

小样本条件下混凝土桥面裂缝图像分类方法比较

唐胜文 黄达燕

广西民族大学智能建造学院 广西壮族自治区南宁市 530007

DOI:10.32629/ems.v8i6.20532

[摘要] 针对小样本条件下混凝土桥面裂缝图像分类问题, 本文以 SDNET2018 数据集中的桥面图像为研究对象, 构建裂缝与无裂缝二分类任务, 对 HOG+SVM、LBP+SVM、基础 CNN、MobileNetV2 和 ResNet18 五种模型进行了实验比较, 并分析了不同参数设置对模型性能的影响。结果表明, 传统机器学习方法中 HOG+SVM 优于 LBP+SVM; 深度学习方法整体优于传统方法, 其中迁移学习模型表现较好。在本文实验条件下, ResNet18 取得最高测试准确率 97.5%, 裂缝类别 F1 值为 0.9751; MobileNetV2 的测试准确率达到 97.0%, 表现出较好的轻量化应用潜力。实验结果表明, 迁移学习方法在小样本混凝土桥面裂缝图像分类任务中表现较好, 合理的参数设置有助于提升模型性能。

[关键词] 混凝土桥面; 裂缝; 支持向量机; 卷积神经网络

1 绪论

混凝土结构在长期荷载、环境侵蚀和材料老化等因素作用下, 表面容易产生裂缝。裂缝不仅影响结构外观, 还可能降低结构耐久性和安全性, 因此对混凝土裂缝进行及时、准确识别具有重要意义。传统裂缝检测主要依赖人工巡检, 然而, 随着图像处理、机器学习和深度学习技术的发展, 基于图像的自动裂缝识别方法逐渐成为研究热点^[1,2]。

现有裂缝识别方法主要包括传统机器学习和深度学习两类。传统方法通常依赖 HOG、LBP 等人工特征, 结合 SVM 等分类器进行识别, 优点是实现简单、对小样本较友好, 但特征表达能力有限。深度学习方法能够自动提取图像特征, 尤其是迁移学习模型, 在小样本任务中通常具有更好的识别效果^[3]。



图1 混凝土桥面无裂缝、裂缝图像示例

桥面混凝土裂缝图像具有背景复杂、纹理干扰明显、样本数量有限等特点, 分类难度较高。基于此, 本文选取 SDNET2018 数据集中的桥面图像, 构建裂缝与无裂缝二分类任务, 对 HOG+SVM、LBP+SVM、基础 CNN、MobileNetV2 和

ResNet18 五种模型进行对比实验, 分析不同方法及参数设置对分类性能的影响, 以探讨其在小样本桥面裂缝识别中的适用性。

2 数据与方法

本文采用 SDNET2018 数据集中的桥面混凝土图像构建二分类数据集, 训练集和测试集均保持裂缝类与无裂缝类样本数量平衡。训练集包含裂缝图像 500 张、无裂缝图像 500 张, 测试集各 100 张, 以保证实验对比的公平性。

方法上, 本文分为传统机器学习和深度学习两类。传统方法选取 HOG+SVM 和 LBP+SVM, 其中 HOG 用于提取边缘和方向信息, 适合描述裂缝的线状结构; LBP 用于提取局部纹理特征, 能够反映裂缝周围灰度变化。深度学习部分选取基础 CNN、MobileNetV2 和 ResNet18, 其中基础 CNN 用于分析从零训练的效果, MobileNetV2 和 ResNet18 采用迁移学习策略, 用于比较轻量化模型与残差网络在小样本条件下的性能差异。

3 实验设置

本文采用统一实验框架对五种模型进行比较。传统机器学习模型主要调整特征提取参数与 SVM 参数; HOG+SVM 重点搜索图像尺寸、方向数、单元大小、块大小及核函数和惩罚系数; LBP+SVM 主要调整图像尺寸、半径、采样点数、编码方式及 SVM 参数。

深度学习模型主要考察学习率、批大小、冻结策略和数

据增强方式。学习率设置为 0.001、0.0001 和 0.00001，批大小设置为 8、16 和 32，冻结策略分为冻结骨干网络与不冻结骨干网络，数据增强分为基础增强与强增强。CNN、MobileNetV2 和 ResNet18 采用相同的参数组合进行搜索，以保证可比性。

模型评价采用准确率、精确率、召回率和 F1 值。本文重点关注裂缝类别的召回率和 F1 值，因为在裂缝检测任务中，漏检裂缝比误判更需要避免。^[4]

4 结果与分析

本文对 HOG+SVM、LBP+SVM、基础 CNN、MobileNetV2 和

表 1 传统机器学习模型最优结果表

模型	图像尺寸	特征/参数设置	裂缝类准确率	裂缝类精确率	裂缝类召回率	裂缝类 F1 值
HOG+SVM	128	ori=9, ppc=8, cpb=3, rbf, C=10	0.825	0.804	0.860	0.831
LBP+SVM	128	R=3, P=16, uniform, rbf, C=10	0.810	0.804	0.820	0.812




图 2 HOG+SVM 与 LBP+SVM 最优模型混淆矩阵

造成这一差异的主要原因在于两类特征的表达方式不同。HOG 特征通过描述梯度方向分布，能够较好地刻画裂缝的边缘和线状结构；而 LBP 更侧重局部纹理信息，在桥面复杂背景下容易受到干扰，从而影响分类效果。

从参数结果来看，两种模型均表现出一定规律：RBF 核函数整体优于线性核函数，说明裂缝图像特征具有非线性分布特性；同时，适中的特征尺度参数（如 HOG 单元大小、LBP 半径等）更有利于提升模型性能。总体而言，传统机器学习方法实现简单、训练成本较低，在小样本条件下具有一定稳定性，但受限于人工特征表达能力，其分类性能仍有提升空间。

4.2 深度学习模型分析

相比传统方法，深度学习模型在裂缝识别任务中表现出更强的特征学习能力。基础 CNN 在最优参数配置下测试准确率达到 91.0%，裂缝类别 F1 值为 0.908，较传统模型有明

表 2 深度学习模型最优结果表

ResNet18 五种模型进行了实验比较，并在最优参数配置下对其性能进行分析。

4.1 传统机器学习模型分析

通过参数搜索，HOG+SVM 与 LBP+SVM 均能够实现桥面裂缝图像的有效分类。其中，HOG+SVM 的最优测试准确率为 82.5%，裂缝类别精确率为 0.8037，召回率为 0.860，F1 值为 0.831；LBP+SVM 的测试准确率为 81.0%，F1 值为 0.812。总体来看，HOG+SVM 在各项指标上均略优于 LBP+SVM。

显提升。这表明卷积神经网络能够从原始图像中自动提取有效特征，提升分类性能。但由于训练样本规模有限，从零训练的 CNN 在特征表达和泛化能力方面仍存在一定不足。

基于迁移学习的 MobileNetV2 和 ResNet18 表现更为优异。其中，MobileNetV2 的测试准确率为 97.0%，F1 值为 0.970；ResNet18 达到最高测试准确率 97.5%，F1 值为 0.975。两种模型均显著优于基础 CNN，说明预训练模型能够有效缓解小样本带来的训练不足问题，提高模型对裂缝特征的识别能力。

从模型结构来看，ResNet18 通过残差连接增强了深层特征表达能力，因此在复杂背景下具有更好的判别能力；而 MobileNetV2 作为轻量化模型，在保证较高精度的同时，计算复杂度更低，具有较好的工程应用潜力。

参数实验结果表明，各深度学习模型在参数变化下呈现出较为一致的规律：不冻结骨干网络通常优于冻结策略，说明完整微调有助于模型更好适应目标任务；批大小为 8 或 16 时性能较优，而较大批量（32）可能降低泛化能力；学习率以 0.001 或 0.0001 表现较好，过小学习率会导致收敛缓慢甚至欠拟合。此外，数据增强能够在一定程度上提升模型鲁棒性，但过强增强可能破坏裂缝细节信息，需要合理控制。

模型	学习率	批大小	冻结策略	数据增强	裂缝类准确率	裂缝类精确率	裂缝类召回率	裂缝类 F1 值
CNN	0.001	8	不冻结	basic	0.910	0.927	0.890	0.908
MobileNetV2	0.0001	16	不冻结	strong	0.970	0.961	0.980	0.970
ResNet18	0.001	16	不冻结	strong	0.975	0.970	0.980	0.975




图 3 三种深度学习模型最优混淆矩阵对比图

4.3 模型综合对比分析

比较五种模型的最优结果如图 4，可以得到性能排序为：ResNet18 > MobileNetV2 > CNN > HOG+SVM > LBP+SVM。整体来看，深度学习方法显著优于传统机器学习方法，而迁移学习模型在小样本条件下表现最佳。




图 4 五种模型综合性能对比图

具体而言，传统方法虽能实现基本分类，但在复杂背景下识别能力有限；基础 CNN 通过端到端学习显著提升性能，但仍受限于样本规模；迁移学习模型则通过引入预训练特征，有效提升了模型的泛化能力和分类精度。其中，ResNet18 更适用于对精度要求较高的场景，而 MobileNetV2 在兼顾精度与计算效率方面具有优势，更适合实际工程部署。

实验结果表明，在小样本混凝土桥面裂缝图像分类任务中，合理选择模型结构并结合迁移学习策略，能够显著提升识别性能。

5 结论

本文以 SDNET2018 数据集集中的桥面混凝土裂缝图像为研究对象，针对小样本条件下的裂缝图像分类问题，构建了 HOG+SVM、LBP+SVM、基础 CNN、MobileNetV2 和

ResNet18 五种模型的对比实验，并分析了不同参数设置对模型性能的影响。

实验结果表明，传统机器学习方法能够实现裂缝图像的基本分类，其中 HOG+SVM 整体性能优于 LBP+SVM。基础 CNN 的性能明显高于传统方法，说明卷积神经网络在裂缝特征提取方面具有优势。相比之下，基于迁移学习的模型表现更优，其中 ResNet18 取得最高测试准确率 97.5%，MobileNetV2 达到 97.0%，表明预训练模型在小样本条件下具有更强的特征表达能力和泛化能力。参数分析结果表明，不冻结骨干网络通常优于冻结策略，学习率 0.001 或 0.0001 整体优于 0.00001，适当的数据增强有助于提升模型稳定性与泛化性能。

综上，在小样本混凝土桥面裂缝图像分类任务中，迁移学习方法具有更好的适用性。其中，ResNet18 更适用于精度优先场景，MobileNetV2 在保证较高精度的同时具备轻量化优势，更适合工程应用。

[参考文献]

[1]史宏宇,杨晨,李亚非,等. 基于轻量化深度学习的沥青路面裂缝智能识别[J]. 市政技术, 2025, 43 (09) :81-91.

[2]宋云飞,梁泽楠,李金浩,等. 基于计算机视觉的皮革瑕疵自动检测与分级系统优化研究[J]. 西部皮革, 2025, 47 (2 1) :17-19.

[3]邢贺冰. 机器人作业路径补偿及运动位姿光顺方法[D]. 大连理工大学, 2025.

[4]牛顿,林宁,林振超,等. 多特征融合的焊缝图像多标签分类算法[J]. 华侨大学学报(自然科学版), 2024, 45 (04) :5 14-523.

[5]闫振,吴炜,杨晓英,等. 基于事件递归卷积网络的沥青路面宏观纹理重建[J]. 长沙理工大学学报(自然科学版), 2026, 23 (01) :118-129.

作者简介：唐胜文（1996-5），男，苗族，广西桂林人，硕士，研究方向：工程结构检测监测。