

DOI:10.3969/j.issn.1003-5060.2024.07.021

基于深度学习的桥梁表观裂缝检测算法研究

张鸣祥^{1,2}, 张睿¹, 钟其仁¹

(1. 合肥工业大学 土木与水利工程学院, 安徽 合肥 230009; 2. 土木工程防灾减灾安徽省工程技术研究中心, 安徽 合肥 230009)

摘要: 针对在复杂背景条件下难以直接对桥梁表观裂缝进行检测的问题, 文章提出一种基于深度学习的桥梁表观裂缝检测算法。首先利用滑动窗口算法将采集到的桥梁表观裂缝图像切分为小尺寸的桥梁裂缝面元图像和桥梁背景面元图像, 并根据对面元图像的分析, 提出一种基于 Inception 网络和残差网络(ResNet)的桥梁裂缝分类模型, 用于桥梁裂缝面元和桥梁背景面元的识别; 然后结合桥梁裂缝分类模型与滑动窗口算法对桥梁表观裂缝图像进行检测; 最后利用数字图像处理技术测量裂缝宽度。结果表明: 该文算法对桥梁表观裂缝有超过 99% 的分类精度, 可满足实际工程需要; 实现了裂缝的提取并能准确地定位出裂缝在图像中的位置; 根据成像原理能测量出裂缝宽度。与传统的深度学习模型相比, 该模型拥有更高的执行效率, 可用于大规模检测, 更易于应用在桥梁健康检测中。

关键词: 深度学习; 桥梁表观裂缝检测; 滑动窗口算法; Inception 网络; 残差网络; 数字图像处理

中图分类号: U446.2 **文献标志码:** A **文章编号:** 1003-5060(2024)07-0995-08

Research on detection algorithm for bridge apparent crack based on deep learning

ZHANG Mingxiang^{1,2}, ZHANG Rui¹, ZHONG Qiren¹

(1. School of Civil and Hydraulic Engineering, Hefei University of Technology, Hefei 230009, China; 2. Anhui Civil Engineering Research Center for Disaster Prevention and Mitigation, Hefei 230009, China)

Abstract: Aiming at the problem that it is difficult to directly detect bridge apparent cracks under complex background conditions, this paper proposes a bridge apparent crack detection algorithm based on deep learning. Firstly, the collected bridge apparent crack image is divided into small-sized bridge crack patches and bridge background patches by sliding window algorithm, and a bridge crack classification model based on Inception network and residual network(ResNet) is proposed according to the analysis of the patches, which is used to identify bridge crack patches and bridge background patches. Then, the bridge crack classification model and sliding window algorithm are combined to detect the apparent crack image of the bridge. Finally, the width of the crack is measured using digital image processing technology. The experimental results show that the algorithm in this paper has more than 99% classification accuracy for the apparent cracks of the bridge, which can meet the actual engineering needs. The extraction of cracks is realized and the position of cracks in the image can be accurately located. The crack width is measured according to the imaging principle. Compared with the traditional deep learning model, the model has higher execution efficiency, can be used for large-scale detection, and is easier to apply in bridge health detection.

Key words: deep learning; bridge apparent crack detection; sliding window algorithm; Inception network; residual network(ResNet); digital image processing

收稿日期: 2023-01-01; 修回日期: 2023-04-04

基金项目: 国家自然科学基金资助项目(51878234)

作者简介: 张鸣祥(1980—), 男, 江苏镇江人, 博士, 合肥工业大学副教授, 硕士生导师。

0 引言

随着社会进步,与日俱增的交通量增加了在役桥梁的负荷,造成桥梁损伤事故频发。结构开裂是钢筋混凝土及预应力钢筋混凝土结构中较为常见的病害,这种病害对结构的功能性和耐久性有着决定性的影响,因此对桥梁裂缝进行识别检测至关重要。目前基于图像的无损检测技术已经成为国内外桥梁健康监测领域研究的热点。文献[1]将滑动窗口算法与 DBCC 裂缝分类模型结合进行桥梁裂缝检测,实现了较传统的 CIFAR10 模型更好的裂缝识别效果;文献[2]提出基于 Mask RCNN 的检测算法用于桥梁裂缝检测,算法融合语义增强模块和特征金字塔网络,对裂缝的检测精度有显著提高;文献[3]利用无人机采集桥梁裂缝图像,引入掩膜区域卷积神经网络实现裂缝的识别和定位,并利用图像二值化、裂缝骨架化等方法获取裂缝信息;文献[4]将 U-Net 卷积神经网络算法引入到桥梁裂缝检测中,同时采用八方向搜索算法实现对裂缝宽度的精准测量;文献[5]为了解决 DeepLabv3+ 裂缝图像分割模型在编码模块训练过程中缩减输入数据的空间维度问题,将 YOLOF 模块和 ResNet 模块加入 DeepLabv3+ 裂缝图像分割模型,提升裂缝图像的像素精度。实际采集到的裂缝图像中通常包含大量的背景噪声,这些噪声会干扰算法对裂缝的识别和测量。文献[6]提出结合 U-Net 和 Haar-Like 算法的 UH-Net 深度学习网络,用于复杂背景下桥梁裂缝的有效语义分割;文献[7]将降噪后的裂缝图像运用滑动窗口算法切分为面元图像,并结合 BC-MobileNet 轻量化模型实现面元图像的分类,在识别误检和漏检面元后,最终实现桥梁裂缝的准确识别;文献[8]利用区域生成网络进行隧道裂缝图像中裂缝的检测,该方法减弱背景噪声对检测的影响,实现对裂缝的快速检测;文献[9]采用 U-Net 卷积神经网络实现像素级小样本的裂缝检测,该方法使用多层卷积自动提取裂缝特征,并利用浅层网络与深层网络叠加的方法实现裂缝局部特征与抽象特征的融合,从而减少背景噪声的干扰,保留裂缝细节特征。

针对在复杂背景条件下难以直接对桥梁表面裂缝进行检测的问题,本文提出一种基于 Inception_ResNet 网络模型的桥梁表面裂缝检测算法。输入经滑动窗口算法处理后的面元图像对 Inception_ResNet 网络模型进行训练、测试,实现

桥梁裂缝面元图像和背景面元图像的分类;然后利用模型分类结果,结合 `xlwing`、`pandas`, 实现在裂缝图像上提取裂缝和定位裂缝;最后利用模型分类结果,结合数字图像处理技术和相机成像原理,实现裂缝宽度的测量。

1 数据集

深度学习^[10]中的神经网络模型进行桥梁裂缝检测时,需要大量带类别标签的桥梁裂缝图像作为训练集、验证集和测试集。

本文的数据集来源以下 2 个部分:① 文献[1]所提供的无人机采集的桥梁裂缝集,该数据集的桥梁表面裂缝图像是由无人机自带的 CMOS 面阵相机采集的,具体的采集方法是让无人机在桥梁裂缝的附近进行悬停,通过无人机的云台调整相机的姿态,使得云台保持与裂缝表面垂直,同时保证相机的镜头与桥梁裂缝保持 30 cm 的距离,在调整好相机的姿态和距离之后,无人机沿着裂缝方向稳定飞行、连续拍照。该数据集共采集 2 000 张桥梁表面裂缝图像。② 安徽省六安市迎驾大桥桥梁检测现场采集的 2 047 张桥梁表面裂缝图像。

这些现场采集的桥梁表面裂缝图像既没有限制固定的拍摄条件,如焦距、物距等,也没有统一的光照条件,导致图像的背景部分较为复杂,提高了后期模型的训练难度,保证了模型对不同复杂环境的适应能力。本文示例中所采用的桥梁表面裂缝图像均来源于安徽省六安市迎驾大桥。

根据文献[1]的研究成果,本文提出一种基于滑动窗口算法的数据集扩增方法。该方法首先将桥梁表面裂缝图像归一化为 $1\ 024 \times 1\ 024$ 大小的图像,然后使用 $w \times h$ 固定大小的窗口在桥梁表面裂缝图像上沿着 x 、 y 轴有序且不重叠地滑动。同时把窗口覆盖下的桥梁表面裂缝图像的切片单元另存为面元图像。把包含裂缝的面元图像称为裂缝面元,标记为 1;把不包含裂缝面元的图像称为背景面元,标记为 0。具体过程为:

$$\begin{cases} L_x^{\text{img}} = iw, \\ L_y^{\text{img}} = jh, \\ R_x^{\text{img}} = iw + w, \\ R_y^{\text{img}} = jh + h \end{cases} \quad (1)$$

其中: w 、 h 为滑动窗口的宽度和高度;坐标 $(L_x^{\text{img}}, L_y^{\text{img}})$ 为切片单元左上角的角点坐标;坐标 $(R_x^{\text{img}}, R_y^{\text{img}})$ 为切片单元右下角的角点坐标; w_{img} 、 h_{img} 分别为桥梁表面裂缝图像的宽度和高度,令 $w_{\text{img}} =$

$h_{img}=1\ 024$ 像素; i,j 的取值范围分别为 $(0,1,2,\dots,\tau_{img}/\tau_w)$ 和 $(0,1,2,\dots,h_{img}/h)$ 。以 $w=h=128$ 为例基于滑动窗口算法的数据扩增过程如图 1 所示。




图 1 基于滑动窗口算法的数据扩增过程

在数据扩增之前,需要先确定滑动窗口的窗口大小。一方面,若滑动窗口过大,则会导致裂缝面元图像中除了裂缝信息以外还会包含过多复杂的背景信息干扰,从而降低模型分类的准确率;另一方面,若滑动窗口过小,则会导致裂缝面元图像过于细碎从而损失裂缝信息,影响后期模型计算的准确率。因此,过大或过小的滑动窗口都会直接影响模型分类的准确率。从文献[11]的研究结果可以看出,滑动窗口大小的确定并没有严格的规定,而是根据图片数据的情况以及工程实际的需求来确定。本文分别选择 128×128 、 64×64 、 32×32 、 16×16 共 4 种不同尺寸的窗口进行对比,如图 2 所示。

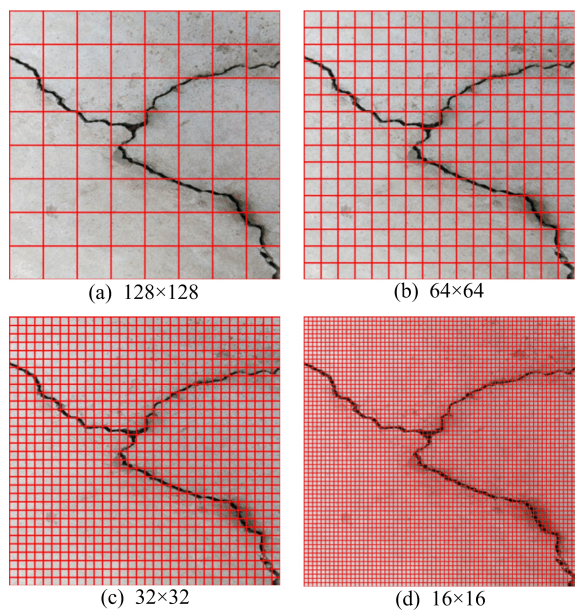


图 2 不同尺寸的滑动窗口实例

由图 2 可知, 128×128 、 64×64 的滑动窗口尺寸过大,裂缝面元图像内部包含了大量的背景

干扰信息,而过小的滑动窗口(如 16×16)则会损失裂缝信息。 32×32 的滑动窗口更适用本文所构建的数据集,能够很好地把裂缝信息从原图中提取出来。使用 32×32 的滑动窗口所提取的裂缝如图 3 所示。




图 3 32×32 大小的切片单元所提取的裂缝

将采集来的 4 047 张桥梁表面裂缝图像随机地划分为 2 组,A 组包含 2 047 张桥梁裂缝图像,B 组包含 2 000 张图像。对 A 组中的 2 047 张照片使用上述滑动窗口算法进行人工扩增。在扩增的过程中,部分切片只裁剪到了裂缝的部分边缘信息,需手动剔除此类切片图像。从剔除不合格图像后的数据组中挑选出 14 000 张桥梁表面裂缝面元图像、96 000 张桥梁背景面元图像。最后将桥梁表面裂缝面元图像和背景面元图像拆分成训练集和验证集。

按照一张桥梁表面裂缝照片中裂缝和背景的百分比,来确定训练集和验证集中裂缝面元和背景面元所占比例。训练集包含 12 000 张桥梁表面裂缝面元图像、88 000 张桥梁背景面元图像;验证集包含 2 000 张桥梁表面裂缝面元图像、8 000 张桥梁背景面元图像。B 组中的 2 000 张桥梁表面裂缝图像构成测试集。

2 Inception_ResNet 网络模型的构建

由于桥梁表面裂缝所处的环境较为复杂,存在污渍、遮挡、光照不均等多种噪声干扰,传统的基于人工的特征分类方法效率较低、精度较差。基于深度学习的桥梁表面裂缝检测已成为当前的主流研究方向。本文提出 Inception_ResNet 网络模型,用于分类桥梁裂缝面元和桥梁背景面元。

2.1 Inception_ResNet 网络模型的理论基础

2.1.1 Inception 网络

Inception 网络^[12]是由 Inception 模块反复叠堆形成的。Inception 模块可以对网络的深度和宽度进行高效扩充,在提升深度学习网络准确率

的同时防止过拟合现象发生。Inception 模块的核心思想就是将不同的卷积层通过并联的方式结合在一起,经过不同卷积层处理的结果矩阵拼接起来形成一个更深的矩阵。基础的 Inception 模块使用 3 种不同尺寸的卷积层(1×1、3×3、5×5)和 1 个最大池化层。Inception 模块的基本结构如图 4 所示。

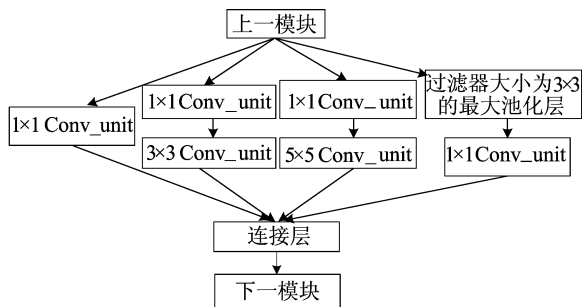


图 4 Inception 模块基本结构

图 4 中,Conv_unit 包含卷积层、正则化层和激活函数层(ReLU)。

2.1.2 残差网络(ResNet)

深度卷积网络具备高效的特征提取能力,能够通过组合低维特征形成更抽象的高维特征。通常认为通过堆叠卷积层、池化层加深卷积网络的层次结构可以丰富特征的层次,然而随着网络层数的不断增加,梯度消失和梯度爆炸问题也随之出现,随着网络层数增加,反向传播至网络前几层的梯度无穷小或者无穷大,模型训练难以收敛。传统的解决方法是在模型中加入数据初始化、正则化^[13]以及随机失活^[14]等,但这使得模型变得更复杂。同时,这些措施的加入带来网络性能的退化问题,即网络层数加深了,模型分类结果的准确率却下降了。残差网络^[15]在层级之间添加跳跃连接,在不增加网络层数的同时却极大地增加网络的深度,同时使得模型分类结果的准确率得到巨大提升。跳跃连接的加入也解决了梯度消失和梯度爆炸问题。

作为跳跃连接思想的延伸,残差网络引入了残差块(residual block)这一结构形式。残差块结构如图 5 所示。




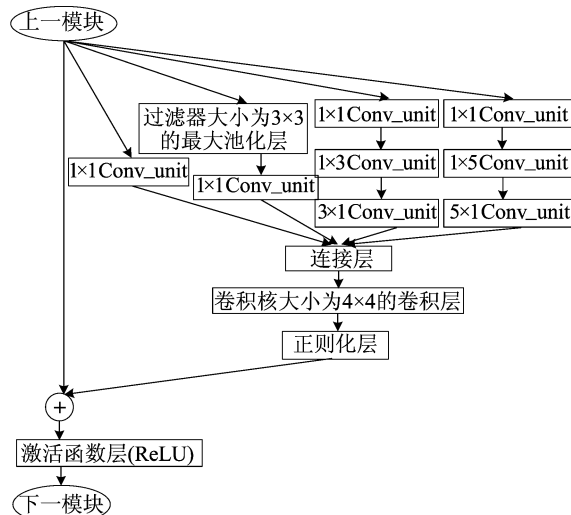

图 5 残差块结构

图 5 中: $a^{[l-1]}$ 为上一层网络块的输出或者残差块的输入层; $a^{[l]}$ 为残差块的输出; $g(a^{[l-1]})$ 为残差映射函数。

因为构造具有更深层网络模型的基本约束是堆叠后的网络模型误差应不高于基础的浅层模型,所以研究采用在浅层网络的基础上,对后续堆叠的网络层采用恒等映射的方法构建深层模型,恒等映射表示堆叠层的输入等于输出。一组堆叠卷积网络的最佳解映射为 $a^{[l]} = a^{[l-1]}$ 。深度卷积神经网络难以训练的原因之一是当网络较深时,卷积神经网络难以直接拟合实际映射。而残差网络是通过引入跳跃连接直接将残差块的输入 $a^{[l-1]}$ 与残差映射 $g(a^{[l-1]})$ 叠加作为残差块的输出 $a^{[l]}$ 。此时,残差块的输出即实际映射 $a^{[l]}$ 表示为 $a^{[l]} = g(a^{[l-1]}) + a^{[l-1]}$ 。当 $g(a^{[l-1]}) \rightarrow 0$ 时,原式 $a^{[l]} = g(a^{[l-1]}) + a^{[l-1]}$ 就构成一个恒等映射 $a^{[l]} = a^{[l-1]}$ 。模型只需要最小化残差映射 $g(a^{[l-1]}) = a^{[l]} - a^{[l-1]}$ 即可解决网络层堆叠带来的梯度消失、梯度爆炸以及网络性能退化问题。

2.2 Inception_ResNet 网络模型的构建

Inception_ResNet 网络模型由 Stem、Inception、Inception_ResNet_A、Inception_ResNet_B 模块组成,如图 6 所示。



(b) Inception_ResNet_A 模型

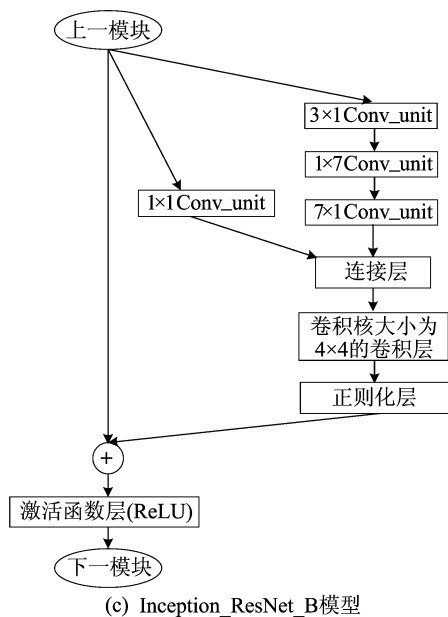


图 6 Stem、Inception-ResNet-A、Inception-ResNet-B 模块

Inception-ResNet-A 模块、Inception-ResNet-B 模块结合 Inception 网络和残差网络的核心思想,保留两类神经网络的特点。

Inception-ResNet 网络模型结构如图 7 所示。

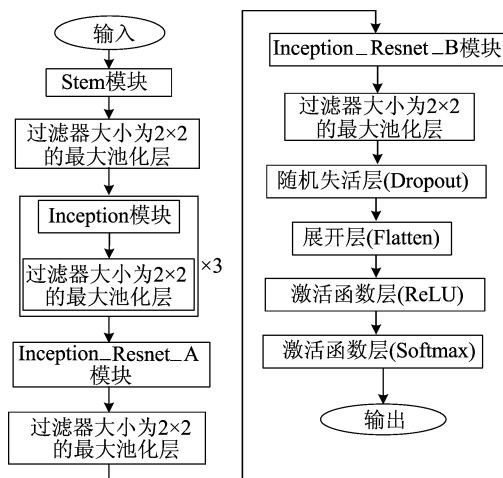


图 7 Inception-ResNet 网络模型结构

使用 Inception-ResNet 网络模型对桥梁表面裂缝图片进行检测时,首先通过 Inception-ResNet 网络 Stem 模块对桥梁表面裂缝图像进行特征提取。输入 Stem 模块的裂缝图像经过 3 次卷积、正则化操作后,裂缝图像的浅层特征得到了有效提取。裂缝图像在经过 Stem 模块以后,利用 2×2 大小的最大池化核对特征图进行处理,这极大地增加有效感受野。然后裂缝图像依次经过 2 层 Inception 模块、1 层 Inception-ResNet-A 模块、1 层 Inception-ResNet-B 模块,每个模块之

间均有 1 层最大池化层。在经过 Dropout 层进行随机失活以后,裂缝图像进入 Flatten 层进行展开并经过激活函数 ReLU 层进行激活。最后采用 Softmax 激活函数输出最终的特征预测值。

3 模型训练及结果分析

3.1 模型训练

本实验在 TensorFlow、Keras 框架下的 Jupyter notebook 上进行训练。CPU 采用 Intel i5-9300H, GPU 采用 GTX 1050。模型使用小批量优化算法和 Adam 优化算法相结合的训练方法,主要超参数包括批大小、迭代次数、学习率、学习率衰减等。实验设置训练批量大小为 32,数据训练迭代 250 次。学习率初始值设置为 1×10^{-6} ,学习率衰减值设置为 4×10^{-8} 。为了排除神经网络参数初始化随机性带来的影响,从而验证 Inception-ResNet 网络模型的稳定性和可靠性,重复实验 10 次。

为了显示出 Inception-ResNet 网络模型的优越性,实验选取 VGG 模型^[16]进行对比实验。VGG 模型的各项超参数的设置均与 Inception-ResNet 模型相同。

3.2 模型训练结果及分析

将桥梁表面裂缝数据集代入 Inception-ResNet 网络模型、VGG 模型进行训练,得到训练结果如图 8 所示。模型训练结果评价见表 1 所列。

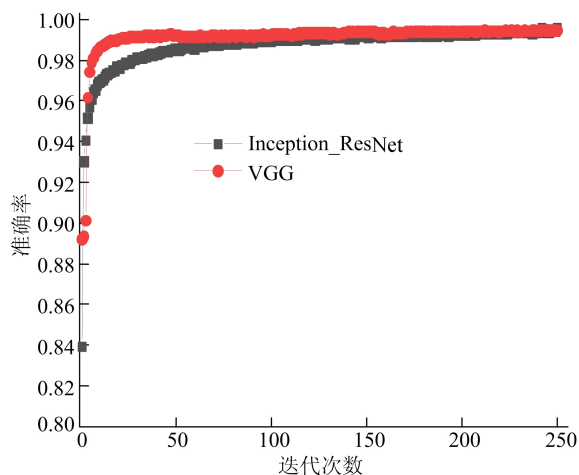


图 8 模型训练集准确率曲线

表 1 模型验证集测试结果

| 指标 | Inception-ResNet | VGG |
|----------------|------------------|---------|
| A | 0.994 6 | 0.995 3 |
| P | 0.983 1 | 0.989 2 |
| R | 0.962 3 | 0.963 8 |
| F ₁ | 0.972 6 | 0.976 3 |
| 每次迭代用时/s | 56 | 89 |

表 1 中: A 、 P 、 R 分别为准确率、精确率、召回率; F_1 为精确率和召回率的调和平均数。各评价指标计算公式为:

$$A = \frac{T_P + T_N}{T_P + F_P + F_N + T_N} \quad (2)$$

$$P = \frac{T_P}{T_P + F_P} \quad (3)$$

$$R = \frac{T_P}{T_P + F_N} \quad (4)$$

$$F_1 = \frac{2PR}{P+R} \quad (5)$$

其中: T_P 为被预测对象为桥梁裂缝面元,且预测结果正确的图像数量; F_N 为被预测对象为桥梁裂缝面元,且预测结果错误的图像数量; F_P 为被预测对象为桥梁背景面元,且预测结果正确的图像数量; T_N 为被预测对象为桥梁背景面元,且预测结果错误的图像数量。

由图 8 可知, Inception-ResNet 网络模型在分类桥梁裂缝面元和桥梁背景面元方面有超过 99% 的准确率, 可满足工程实际需求。由表 1 可知, Inception-ResNet 网络模型 1 次迭代用时为 56 s, 与 VGG 模型 1 次迭代用时 89 s 相比, Inception-ResNet 网络模型拥有更高的执行效率、更低的时间复杂度, 更能满足桥梁裂缝检测实时处理的需求。同时, 10 次重复实验 Inception-ResNet 网络模型分类准确率均保持在 99% 以上, 表现出良好的稳定性和可靠性。

4 裂缝的提取、定位及宽度测量

4.1 裂缝的提取和定位

根据第 1 节提出的滑动窗口算法, 首先将测试集里的 2 000 张桥梁表面裂缝图像切分为 32×32 大小的面元图像。切分裂缝图像时运用数据分析库 xlwing、pandas 在表中记录下元图像的序号以及左上角的 x 、 y 轴坐标。然后将面元图像重新打包为测试集, 并将其代入训练好的 Inception-ResNet 网络模型进行面元图像的分类。将 Inception-ResNet 网络模型分类结果按照序号记录, 裂缝面元标记为 1, 背景面元标记为 0。最后利用记录下的标记信息, 将裂缝面元图像按照序号和图像左上角的 x 、 y 轴坐标重新拼接成完整的桥梁表面裂缝图像, 实现裂缝图像的提取。裂缝提取结果如图 9 所示。

运用 pandas 在表中筛选出标记为 1 的面元图像的序列号、 x 轴坐标、 y 轴坐标。利用 pandas 中的 DataFrame 排序功能, 将筛选过的裂缝图像

坐标信息按照从小到大和从大到小的顺序进行排序, 得到裂缝图像四角点的坐标, 即 (x_{\min}, y_{\min}) 、 (x_{\max}, y_{\min}) 、 (x_{\max}, y_{\max}) 、 (x_{\min}, y_{\max}) , 最终在原裂缝图像上实现裂缝的定位。裂缝定位情况如图 10 所示。




图 9 桥梁表面裂缝提取结果




图 10 桥梁表面裂缝定位

4.2 裂缝宽度测量

在测量裂缝宽度之前, 首先需要对提取到的裂缝图像进行阈值分割处理。阈值分割法是一种常用的并行区域技术, 是通过设定阈值将输入的图像 f 变为输出图像 g 的技术, 阈值的设定公式为:

$$g(x, y) = \begin{cases} 0, & f(x, y) \geq T; \\ 255, & f(x, y) < T \end{cases} \quad (6)$$

其中, T 为阈值。

当裂缝图像 f 上任意一点 (x, y) 的像素值 $f(x, y) \geq T$ 时, 输出的裂缝图像 g 上点 (x, y) 的像素值为 0, 显示为黑色; 当裂缝图像 f 上任意一点 (x, y) 的像素值 $f(x, y) < T$ 时, 输出的裂缝图像 g 上点 (x, y) 的像素值为 255, 显示为白色。为了阈值分割后的裂缝图像 g 能更好地拟合原裂缝图像 f , 经过数次实验, 最终将阈值 T 定为 105。

阈值分割结果如图 11 所示。裂缝图像经过阈值分割后即可用于裂缝宽度测量。裂缝宽度的测量采用逐行、逐列统计像素值为 255 的像素数量。然后将逐行统计得到的像素值为 255 的像素数量与逐列统计得到的像素值为 255 的像素数量进行比较, 即可得到像素意义上的裂缝宽度值。



图 11 桥梁表面裂缝阈值分割结果

运用 OpenCV 将桥梁表面裂缝图像进行像素意义上的宽度测量后,结合激光测距仪标定出相机与裂缝病害之间的物距 u 。根据透镜成像相关原理,可推出下列公式:

$$\frac{1}{v} + \frac{1}{u} = \frac{1}{f} \Rightarrow v = \frac{uf}{u-f} \quad (7)$$

其中: v 为相距; f 为焦距。

令 s 为裂缝病害的实际尺寸, H 为裂缝病害的成像尺寸,根据透镜成像相关原理,可得:

$$\frac{H}{s} = \frac{v}{u} \Rightarrow s = \frac{Hu}{v} \quad (8)$$

将式(7)代入式(8),可得:

$$s = [(u-f)/f]H \quad (9)$$

对于成像尺寸 H ,有

$$H = (D/d)h \quad (10)$$

其中: h 为裂缝图像中裂缝所包含的像素数量; D 为相机镜头 CMOS 的真实尺寸; d 为裂缝图像所包含的像素数量。将式(10)代入式(9),可得:

$$s = [(u-f)/f](D/d)h \quad (11)$$

由式(11)可知,在统计出裂缝图像中裂缝的像素宽度后,即可实现裂缝病害的实际尺寸测量。

将上述研究成果综合成桥梁表面裂缝检测算法。桥梁表面裂缝检测算法流程如图 12 所示。首先将采集到的桥梁表面裂缝图像进行预处理并制备成数据集;然后利用数据集训练、验证 Inception-ResNet 网络模型;最后将 Inception-ResNet 网络模型用于裂缝的提取、定位以及宽度测量。

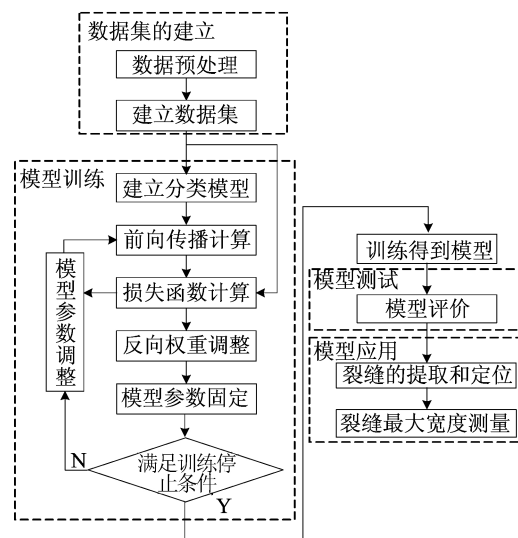


图 12 桥梁表面裂缝检测算法流程

本文提出的桥梁表面裂缝检测算法对裂缝图像的质量有如下要求:裂缝图像的光照要均匀,不能存在阴影;拍摄时相机需与结构表面保持垂直;拍摄时相机与结构表面的距离需保持在 25~35 cm。

从测试集中随机选取 200 张裂缝图像来验证本文算法对裂缝宽度测量的准确性,其中包括网状裂缝图像、斜裂缝图像、横向裂缝图像和竖向裂缝图像,如图 13 所示,验证结果见表 2 所列。




图 13 桥梁表面部分裂缝图像

表 2 实测裂缝宽度与算法计算裂缝宽度结果

| 裂缝模型 | 网状 | 斜 | 横向 | 竖向 |
|-----------|------|------|------|------|
| 实测裂缝宽度/mm | 0.86 | 0.83 | 0.52 | 0.65 |
| 计算裂缝宽度/mm | 0.92 | 0.88 | 0.55 | 0.69 |
| 误差值/mm | 0.06 | 0.05 | 0.03 | 0.04 |
| 相对误差/% | 6.98 | 6.02 | 5.77 | 6.15 |

200 张裂缝图像实测裂缝宽度与算法计算裂缝宽度的相对误差均值为 6.15%，相对误差最小值为 5.47%。本文所提算法对裂缝宽度的测量精度较高，能满足工程实际需要。当桥梁表面裂缝图像的质量达不到上述要求时，算法对裂缝宽度的测量存在精度下降、误差增加的现象。

5 结 论

本文针对在复杂背景条件下难以直接对桥梁表面裂缝进行检测的问题，提出一种基于 Inception 网络和残差网络(ResNet)的桥梁表面裂缝检测算法。经实验验证表明：

1) 本文提出的 Inception-ResNet 网络模型实现了桥梁裂缝面元和桥梁背景面元的精准分类，分类准确率超过 99%，且与 VGG 模型相比，Inception-ResNet 网络模型拥有更高的执行效率、更低的时间复杂度，更能满足桥梁裂缝检测实时处理的需求。

2) 本文所提算法利用 Inception-ResNet 网络模型分类结果，结合 xlwing、pandas 实现了裂缝区域在裂缝图像中的提取。

3) 算法运用 pandas，结合 Inception-ResNet 网络模型分类结果，得到了裂缝的四角点坐标，实现了桥梁表面裂缝图像中裂缝的定位。

4) 算法运用图像阈值分割技术和 OpenCV，得到像素意义上裂缝宽度，再结合相机成像原理，最终得到裂缝病害的宽度。与裂缝实测宽度对比，算法计算裂缝宽度的平均相对误差值为 6.15%，能满足工程实际需要。

5) 本文所提算法对桥梁表面裂缝图像的质量有严格的要求。当裂缝图像的质量达不到文中所述要求时，算法对裂缝宽度的测量存在精度下降、误差增加的现象，因此本文所提算法的鲁棒性还有待提高。

法研究[J]. 自动化学报, 2019, 45(9): 1727-1742.

- [2] 廖延娜, 豆丹阳. 基于 Mask RCNN 的桥梁裂缝检测方法设计及研究[J]. 应用光学, 2022, 43(1): 100-105, 118.
- [3] 余加勇, 李锋, 薛现凯, 等. 基于无人机及 Mask R-CNN 的桥梁结构裂缝智能识别[J]. 中国公路学报, 2021, 34(12): 80-90.
- [4] 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.
- [5] 谭国金, 欧吉, 艾永明, 等. 基于改进 DeepLabv3+ 模型的桥梁裂缝图像分割方法[J]. 吉林大学学报(工学版), 2024, 54(1): 173-179.
- [6] 杨杰文, 章光, 陈西江, 等. 基于深度学习的较复杂背景下桥梁裂缝检测[J]. 铁道科学与工程学报, 2020, 17(11): 2722-2728.
- [7] 张振海, 季坤, 党建武. 基于桥梁裂缝识别模型的桥梁裂缝病害识别方法[J]. 吉林大学学报(工学版), 2023, 53(5): 1418-1426.
- [8] 吴贺贺, 王安红, 王海东. 基于 Faster R-CNN 的隧道图像裂缝检测[J]. 太原科技大学学报, 2019, 40(3): 165-168.
- [9] JI J S, WU L J, CHEN Z C, et al. Automated pixel-level surface crack detection using U-Net[C]//International Conference on Multi-disciplinary Trends in Artificial Intelligence. [S.l. : s. n.], 2018: 69-78.
- [10] HINTONG E, SALAKHUTDINOV R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.
- [11] 邹俊志. 基于卷积神经网络的 RC 桥梁表面病害识别方法研究[D]. 重庆: 重庆交通大学, 2021.
- [12] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions[EB/OL]. (2014-09-17) [2023-01-31]. <https://doi.org/10.48550/arxiv.1409.4842>.
- [13] SCHMIDHUBER J. Deep learning in neural networks: an overview[J]. Neural Network, 2015, 61: 85-117.
- [14] SRIVASTAVA N, HINTON G E, KRIZHEVSKY A, et al. Dropout: a simple way to prevent neural networks from overfitting[J]. Journal of Machine Learning Research, 2014, 15(1): 1929-1958.
- [15] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[EB/OL]. (2015-12-10) [2023-01-31]. <https://doi.org/10.48550/arxiv.1512.03385>.
- [16] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2014-09-04) [2023-01-31]. <https://doi.org/10.48550/arxiv.1409.1556>.

(责任编辑 张 镛)

[参 考 文 献]

- [1] 李良福, 马卫飞, 李丽, 等. 基于深度学习的桥梁裂缝检测算