

基于卷积神经网络的桥梁病害识别与裂缝特征测量方法

Bridge Damages Identification and Measurement Method of Crack Features based on Convolutional Neural Network

冯志慧¹，曹文凯¹，薛鹏涛²，梁志强³

(1. 河南农业大学 信息与管理科学学院, 郑州 450002; 2. 河南省交通事业发展中心, 郑州 450016;
3. 长安大学 公路学院, 西安 710064)

摘要: 为改进桥梁病害识别效率和质量, 提出一种基于贝叶斯优化和卷积神经网络的深度学习算法, 进行桥梁麻面、裂缝、露筋和剥落等4种桥梁病害识别; 针对裂缝病害, 建立以 Mobilenet - v2 特征提取网络的 DeepLabv3+ 作为裂缝图像语义分割模型。结果表明: 基于贝叶斯优化和卷积神经网络的深度学习算法对4种桥梁病害识别精度及鲁棒性基本保持不变, 训练时间减少了约80%; 通过裂缝图像语义分割模型和图像处理技术实现裂缝的精准分割和几何信息的自动提取计算, 分割裂缝 MIoU 达到0.95。桥梁病害的高效和精准识别, 为桥梁性能预测分析提供了更加准确的数据参考。

关键词: 深度学习; 病害识别; 裂缝特征; 卷积神经网络; 贝叶斯优化; 语义分割

中图分类号: TP391 **文献标志码:** A **文章编号:** 1005-8249 (2025) 06-0140-10

DOI: 10.19860/j.cnki.issn1005-8249.2025.06.024

FENG Zhihui¹, CAO Wenkai¹, XUE Pengtao², LIANG Zhiqiang³

(1. Henan Agricultural University College of Information and Management Science, Zhengzhou 450002, China;
2. Transportation Development Center of Henan Province, Zhengzhou 450016, China;
3. Chang'an University Highway College, Xi'an 710064, China)

Abstract: To improve the efficiency and accuracy of bridge defect identification, a deep learning algorithm based on bayesian optimization and convolutional neural networks is proposed for identification of four types of bridge defects: pockmarked surface, cracks, exposed rebar, and spalling. For cracks, DeepLabv3+ with Mobilenet - v2 as the feature extraction network is established as the semantic segmentation model for crack images. The results show that the proposed method maintains nearly the same accuracy and robustness in identifying the four types of bridge defects, while reducing training time by approximately 80%. Through the semantic segmentation model and image processing techniques, precise segmentation of cracks and automatic extraction of geometric information are achieved, with an MIoU of 0.95 for crack segmentation. The efficient and accurate identification of bridge diseases provides more precise data references for bridge performance prediction and analysis.

Key words: deep learning; damage identification; crack features; convolutional neural network; Bayesian optimization; semantic segmentation

基金项目: 国家自然科学基金项目 (51878059), 河南省科技攻关项目 (252102240037)。

作者简介: 冯志慧 (1977—), 女, 博士, 副教授。研究方向: 机器学习。

通信作者: 薛鹏涛 (1978—), 男, 博士。研究方向: 桥梁工程。

收稿日期: 2023-04-07

0 引言

基于深度学习的病害识别方法已成为桥梁检测的新兴手段之一,特别是基于卷积神经网络(CNN)的图像处理技术,具有效率高、可达性广等优点。图像识别凭借其远距离、非接触的检测方式和高精度、高效率的识别效果,在桥梁外观检测领域得到广泛尝试^[1]。

近年来,基于图像处理技术的病害检测识别方法得到迅速发展。谢东阳等^[2]在AlexNet网络模型引入InceptionResNet模块替换Conv3和Conv4来提升模型的特征提取能力。杨超等^[3]提出了基于频率指标和深度学习理论的桥梁损伤识别方法,目的是提高桥梁损伤定位的有效性。Zhu等^[4]提出基于视觉特征的桥梁缺陷检测方法,并通过迁移学习和卷积神经网络实现了自动化图像分析与识别。车艳丽^[5]对AlexNet做出了改进,提出一种新的卷积神经网络架构,采用Caffe深度学习框架进行路面裂缝目标检测。马卫飞^[6]提出了一种基于CNN的DBCC分类模型,用于桥梁裂缝等病害的识别,并结合窗口滑动算法对桥梁裂缝检测,采用图像金字塔和ROI区域相结合的搜索策略对算法进行加速。高小小^[7]提出了使用简化的脉冲耦合神经网络(PCNN)进行裂缝检测。

目前,桥梁病害识别模型多针对单一病害进行设计,而在实际的桥梁检测过程中,桥梁构件常同时出现多种病害。传统基于经验的超参数设置方法已难以满足复杂场景下的训练需求^[8]。在深度学习训练中,图像分类模型引入批量归一化,在减少训练步骤的同时保持模型精度^[9],残差学习框架则能有效缓解深层网络的训练负担^[10]。裂缝作为桥梁检测中的重点病害,王莉静等^[11]提出了一种改进YOLOv5的沥青路面裂缝检测方法,该方法能够降低模型复杂度并加快推理速度,对网络局部特征捕获

和融合能力有所提升;陈军等^[12]采用反演可见光图像方法和光谱匹配方法,实现了装配式工程易变形结构裂缝红外微弱目标的识别;张建勋^[13]提出了构建基于特征图的裂缝检测方法;朱苏雅等^[14]提出了一种基于UNet卷积网络的像素级、小样本的裂缝检测方法,该方法能够准确完整地对桥梁裂缝进行提取,且宽度测量准确。为实现桥梁表观病害的智能识别和尺寸确定,有些学者提出了一系列的桥梁病害识别与量化方法^[15-18]。

综上可知,多数研究集中于病害(尤其是裂缝)的识别或分割,缺乏一个完整的能够同步处理多种病害和量化几何特征信息的集成框架。此外,现有方法在超参数优化上仍较多依赖人工经验。为克服上述局限,旨在构建一个能够同步识别多种病害的深度检测模型,提出一种基于贝叶斯优化的超参数自动设置方法,获取最优参数组合,确保模型在多病害联合训练中的鲁棒性。同时,针对裂缝病害需进一步获取位置、尺寸等几何信息的需求,在建立多病害检测模型的基础上,深度融合图像分割与处理技术,实现裂缝几何特征的自动提取与计算。

1 方法实现框架

桥梁表观病害自动检测与几何特征提取方法,主要包括DBDD的桥梁表观病害识别、DeepLabv3+的裂缝分割以及形态学的裂缝图像处理分析,方法框架的流程如图1所示。其中,基于DBDD的桥梁表观病害识别是通过建立贝叶斯优化的DBDD模型,实现麻面、裂缝、露筋和剥落等4种病害类型自动识别;基于DeepLabv3+的裂缝分割通过建立以Mobilenet-v2特征提取网络的DeepLabv3+裂缝图像语义分割模型,实现裂缝的精确分割;基于形态学的裂缝图像分析实现了裂缝的几何信息的自动提取及计算。

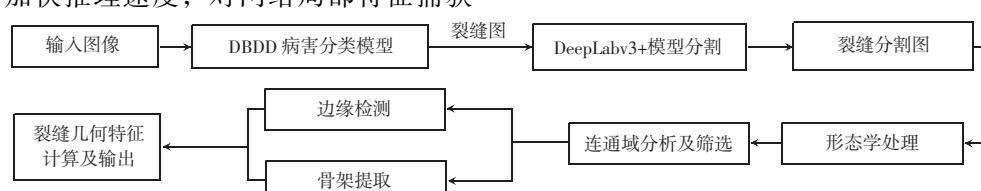


图1 方法实现框架
Fig. 1 Method implements the framework

研究与应用

2 DBDD 的桥梁表观病害识别

2.1 DBDD 模型构建

桥梁病害检测模型 (Deep Bridge Defect Detection, DBDD) 如图 2 所示, 模型的具体参数见表 1。该模型是在 Inception – v3 模型^[9]的基础上进行改进, 使用了 4 层卷积层 (C1 ~ C4)、4 层池化层 (P1 ~ P4) 和 2 层全连接层 (FC1 – FC2), 最后一层为输出层, 输出图像预测所属病害类型的概率。

为增加 DBDD 模型在多病害学习过程中的鲁棒性, 在卷积层后添加批量归一化层 (Batch Normalization, BN) 和 ReLU 层。同时, 在全连接层 FC1 层后添加 dropout 函数, 其参数设置为 0.5。

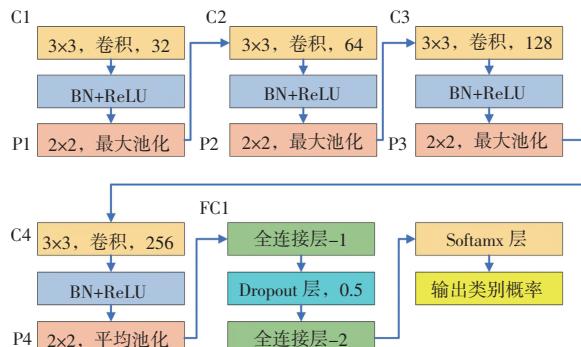


图 2 DBDD 模型网络结构图

Fig. 2 Schematic diagram of DBDD model network structure

表 1 DBDD 模型构建参数表

Table 1 DBDD model construction parameter table

层	各层尺寸			层	核尺寸及步长					
	高度	宽度	深度		高度	宽度	深度	个数	步长	
L1	224	224	3	C1	3	3	3	32	1	
L2	224	224	32	BN						
L3	224	224	32	Relu						
L4	224	224	32	P1 (max)	2	2			2	
L5	112	112	32	C2	3	3	32	64	1	
L6	112	112	64	BN						
L7	112	112	64	Relu						
L8	112	112	64	P2 (max)	2	2			2	
L9	56	56	64	C3	3	3	64	128	1	
L10	56	56	128	BN						
L11	56	56	128	Relu						
L12	56	56	128	P3 (max)	2	2			2	
L13	28	28	128	C4	2	2	128	256	1	
L14	28	28	256	BN						
L15	28	28	256	Relu						
L16	28	28	256	P4 (average)	2	2			2	
L17	14	14	256	FC1						
L18	1	1	128	Dropout						
L19	1	1	128	FC2						
L20	1	1	4	Softmax						
L21	1	1	4	classoutput						

BN 层是为保证训练过程中提高网络泛化能力, 加快网络收敛和训练速度而设置的归一化计算函数。经过该层归一化处理后, 上一层信息输入至下一层时均值为 0, 方差为 1, 这种操作极大改善训练的鲁棒性。ReLU 层相比于传统的 Sigmoid 函数, 其不存在梯度爆炸或梯度消失问题。随着卷积神经网络深度的增加, 设置 ReLU 层能明显保存神经元的非线性, 使得在多病害识别过程中不会因病害类型增多而降低模型的泛化能力, ReLU 函数的表达式为:

$$f(x) = \max(0, x) \quad (1)$$

Dropout 层是为提高模型泛化能力, 在训练过程中有意随机丢弃部分数据。主要原因是在训练过程中, 由于病害类型增加, 每类病害照片数量又不完全统一, 且部分病害具有相似特征, 这种现象将导致模型在训练过程中出现过拟合的现象, 进一步导致识别精度下降。将 Dropout 层设置参数为 0.2, 即随机丢弃 20% 信息。Dropout 层工作机制如图 3 所示。

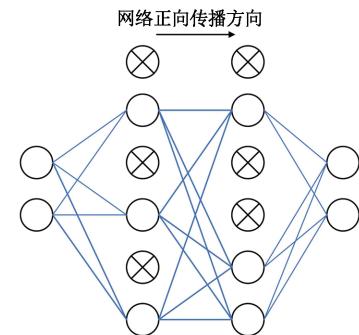


图 3 Dropout 层工作机制示意图

Fig. 3 Schematic diagram of the working mechanism of the Dropout layer

2.2 贝叶斯优化的模型训练

2.2.1 基于贝叶斯算法的超参数优化

传统的超参数优化并没有考虑到先验函数传递后验函数的信息, 即没有考虑上一次验证集的评估结果对超参数优化选择带来影响。针对这一问题, 提出基于贝叶斯优化的调参算法, 使得优化过程总是向设置的预期方向进行优化。贝叶斯计算超参数是基于给定的优化目标函数, 通过样本点来迭代更新目标函数的后验分布。当目标函数后验分布基本与目标函数真实分布贴合则迭代停止, 得到模型最优参数。贝叶斯优化超参数示意图如图 4 所示。

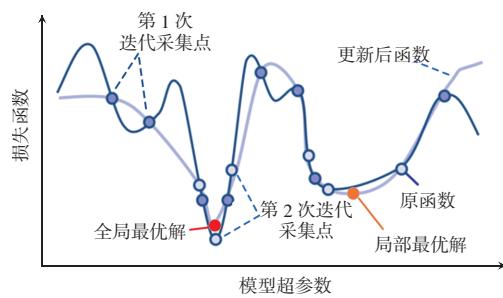


图 4 贝叶斯优化超参数示意图

Fig. 4 Bayesian optimization hyper-parameter diagram

2.2.2 优化超参数范围设置

使用训练数据和验证数据作为输入, 为贝叶斯优化器创建一个目标函数, 该目标函数设置为验证集的分类误差。经过多次迭代, 直至目标函数后验分布基本与目标函数真实分布贴合, 则迭代停止, 此时认为得到模型的最优参数。

构建的 DBDD 模型, 需要设置贝叶斯优化的超参数有:

(1) 网络卷积深度: 此参数控制网络的卷积层数量, 其域空间为 $[1, 3]$, 取值为整数。

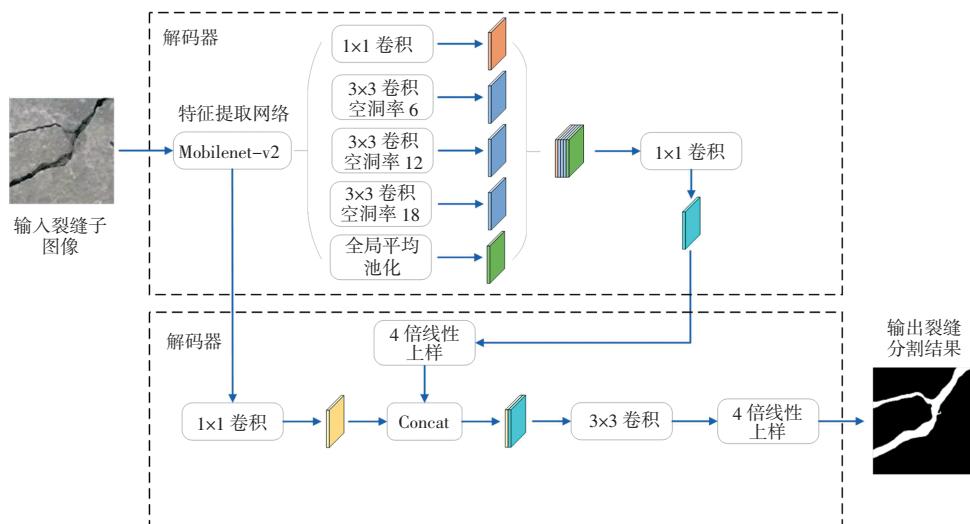


图 5 DeepLabv3+ 网络结构
Fig. 5 DeepLabv3+ network structure

4 算例验证

4.1 数据集制作和标定

4.1.1 数据集制作

为确保有足够的病害图像对模型进行训练, 采用滑动窗口算法对图像进行自动裁切, 这样不仅增

(2) 初始学习率: 此参数控制网络训练的初始学习率, 其域空间为 $[10^{-5}, 10^{-2}]$ 。

(3) 随机梯度下降动量: 此参数控制超参数更新的平滑程度, 减少随机梯度下降的噪声, 其域空间为 $[0.8, 0.98]$ 。

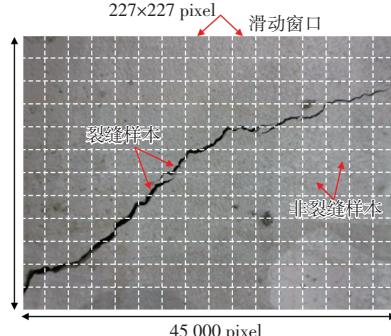
(4) L2 正则化强度: 此参数控制正则化强度, 以防止过拟合, 其域空间为 $[10^{-10}, 10^{-2}]$ 。

3 DeepLabv3+的桥梁裂缝几何特征提取

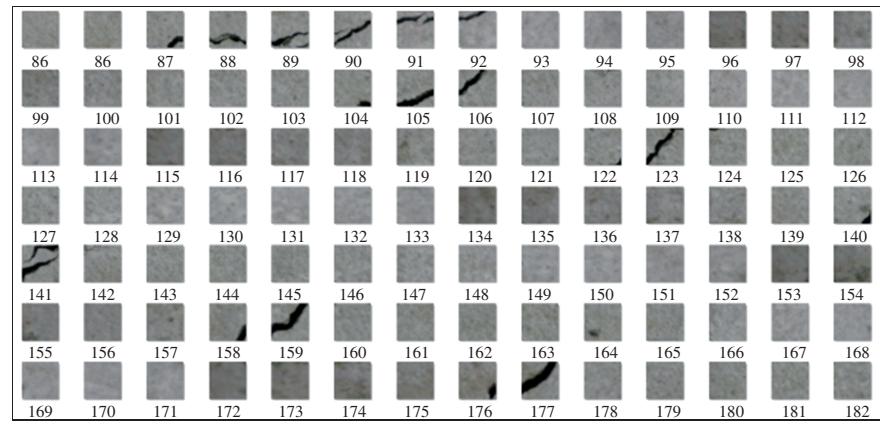
MobileNet-v2^[15]借鉴了 MobileNet-v1 和 ResNet 的优点, 在保持良好的计算速度和较小的存储需求基础上, 通过线性瓶颈和倒残差的方式提升网络性能。因此, 利用 MobileNet-v2 作为 DeepLabv3+ 模型的特征提取网络, 以提高训练速度及识别精度, DeepLabv3+ 模型的网络结构如图 5 所示。选择交叉熵作为模型的损失函数, 学习率由贝叶斯优化算法优化, 初始值设为 0.000 01, 梯度下降算法选择为 Adam 优化算法。

加训练图像数量, 同时还能保证每张图像像素大小保持一致。原始的病害图像尺寸为 4500×3200 像素。定义滑动窗口大小为 227×227 像素, 窗口的滑动步长为 227 像素。经过滑动窗口自动裁剪后, 单张原始的病害图像可以得到 266 张小尺寸图像。裁剪后的小尺寸裂缝图像如图 6 所示。

研究与应用



(a) 原裂缝图像



(b) 剪裁后的裂缝子图像

图 6 数据集制作
Fig. 6 Dataset production

4.1.2 数据集标注

数据集中包含桥梁麻面、裂缝、露筋和剥落等 4 种桥梁病害图像, 经 HSV (色调 Hue, 饱和度 Saturation, 明度 Value) 变换、平移和镜像等数据增强操作, 将增强后图像扩充至原始病害数据集进行训练, 最后划分训练集、验证集和测试集, 数据集图像的划分数量见表 2。

对于训练集, 需要对子图像进行标定, 设置标签表明图像的所属病害类别, 标定的工具如图 7 所示。在数据集制作完成以后, 将大量含有标签的图片样本数据输入到 DBDD 网络模型进行训练, 结合

表 2 DBDD 网络病害分类数据集

Table 2 Disease classification data set based on convolutional neural network

类别	麻面	裂缝	露筋	剥落
滑动窗口切割后	1 600	1 500	320	214
数据增强后	3 200	3 000	1 650	1 070
比例				
训练集: 验证集: 测试集 = 7:2:1				

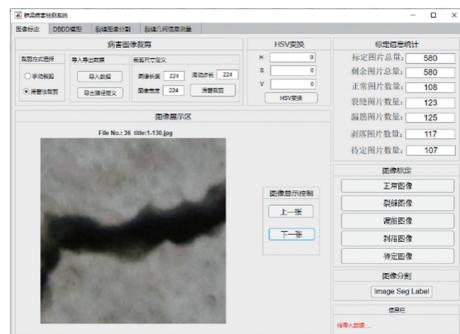


图 7 基于 Matlab GUI 设计简易的病害图像裁剪及标定工具箱

Fig. 7 Design a simple disease image cropping and calibration toolbox based on Matlab GUI

损失函数及反向传播算法, 不断调整病害分类器的网络参数, 优化算法模型, 从而实现预测病害的有无及类型。

对于验证集, 同样需要制作对应子图像的标签, 目的是用于验证训练完毕的网络模型, 结合相关评价指标对模型训练试验结果作有效评价, 以便及时发现问题, 调整网络结构。

4.2 病害图像的预处理

除了 HSV 变换、平移和镜像等图像预处理操作之外, 为加快训练过程中梯度下降求最优解的速度, 将图像进行归一化和均值减法处理, 计算公式如下:

$$y = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (2)$$

式中: y 为转化后的像素值; x 为转化前的像素值; x_{\min} 为样本图片最小像素值; x_{\max} 为样本图片最大像素值。

$$\bar{x} = \frac{1}{N} \sum_{n=1}^N x_n \quad (3)$$

$$\tilde{x} = x - \bar{x} \quad (4)$$

经过归一化和均值减法处理后的效果如图 8 所示。按照此方法进行批量处理后, 可以移除图



(a) 原始子图像



(b) 归一化结果



(c) 均值减法结果

图 8 裂缝样本图像预处理后效果图

Fig. 8 Preprocessing effect of crack sample image

片中的共同部分, 进一步凸显个体差异, 利于加快训练速度。

4.3 DBDD 模型训练

模型训练环境为 CPU Intel Xeon Sliver, 内存为 32 GB, GPU 为 NVIDIA Quadro P4000, 内存为 8 GB。网络模型基于 Matlab2019b 软件实现, 使用单 GPU 加速计算。

执行贝叶斯优化后, 验证集误差最小为 0.038 0, 优化过程如图 9 所示, 此时最优网络参数见表 3。从图 9 中可以看出, 迭代过程中出现 4 个波峰。主要原因是针对多种病害的训练, 前一个病害确定适合的

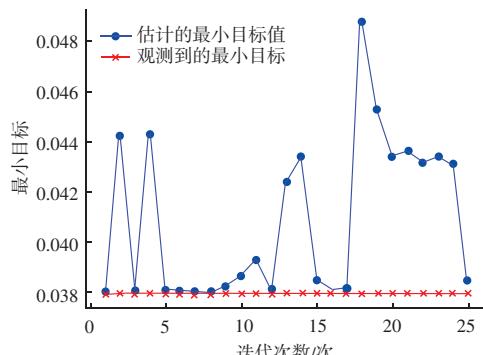


图 9 验证集贝叶斯优化结果

Fig. 9 Verify set Bayesian optimization results

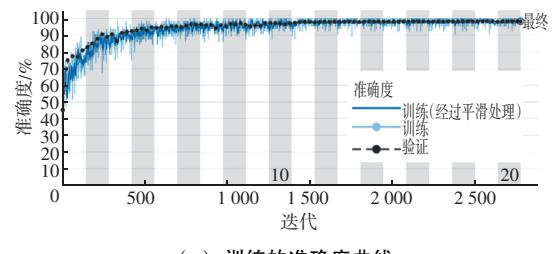
表 3 最优组合参数取值

Table 3 The optimal parameter takes the value

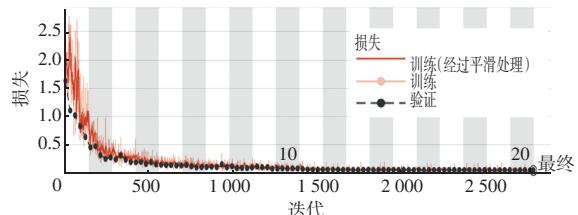
验证集误差	卷积深度	初始学习率	随机梯度下降动量	L2 正则化强度
0.038 0	3	0.000 75	0.936 1	1.391 2e ⁻⁵

超参数后, 后一个病害会在前一个病害的基础上, 进一步寻找同时适用于这两种病害的超参数, 形成波峰。这样通过迭代前一种病害的超参数基础上, 逐步寻找适用于全部病害的超参数, 使得最终得到的目标值和理论目标值尽可能接近, 满足多种病害同步识别。

采用随机梯度下降法 (Stochastic Gradient Descent, SGD), 以贝叶斯优化后的超参数进行模型训练, 迭代轮次设置为 20, 训练和验证过程中病害的准确度曲线和损失曲线如图 10 所示。



(a) 训练的准确度曲线



(b) 训练损失曲线

图 10 DBDD 模型训练的准确度和损失曲线
Fig. 10 Accuracy and loss curves for DBDD model training

在第 1 到 6 迭代轮次中, 准确率一直处于增长阶段, 损失值则处于下降阶段。在前 2 个迭代轮次中, 准确率上升较快, 损失曲线下降较快。第 3 和 4 迭代轮次, 准确率上升速率放缓, 损失下降速率也逐渐放缓。在第 4~10 迭代轮次中, 正确率与损失值比较平稳, 没有出现剧烈波动情况。因此, 可以判断没有出现过拟合现象, 训练结果是可行的。

4.4 模型验证结果和性能对比

最终的训练结果显示, 训练阶段准确率平均值达到 98.53%, 验证阶段准确率平均值为 97.69%, 验证损失值为 0.064 6, 最终测试结果见表 4。

研究与应用

表 4 最优网络测试集测试结果
Table 4 Optimal network set test results

测试集 误差	麻面准 确率/%	裂缝准 确率/%	露筋准 确率/%	剥落准 确率/%	平均准 确率/%
0.049 3	90.9	97.0	98.2	97.2	95.1

测试集误差 0.049 3 略大于验证集误差 0.038, 这是因为贝叶斯优化采用验证集误差最小的原则来确定最佳网络, 而不采用网络对测试集进行评价。因此, 测试误差略高于验证误差。在测试集中, 各个病害类型的检测准确率都超过 90%。由此可见, 网络表现出良好的识别性能。

选用 4 个评价指标: 精确度 (Precision)、召回率 (Recall)、F1 分数 (F1 score) 以及混淆矩阵进行评估模型性能, 前 3 个评价指标的计算公式如下:

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (5)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (6)$$

$$F1 = \frac{2PR}{P + R} \quad (7)$$

将 TP、FN、FP、TN 一起呈现在同一个表格中, 就可以得到一个表征分类结果的矩阵, 称为混淆矩阵 (Confusion Matrix)。常见的二分类问题的混淆矩阵见表 5。贝叶斯优化后的 DBDD 模型, 在测试集上进行分类, 得到混淆矩阵如图 11 所示。

表 5 二分类问题混淆矩阵
Table 5 the confusion matrix for two class

混淆矩阵	预测值		
	正类	负类	
真实值	正类	TP	FN
	负类	FP	TN

Precision Spall	Rebar	Crack	Background		Recall
			291	22	
			9	291	0.97
			0	1	0.98
			0	2	0.97
			0.97	0.92	0.97
			0.97	0.95	

图 11 测试集混淆矩阵

Fig. 11 Confusion matrix of Test set

此外, 还选取支持向量机 (SVM) 模型以及 Inception - v3 - TL 进行分类性能对比, 以裂缝病害的识别效果为例, 对比结果见表 6。

表 6 网络识别裂缝性能对比
Table 6 Comparison of network crack identification performance

识别算法	精确度/%	召回率/%	F1 分数/%	训练时间/h
DBDD 模型	92.4	97.0	94.6	0.5
SVM	83.0	90.0	86.4	
Inception - v3 - TL	95.0	97.7	96.3	2.5

DBDD 模型与 SVM 模型相比, 性能更为优异。与 Inception - v3 - TL 模型性能相差不大, Inception - v3 性能略胜一筹。但是从训练时间相比, 在训练相同迭代 20 个轮次的情况下, DBDD 模型仅耗费 0.5 h, 而 Inception - v3 模型耗费 2.5 h。由此可见, 建立的 DBDD 模型在相同数据量、相同迭代次数下, 训练时间可以明显缩短。

4.5 裂缝图像分割和几何特征测量

4.5.1 裂缝图像分割

建立的 DeepLabv3 + 图像语义分割模型与其他经典图像语义分割模型 FCN、U - net、Seg - Net 模型以及文献 [8] 提出的 VGG - 19 - FCN 模型进行性能对比。选用相同的软硬件配置和数据集 (训练集、验证集、测试集)。选用 MAP、MIoU、FWIoU 为模型评价指标, 以评价各网络分割性能。各评估指标的计算公式如下:

$$MAP = \frac{1}{k+1} \sum_{i=0}^k \frac{p_{ii}}{\sum_{j=0}^k p_{ij}} \quad (8)$$

$$MIoU = \frac{1}{k+1} \sum_{i=0}^k \frac{p_{ii}}{\sum_{j=0}^k p_{ij} + \sum_{j=0}^k p_{ji} - p_{ii}} \quad (9)$$

$$FWIoU = \frac{1}{\sum_{i=0}^k \sum_{j=0}^k p_{ij}} \sum_{i=0}^k \frac{p_{ii}}{\sum_{j=0}^k p_{ij} + \sum_{j=0}^k p_{ji} - p_{ii}} \quad (10)$$

各模型在测试集上各评价指标结果见表 7。

表 7 网络分割性能评价指标对比

Table 7 Comparison of network segmentation performance evaluation

分割模型	MAP	MIoU	FWIoU
DeepLabv3 +	0.97	0.95	0.98
VGG19 - FCN	0.95	0.92	0.97
FCN	0.94	0.91	0.97
Seg - Net	0.92	0.87	0.96
U - Net	0.93	0.86	0.95

研究与应用

以5张裂缝图像为示例,进一步展示分割图结果,直观对比各模型性能差异,并以MIoU为指标评价量化分割效果,分割效果图及MIoU指标见表8。

图片1~图片3中的照片分辨率较低,裂缝宽度相对较小。照片有些裂缝位置,肉眼难以准确辨别。在图片1中,DeepLabv3+网络和FCN识别效果较好,MIoU达到0.7以上。而Seg-Net网络仅仅识别出一小部分。在图片2中,裂缝宽度不一,各网络在宽度较大处识别效果良好;而在裂缝宽度较小处,

清晰度模糊位置,DeepLabv3+网络识别效果较其他图片更好。VGG19-FCN识别效果也不错,大致呈现了裂缝走向。U-Net网络虽然大致识别出裂缝走向,但是结果中也呈现出噪点较多的缺点。在图片3中,裂缝识别也较为模糊,各网络识别分割图均有断裂。相对而言,DeepLabv3+网络分割效果较好。在图片4和图片5中,裂缝宽度相对较大,各网络模型均能分割出裂缝走向及位置,从MIoU指标看,DeepLabv3+裂缝分割模型性能较为稳定,分割效果较优。

表8 裂缝图像分割效果对比
Table 8 Comparison of crack image segmentation effects

图片方法	图片1	图片2	图片3	图片4	图片5
裂缝原始子图像					
DeepLabv3 +					
Vgg19 - FCN					
FCN					
Seg - Net					
U - Net					

研究与应用

4.5.2 裂缝几何特征测量

桥梁裂缝图像经过 DeepLabv3+ 模型语义分割处理后, 得到的二值化裂缝图像中可能包含大量的噪点。在进行几何特征测量之前, 首先需要利用形态学方法对裂缝二值化图像进行二度去噪和去毛刺处理, 以保证裂缝的连续性。具体流程包括:

(1) 形态学去噪与毛刺处理: 利用形态学方法对 DeepLabv3+ 模型输出的二值化裂缝图像进行二次去噪, 提升裂缝连续性, 减少干扰。

(2) 连通域标记与分离: 对图像中可能存在的多条裂缝进行区分, 形成独立连通域, 以便逐条分析其几何特征。

在完成图像预处理与连通域划分的基础上, 对每一条裂缝进行以下三项几何参数测量:

(1) 裂缝方向测量

首先, 对于标记每个裂缝区域的连通域, 在处理该裂缝时, 隐去其他裂缝区域, 得到仅包含每条裂缝连通区域的二值图像。然后, 遍历整个二值图像, 得到每个裂缝像素的坐标, 计算这些裂缝像素

横坐标差值 H , 纵坐标差值 V , 然后根据横纵坐标比值及反三角函数, 计算出裂缝倾斜角度。

(2) 裂缝长度测量

首先, 采用 Zhang-Suen 细化算法提取裂缝骨架, 统计裂缝骨架图像像素个数。然后, 按照像素标定得到的转换系数, 将裂缝骨架图中的像素个数转化为裂缝真实物理长度。

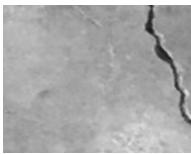
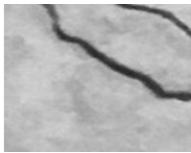
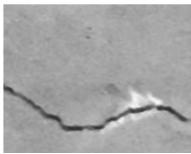
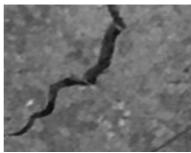
(3) 裂缝宽度测量

首先, 基于边缘提取算法得到裂缝边缘的二值图像, 对裂缝边缘二值图像扫描得到裂缝边界坐标。然后, 采用最小距离法计算边界中每点的裂缝像素宽度, 然后对所有裂缝宽度值取平均值、最大值。最后, 根据像素标定转换系数, 得到裂缝最大宽度及裂缝平均宽度物理值, 具体计算流程如图 12 所示。

为了验证该方法的可行性, 以 5 个裂缝图像为例, 计算裂缝宽度、长度和走向等几何信息, 具体计算结果见表 9。然而, 由于缺少专业的裂缝宽度测量仪器作为基准, 目前尚无法验证算法精度。后续研究将结合专业测量设备, 进一步开展算法精度验证与优化工作。

表 9 裂缝几何特征信息测量 (像素标定系数为 0.253 6)

Table 9 Measurement of crack geometric feature information (pixel calibration coefficient of 0.253 6)

图片	分割图	长度/mm	最大宽度/mm	平均宽度/mm	角度/ (°)
		58.33	6.01	4.03	14.35
		50.72	3.97	2.31	-73.20
		58.07	5.20	3.96	-38.29
		27.90	3.18	1.82	-27.58
		66.70	3.53	2.75	-4.44
		65.43	5.98	3.76	55.49

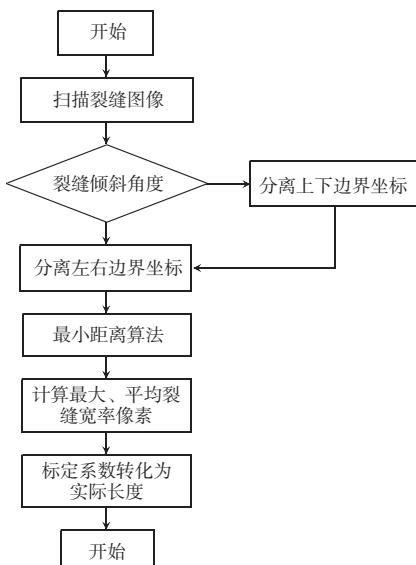


图 12 裂缝宽度计算流程图
Fig. 12 Crack width calculation flowchart

5 结论

为实现桥梁表观病害的高效识别与裂缝几何特征的精准测量, 构建了一个集病害分类、语义分割与图像处理的集成框架。通过系统的研究与验证, 得出以下主要结论:

(1) 提出了一种基于贝叶斯优化的多病害自动识别模型 (DBDD)。该模型通过贝叶斯算法自动寻优超参数, 有效克服了传统方法对人工经验的依赖。模型在测试集上的平均识别准确率达到 95.1%, 在保证与 Inception-v3 等先进模型相近识别精度的同时, 将训练时间显著缩短了约 80%。

(2) 建立了一种新的裂缝语义分割与几何特征提取方法。分割模型在测试集上 MIoU 值为 0.95, 其分割性能优于 FCN、U-Net 等经典模型。结合形态学处理和连通域分析技术, 成功实现了对裂缝长度、最大宽度、平均宽度和倾斜角度等关键几何参数的自动化、定量化测量。

(3) 综合而言, 本研究提出的集成框架, 成功地将病害分类、裂缝分割与几何量化功能融为一体, 证明了深度学习技术在桥梁表观病害自动化检测中的应用潜力。该方法不仅提升了病害识别的效率, 更能为桥梁的性能预测与养护决策提供精确的数据支撑, 具有很大的工程应用价值。未来的研究将侧重于引入专业测量仪器, 进一步验证与提升几何特征测量的绝对精度。

参 考 文 献

- [1] 贺拴海, 赵祥模, 马建, 等. 公路桥梁检测及评价技术综述 [J]. 中国公路学报, 2017, 30 (11): 63–80.
- [2] 谢东阳, 李丽宏, 苗长胜. 基于改进 AlexNet 卷积神经网络的手写体数字识别 [J]. 河北工程大学学报 (自然科学版), 2021, 38 (4): 102–106.
- [3] 杨超, 刘凯, 刘亚红, 等. 有载频率与深度学习在桥梁损伤识别中的应用研究 [J]. 粉煤灰综合利用, 2024, 38 (4): 123–128.
- [4] ZHU J, ZHANG C, QI H, et al. Vision-based defects detection for bridges using transfer learning and convolutional neural networks [J]. Structure and Infrastructure Engineering, 2020, 16 (7): 1037–1049.
- [5] 车艳丽. 基于深度学习的路面裂缝分类与识别技术研究与实现 [D]. 西安: 长安大学, 2018.
- [6] 马卫飞. 基于深度学习的桥梁裂缝检测算法研究 [D]. 西安: 陕西师范大学, 2018.
- [7] 高小小. 基于深度学习的混凝土桥梁裂缝检测与分类 [D]. 西安: 陕西师范大学, 2018.
- [8] 张宇博. 复杂环境下全卷积神经网络在桥梁裂缝检测中的应用研究 [D]. 西安: 长安大学, 2019.
- [9] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift [J]. JMLR.org, 2015, 37, 448–456.
- [10] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition. IEEE, 2016: 770–778.
- [11] 王莉静, 孙泽然, 李志猛, 等. 改进 YOLOv5 的沥青路面裂缝检测方法 [J]. 河北工程大学学报 (自然科学版), 2024, 41 (3): 67–73, 79.
- [12] 陈军, 王青, 周辉阳. 装配式工程易变形结构裂缝红外微弱目标识别方法 [J]. 粉煤灰综合利用, 2023, 37 (4): 122–127.
- [13] 张建勋. 基于特征图的路面冻融裂缝红外检测算法 [J]. 粉煤灰综合利用, 2025, 39 (2): 164–168.
- [14] 朱苏雅, 杜建超, 李云松, 等. 采用 U-Net 卷积网络的桥梁裂缝检测方法 [J]. 西安电子科技大学学报, 2019, 46 (4): 35–42.
- [15] 乔朋, 梁志强, 段长江, 等. 基于改进 Faster R-CNN 与 U-Net 算法的桥梁病害识别与量化方法 [J]. 东南大学学报 (自然科学版), 2024, 54 (3): 627–638.
- [16] 朱劲松, 李欢. 基于深度学习的钢桥病害分割与量化 [J]. 东南大学学报 (自然科学版), 2022, 52 (3): 516–522.
- [17] 余加勇, 刘宝麟, 尹东, 等. 基于 YOLOv5 和 U-Net3+ 的桥梁裂缝智能识别与测量 [J]. 湖南大学学报 (自然科学版), 2023, 50 (5): 65–73.
- [18] 劳武略, 崔闯, 张登科, 等. 基于计算机视觉的钢桥面板裂纹识别方法 [J]. 中国公路学报, 2023, 36 (3): 188–201.