5.8

引言

在现代工程试验检测中，图像识别作为一种高效、非接触式的检测方式，广泛应用于裂纹检测、设备状态监测、材料分析等领域。传统方法依赖人工经验与图像处理算法，如边缘检测、阈值分割等，效率低、受环境影响大。近年来，深度学习技术——特别是卷积神经网络（CNN）在图像分类、物体检测方面取得显著成果，为试验检测提供了新路径。然而，试验检测图像具有噪声大、背景复杂、特征细粒度高等特点，通用模型往往在速度或准确率上难以同时兼顾，还面临数据标签稀缺与硬件部署限制等问题。

本文从以下两个维度展开研究：一是算法架构与特征学习方式的优化，包括多尺度特征融合、轻量化设计以及注意力机制嵌入；二是试验环境下数据构建与增强策略，以提升模型对细小缺陷或异常行为的识别能力。通过构建特定设备的图像数据集，整合知网前期研究成果，采用实验对比方式验证优化思路的有效性。整篇文章分为四个部分：首章分析图像识别算法的现状与优化需求；次章设计优化模型架构；三章探讨样本构建及训练方法；末章进行性能评估与工程适配性分析^[1]。

1 图像识别算法优化的现实需求与研究方向

1.1 深度学习在试验检测图像识别中的挑战

第一段：试验检测图像通常包含复杂背景，如仪器表面反光、光照差异与视角变化，且重要信息常以裂纹、变形、污渍等形式呈现，尺寸小、分布不集中。现有深度学习模型如 ResNet、VGG 在通用图像集（如 ImageNet）表现良好，但迁移至试验检测图像时，容易出现误识别、漏检或识别时间过长等问题，不满足工程现场快速响应需求。特别是在工业环境中，算法需实时运行于嵌入式设备或边缘计算平台上，对模型轻量化和推理速度提出更高要求。

第二段：知网多篇研究指出，传统机器视觉方法结合深度学习模型用于裂纹检测，虽可提升准确率，但常耗费巨量计算资源，部署难度大。如某研究在桥梁裂缝识别中将 Fast R-CNN 迁移至 TensorRT 平台后，识别速度快但需额外硬件支持，工程成本上升。可见，高精度、低延迟、低资源消耗三者间存在明显冲突。因而研究中亟需设计精度与效率兼顾且具实用性的模型结构，并对训练策略做针对性改进，使其适配试验检测场景^[2]。

1.2 算法优化方向与研究思路

第一段：为应对上述问题，本文将算法优化聚焦于三方面：一是构建轻量级主干网络，如 MobileNetV3、ShuffleNetV2，通过深度可分离卷积和通道 Shuff

le 机制减少模型参数；二是在网络顶部嵌入注意力机制（如 SE、CBAM），增强对裂缝等目标特征的响应能力，并采用多尺度特征融合模块（如 FPN、ASPP），提升模型对微小目标的表现；三是通过知识蒸馏提升轻量模型准确性，通过设计 Teacher - Student 结构，将大模型的表达能力传递给轻量模型。

第二段：此外，针对试验检测图像的样本特点，需结合数据增强策略提升模型鲁棒性。如采用随机裁剪、亮度与对比度调节、色相扰动、边缘模糊以及结构光扭曲等方式丰富训练样本。同时引入切片采样机制，将高分辨率图像分为多块进行处理，既保留细节又能统一输入尺寸，兼顾小目标和整图识别效果。最终将上述优化模块在实验平台进行整合测试，以评估在目标试验场景下模型的实用性。

2 优化模型架构的设计策略与实现方式

2.1 主干网络结构的轻量化与可移植性

深度神经网络在图像识别中的性能受限于模型结构本身的复杂性与深度，而试验检测常要求部署于资源受限的嵌入式设备上，如工业检测机器人、便携式终端等。因此，模型轻量化是实现工程实用性的关键。当前主流轻量级架构如 MobileNet 系列、ShuffleNetV2 和 EfficientNet 等已在移动端图像识别任务中表现出良好性能。MobileNetV3 通过结合 h-swish 激活函数与 SE 注意力模块，在保证识别准确率的同时极大压缩了模型参数与计算量；ShuffleNetV2 则通过通道拆分与信息混洗策略提高并行计算效率，非常适用于边缘计算场景。

在试验检测应用中，轻量网络需要进一步适配于高分辨率图像与多目标特征识别任务，因此不能仅追求小模型体积，而忽视模型表达能力。为此，本文在 ShuffleNetV2 基础上改造网络输入尺度与通道宽度，保留高层语义表达能力的同时，采用深度可分离卷积取代普通卷积，在保持模型泛化能力的同时大幅减少计算量。此外，通过模块化设计方式，保留骨干网络核心结构，使其可灵活移植到不同试验平台或系统框架中，满足工业环境下对灵活部署与系统集成的需求。

2.2 多尺度特征融合与注意力机制整合

试验检测图像中的缺陷、裂纹或异常往往表现为细粒度、微尺度目标，因此在网络结构中增强多尺度感知能力十分关键。常规卷积神经网络通常通过层层下采样提取高级语义信息，易忽略空间细节。为此，本文引入特征金字塔结构（FPN）与空洞空间金字塔池化模块（ASPP），在不同尺度下融合图像特征，提升模型对小目标的识别能力。FPN 通过自顶向下路径将高层语义信息与底层细节信息进行融合，实现特征分辨率的恢复；ASPP 则使用不同扩张率的空洞卷积，提取多尺度上下文信息，增强模型对结构性缺陷的敏感性。

同时，为提升模型对关键区域的注意能力，本文在主干网络与输出端分别嵌入通道注意力机制（SE 模块）与空间注意力机制（CBAM 模块）。SE 模块通过对特征图通道加权抑制无关背景特征，CBAM 则进一步细化模型对空间中目标区域的响应程度。这种“全局+局部”注意力结合，有助于模型在检测混乱背景下仍能稳定聚焦目标特征。此外，注意力模块本身结构紧凑，几乎不增加计算负担，能够很好兼容轻量化网络架构，实现对试验图像的高效、精准识别^[3]。

3 数据集构建与模型训练策略的适应性优化

3.1 试验检测图像数据集构建原则与方法

在深度学习模型的训练过程中，数据质量直接决定模型性能上限。试验检测图像的采集受限于实际设备、检测环境及人工成本，导致数据数量有限、分布不均，存在样本小、缺陷类型不平衡等问题。尤其在工程检测中，某些异常状态极为罕见，难以获得大规模标注数据，因此构建具有代表性、通用性的图像数据集成为算法落地的首要前提。本文结合多个典型检测场景（如金属疲劳裂纹、设备运行异常、结构表面变形等）进行数据采集，涵盖不同工况、不同光照与背景条件，最大限度提高样本多样性与实际适配性。

在数据标注方面，采用人工辅助与智能工具联合标注方式进行分类与框选，确保数据精度。针对目标特征常呈现非规则形态的特点，标注工具支持多边形、自由曲线与区域描边等形式，以适应裂缝、边缘破损等非标准几何形态。在样本组织上，采用类别均衡、尺寸多样、分辨率统一的原则构建训练集、验证集与测试集，分别占比为 70%、15%和 15%，并确保每一类

典型缺陷在三类子集中都有足够代表性。同时，为适配模型对不同分辨率图像的输入需求，采用切图与缩放并举策略，既保留关键细节，又避免内存瓶颈^[4]。

3.2 针对性训练机制与增强策略的融合应用

由于试验检测图像中有效特征区域较小且易受干扰，模型在训练时极易陷入过拟合或忽略小目标的问题。为增强模型泛化能力，本文引入多种数据增强策略，包括随机旋转、亮度对比度调节、仿射变换、噪声叠加与镜像翻转等方法，显著增加样本变异性，提升模型在复杂工况下的适应力。此外，为提升模型对边缘细节的敏感性，采用边缘保留滤波、结构扰动等特定增强方式，强化网络对边缘响应能力，尤其适用于细裂纹与边角破损检测任务。

在训练过程中，模型采用迁移学习策略，优先加载在 ImageNet 或 COCO 等大规模数据集上预训练的权重，缩短收敛时间并提升初期表现。同时，为避免梯度震荡与过拟合，采用余弦退火学习率策略，结合 L2 正则化与 Dropout 机制，有效控制模型复杂度。为应对类别不均衡问题，采用 Focal Loss 替代传统交叉熵损失函数，通过增强对困难样本的关注，提升模型在少样本类别上的识别准确率。最后，通过交叉验证与滑动窗口重采样技术对模型训练过程进行动态调整，确保在整个训练周期中保持良好的稳定性与泛化性能。

4 算法优化效果评估与工程应用前景分析

4.1 模型性能评估与对比验证结果

为了全面评估优化后图像识别算法在试验检测场景中的适用性与性能表现，本文选取原始 MobileNetV2、改进后的轻量模型（加入 CBAM 与 FPN 结构）以及 ResNet50 作为对照组，分别在自建的试验检测数据集上进行了训练与测试。从结果来看，优化模型在不牺牲识别速度的前提下，整体准确率与精度均有明显提升。在识别裂纹与疲劳点等复杂目标时，优化模型 Top-1 准确率达到 92.7%，较基础 MobileNetV2 提升了 5.2%；平均推理时间从原有的 48ms 降低至 31ms，效率提升约 35%，具备较强的实用价值。

此外，在 F1 值、Recall、IoU（交并比）等指标上，优化模型也展现出较为均衡的表现，尤其在小目

标检测任务中具有显著优势。例如，在复杂背景下的表面裂纹识别中，优化模型可准确识别长度小于 10px 的目标，漏检率降低至 3.1%，显著优于 ResNet50 的 6.4%。通过在多轮交叉验证中引入动态采样机制，模型对低曝光、模糊边缘及局部遮挡情形的鲁棒性也得到增强。这些数据充分表明，经过结构轻量化、特征增强与多尺度融合处理的深度学习模型，既具备精度优势，又兼顾了现场实际运行对速度与稳定性的需求，真正具备落地条件^[5]。

4.2 工程适配性分析与未来发展建议

基于上述性能评估结果，优化模型在工业试验检测领域具有良好的工程适配性，尤其适用于设备实时检测、结构表面缺陷识别等高频任务。借助其轻量化特性，该模型可灵活部署在边缘计算终端、手持检测设备或嵌入式控制平台上，在确保识别效果的同时不依赖高性能 GPU，从而大幅降低系统成本，拓宽应用范围。此外，模型具备模块化特征，各子模块（如注意力机制、多尺度融合模块）可按需裁剪或重组，满足不同任务对精度、速度、功耗等方面的定制化要求。这种架构为实际工程中“按场景选算法”的部署思路提供了支撑。

面向未来，优化算法仍可在多个维度进一步提升。一方面，可借助自监督学习与少样本学习方法减少对大规模标注数据的依赖，提升模型适应新任务的能力；另一方面，可融合图神经网络（GNN）与 Transformer 结构，增强模型对图像区域之间的结构感知能力，实现从“局部识别”向“结构识别”升级。此外，建议在平台层引入 BIM、PLC 等工业信息接口，实现图像识别与设备运行状态联动，为数字化工厂或智能监测系统提供一体化信息支持。总之，随着深度学习技术与工程需求的持续对接，图像识别算法的优化不仅提升了试验检测效率与安全性，也推动了智能检测系统向更高阶段发展。

结论

本文围绕“基于深度学习的试验检测图像智能识别算法优化”这一主题，系统探讨了当前试验检测图像识别中存在的典型问题与技术瓶颈，提出了一套基

于轻量级主干网络、多尺度特征融合与注意力机制相结合的算法优化策略。通过搭建具有代表性的数据集、实施多样化的数据增强与迁移学习训练机制，并在多个指标上对比评估，验证了优化模型在准确率、效率、稳定性等方面的显著提升。研究表明，该方法在保证模型推理速度的同时，显著提升了识别精度，具备良好的工程落地性。

面向未来，深度学习在试验检测领域的应用还可进一步拓展，尤其是在少样本学习、自监督学习、图结构建模与跨模态融合等方面。结合新一代工业系统与边缘智能平台，图像识别算法将不再局限于辅助判断，而将成为系统自动运行与闭环控制的重要支撑。本研究的算法优化成果，为推动试验检测智能化、标准化提供了理论基础与实践参考。

参考文献

- [1] 杨宇豪, 郭永存, 李德永, 等. 基于视觉信息的煤矸识别分割定位方法[J/OL]. 浙江大学学报(工学版), 1-13[2025-06-28].
- [2] 朱泽南, 程先辉, 石明明, 等. 近红外光谱无损鉴定水果方法[J]. 应用技术学报, 2025, 25(02): 177-184.
- [3] 胡江, 梁宇, 胡靖宇, 等. 双层衬砌输水隧洞运行安全保障技术研究进展[J/OL]. 水利水运工程学报, 1-17[2025-06-28].
- [4] 赵圣清, 卢仕. 基于树莓派 4B 和 YOLOv5 的自动分类垃圾桶设计[J]. 工业控制计算机, 2025, 38(06): 87-89+92.
- [5] 施伟森. 基于过程神经网络的足球定位球仿真训练策略研究[J]. 普洱学院学报, 2025, 41(03): 95-101.