

基于深度学习的图像分类算法改进与应用

白 凯

陕西国际商贸学院 陕西 咸阳 712046

摘要: 在复杂应用场景对图像识别精度与稳定性要求不断提高的背景下, 研究围绕深度学习图像分类算法在特征表达能力不足、训练收敛效率偏低及模型泛化性能受限等问题, 聚焦网络层级结构优化、训练流程改进与泛化增强策略的技术路径, 并结合工业视觉、医学影像和智能终端场景分析算法改进的应用效果, 形成具备工程可实施性的图像分类算法改进方案。

关键词: 深度学习; 图像分类; 算法改进; 训练策略; 工程应用

引言:

在工业检测、医学影像与智能终端等应用场景持续扩展的背景下, 图像分类任务对识别精度、稳定性与工程适配能力提出更高要求。现有深度学习分类模型在复杂样本分布与算力受限条件下仍暴露出特征表达冗余、训练效率受限及泛化能力不足等问题, 制约其实际部署效果。研究围绕上述技术瓶颈以深度学习图像分类算法为对象, 从网络层级结构、训练流程及泛化增强策略等关键环节展开改进设计, 并结合典型应用场景分析算法改进的适用性, 为后续方法构建与应用研究奠定技术基础。

一、图像分类算法现状与核心问题分析

主流深度学习图像分类模型多采用深层卷积或注意力堆叠获取高维语义表征, 但层间特征在相邻尺度上重复激活, 通道冗余与无效梯度叠加导致参数量增长而有效判别信息增幅有限, 轻量化改造后又易出现细粒度类别边界模糊^[1]。训练层面常见瓶颈集中在批归一化统计漂移、学习率窗口设置不当及难样本占比偏低, 表现为收敛震荡、最优点不稳定与长尾类别召回偏弱。泛化问题主要由域偏移、标注噪声与背景相关性引起, 模型对纹理捷径依赖增强, 在跨场景光照、尺度与遮挡变化下置信度失真。

二、图像分类算法的改进方法

(一) 网络层级设计对特征表达的优化

针对深度学习图像分类模型中层间特征冗余与尺度响应失衡问题, 网络层级设计需要从特征有效性而非单纯加深网络出发进行重构^[2]。主干结构在早期层保持较高空间分辨率, 以稳定边缘、纹理与局部结构响应, 中高层逐步引入语义抽象并控制下采样节奏, 避免关键判别区域在尺度压缩中被弱化。通道配置不采用全层统一扩展策略, 而是集中增强语义层通道表达密度, 使有限计算资源更多分配给对类别区分贡献较大的高层特征。跨层连接采用显式对齐机制, 保证不同尺度特征在融合前具备一致的空间语义基础, 减少简单叠加带来的信息竞争。

在多尺度特征融合阶段, 引入可学习加权机制以动态调节各尺度特征对分类判别的贡献, 其计算形式为

$$\hat{F} = \sum_{i=1}^n w_i F_i$$
$$w_i = \frac{e^{a_i}}{\sum_{j=1}^n e^{a_j}}$$

其中, F_i 表示第 i 个尺度特征, \hat{F} 为融合输出特征, w_i 为归一化融合权重, a_i 为对应尺度的可学习响应参数。该结构使模型在训练过程中自动调整不同尺度的激活强度, 高判别价值尺度在反向传播中获得更稳定的梯度累积, 低贡献尺度的噪声响应被持续抑制。

(二) 训练流程对模型收敛性能的改进

图像分类模型在训练阶段表现出的收敛震荡、最优点漂移和类别响应失衡, 往往源于参数更新节奏与样本梯度分布之间的不匹配。训练流程改进以稳定梯度传播路径为目标, 对学习率变化范围、参数约束强度和样本参与方式进行协同调校^[3]。学习率在初期维持可控上限以避免梯度爆发, 中后期步长变化与损失下降节律保持一致, 减少权重在相邻极值点间反复摆动。正则约束聚焦抑制无效参数扩张而非整体压缩, 使判别贡献较低的通道在更新过程中逐步弱化。样本利用侧引入类别感知的采样机制, 使边界样本在多个训练周期内持续参与梯度更新, 防止模型在早期对易分类样本形成过拟合响应。

学习率调度采用显式余弦函数对全程更新步长进行建

模，其形式为

$$lr_t = lr_{\min} + \frac{1}{2}(lr_{\max} - lr_{\min}) \left(1 + \cos\left(\pi \frac{t}{T}\right) \right)$$

其中， lr_t 为第 t 次参数更新时的学习率， lr_{\max} 为最大学习率， lr_{\min} 为最小学习率， T 为总更新步数。该调度使训练早期保持足够探索能力，避免局部最优的过早锁定，中后期学习率平滑下降，参数更新方向逐渐收敛于稳定区域，梯度方差随步长缩减同步降低。与分段衰减相比，该形式减少学习率突变引发的损失回弹，使验证集指标变化呈现连续趋势。

为约束参数规模并抑制后期震荡，在目标函数中加入权重衰减项，其表达为

$$L = L_{ce} + \lambda \|\theta\|_2^2$$

其中， L 为总损失， L_{ce} 为交叉熵损失， λ 为正则化系数， θ 为模型参数。该项在反向传播中对高幅值权重施加持续惩罚，使参数更新更倾向于平滑解空间，降低局部噪声梯度对模型决策边界的放大效应。

（三）泛化性能不足的针对性增强策略

泛化增强针对小样本、域偏移与噪声标注三类高频场景配置可执行策略：数据增强采用“弱增强保持语义、强增强扩展分布”的分层组合，增强算子固定在可追溯的策略池内并记录采样概率，避免增强分布随训练过程漂移；迁移学习把预训练模型作为特征初始化来源，微调阶段限制可更新层范围，先训练分类后再逐步解冻高语义层以降低灾难性遗忘；模型约束侧用一致性约束与权重约束抑制对背景捷径的依赖，输入扰动下的预测应保持恒定，样本区域的决策边界需在约束下平滑移动，训练监控中以校准误差和负对数似然衡量置信度质量，避免“准确率上升但置信度失真”的部署风险^[4]。

为量化不同泛化增强策略对分类性能与置信度稳定性的影响，下表1对各策略在测试集与跨域场景下的关键指标进行了对比统计。

表1 不同泛化增强策略下测试集分类性能对比

策略配置	测试集准确率	Macro-F1	NLL	ECE	跨域集准确率
基线 (无增强)	0.812	0.79	0.642	0.061	0.701
数据增强 (分层增强)	0.838	0.822	0.587	0.052	0.738
迁移学习 (冻结低层)	0.846	0.831	0.569	0.049	0.752
模型约束(一 致性约束)	0.841	0.826	0.574	0.046	0.747
组合策略(增强 +迁移+约束)	0.867	0.853	0.521	0.038	0.781

单一策略已能在测试集准确率与Macro-F1上带来稳定增益，且NLL与ECE下降说明置信度质量得到修正，跨域集准确率的提升幅度更能反映泛化增强的有效性；组合策略在各指标上形成一致改善，跨域集准确率由0.701提升至0.781，表明增强扩展输入分布、迁移提供稳健初始化、约束抑制捷径依赖三者具备互补关系，工程落地时可按资源边界选择“迁移+轻量增强”作为低成本方案，在域偏移强或小样本更突出的任务中再叠加一致性约束以稳定部署表现。

三、改进算法的应用实践

（一）工业视觉检测中的分类应用

工业视觉检测场景中，缺陷类别往往呈现形态差异小、尺度变化大且背景纹理复杂的特点，改进后的图像分类算法在工程应用中需围绕特征稳定性与判别边界清晰度展开配置^[5]。模型输入阶段对原始图像进行固定裁剪与尺度对齐，保证微小缺陷在特征图中占据足够响应区域；网络结构侧利用多尺度特征融合强化对划痕、孔洞和边缘破损等局部模式的感知能力，避免高层语义对低层细节的覆盖；训练阶段引入难样本重点参与机制，使模型在相似缺陷类别间形成更陡峭的判别边界，减少正常纹理被误判为缺陷的情况。

在产线部署条件下，分类算法需在保证识别准确性的同时满足节拍约束，改进模型在推理阶段对计算路径进行裁剪，使特征提取与分类头计算负载保持稳定。推理输出结合工艺允许误差设置固定判定阈值，对边界样本进行延迟确认而非即时剔除，降低误判对产线连续运行的干扰。该配置使分类结果在连续帧输入下保持一致性，避免单帧异常触发重复报警，为工业检测场景下的稳定运行提供技术支持。

为直观呈现不同模型方案在工业视觉检测场景下的分类稳定性与效率差异，下图1对关键性能指标的变化情况进行了对比展示。

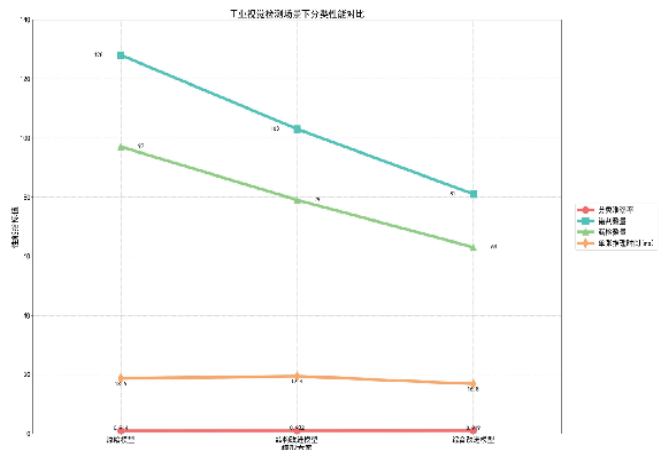


图1 工业视觉检测场景下分类性能对比

综合改进模型在分类准确率提升的同时，错判数量与漏检数量同步下降，说明特征表达对缺陷边界的区分能力得到增强；单张推理时间缩短至16.8，使模型在不增加硬件资源的前提下适配更高检测节拍，兼顾识别稳定性与实

实时性要求，满足工业视觉检测对连续运行和低误触发率的工程约束。

(二) 医学影像自动分类实践

医学影像分类的核心约束集中在数据异质性与错误代价不对称：不同设备、不同成像协议导致灰度分布与噪声形态差异明显，病灶区域占比小且形态多变使模型易被背景组织牵引，误判往往对应不必要复查或漏诊风险。改进算法在该场景的应用侧重点放在一致性与误判控制：输入端执行强制标准化流程，包含强度归一化与空间尺度对齐，训练端把样本按设备来源分组以构造域扰动，模型端在多尺度特征上强化对局部病灶纹理的响应，并把输出置信度作为二级规则的输入，低置信度样本进入复核队列而非直接给出确定结论，形成可落地的“模型输出—规则分流—复核闭环”。

为降低误判并提升病灶分类一致性，可在损失函数中引入对难样本更敏感的形式，抑制易分类样本对梯度的主导，其表达为：

$$L = -\alpha(1-p)^{\gamma} \log(p)$$

其中， L 为损失， P 为真实类别的预测概率， α 为类别权重， γ 为聚焦系数。该损失在训练中提高对低置信度样本的优化强度，减少模型把边界样本压向错误类别的倾向，配合来源分组的训练输入可缓解设备差异引发的一致性下降，并在高风险类别上用 α 校正类别不平衡对误判率的放大效应。

(三) 智能终端场景下的分类部署

智能终端部署的主要矛盾在于算力、内存与时延预算有限，且输入图像受运动模糊、光照变化与压缩噪声影响更强，改进算法落地需要把模型结构与推理链路按端侧资源重新裁剪：主干网络选择可分离卷积或轻量注意力替代高代价算子，输入分辨率随场景动态调整，静态场景使用较高分辨

率提升细节判别，快速运动场景降低分辨率换取时延稳定；推理侧采用算子融合与批归并策略减少内存读写开销，量化部署前以校准集覆盖端侧常见光照与噪声分布，避免量化后置置信度漂移引发阈值失配，端侧输出保留Top-k与置信度供上层业务做降级与重试决策。

轻量化常用手段是通道剪枝，把每层通道按重要性压缩并保持输出维度一致，剪枝形式可写为：

$$y = W(m \odot x)$$

其中， Y 为层输出， W 为权重矩阵， x 为输入特征， m 为通道掩码， \odot 为逐元素乘法。该表达把通道选择显式化，掩码为0的通道在推理中不再参与计算，可直接降低乘加次数与内存访问量；在部署阶段将 m 固化并重整 W 的有效通道，可在不改变整体接口的前提下获得更低时延与更小模型体积，配合端侧量化与算子融合可进一步稳定帧率与功耗，实现改进算法在智能终端场景下的工程化落地。

四、结论

研究围绕深度学习图像分类算法在复杂场景中的工程应用需求，针对特征冗余、收敛不稳、泛化受限及部署受约束等问题，构建了以网络层级优化、训练流程调校和泛化增强为核心的改进路径，并在工业视觉、医学影像和智能终端场景下验证其适配效果。研究表明，多尺度加权融合可提升细粒度特征表达质量，合理的学习率调度与正则约束有助于稳定收敛并抑制过拟合，增强策略与迁移初始化协同作用可改善跨域一致性与置信度可靠性，轻量化与剪枝配置能够在资源边界内维持实时推理性能。相关改进形成了可复用的技术组合，为多场景图像分类提供了工程化实施范式，面向更高复杂度环境，算法结构与训练机制的协同优化仍具有拓展空间。

参考文献：

[1]周仕捷.基于深度学习的字典学习算法研究及其在少样本图像分类中的应用[D].兰州大学,2025.
[2]王帅.基于深度学习的细粒度图像分类算法研究及嵌入式应用[D].齐鲁工业大学,2024.

[3]李馨.深度学习算法在天体目标图像分类中的应用研究[D].辽宁科技大学,2023.
[4]孙中元.基于深度学习的图像分类算法在垃圾分类中的应用[D].北京邮电大学,2021.
[5]王振力,滕藤,王群,等.遥感影像K-最近邻图目标分类改进算法的研究[J].地理空间信息,2021,19(02):33-35+6.

作者简介：白凯（2002-）男，汉族，陕西榆林，在读本科，研究方向：图像分类。