

基于深度学习的隧道病害图像检测

高新闻^{1,2}, 王龙坤¹

(1. 上海大学 机电工程与自动化学院, 上海 200444;

2. 上海大学 上海城建(集团)公司建筑产业化研究中心, 上海 201400)

摘要: 随着我国城市地铁的快速发展, 隧道的养护变得越来越重要, 传统的人工检测方法不仅效率低、成本高, 而且耗时, 已经不能满足当今的需求; 通过对越江隧道中的电缆通道的病害特征进行研究, 提出一种基于深度学习的隧道多病害检测的方法, 并提出了一种针对隧道病害检测的残差融合模块网络(Resfmnet), 利用深度学习网络提取图像病害特征并进行病害分类, 提高了病害的检测能力, 所使用的数据集是通过特种机器人在越江隧道中的电缆通道拍摄的视频获得; 实验结果表明所提出的网络显示出更高的准确性和泛化性, 对多病害的检测的精度 mAP 达到 0.891 4, 使得越江隧道检查和监控变得高效、低成本, 并最终实现自动化。

关键词: 越江隧道; 电缆通道; 隧道病害检测; 深度学习; 自动化

Image Detection of Disease in Cross-river Tunnel Based on Deep Learning

GAO Xinwen^{1,2}, WANG Longkun¹

(1. School of Mechanical and Electrical Engineering and Automation, Shanghai University, Shanghai 200444, China;

2. SHU-SUCG Research Centre of Building Information, Shanghai University, Shanghai 201400, China)

Abstract: With the rapid development of urban subways in our country, the maintenance of tunnels becomes more and more important. The traditional manual inspection methods are not only low in efficiency and high in cost, but also time-consuming, which can no longer meet today's needs. By studying the disease characteristics of the cable channel in the cross-river tunnel, a method for detecting multiple diseases in the tunnel based on deep learning is proposed, and a residual fusion module network (Resfmnet) for the detection of tunnel diseases is proposed, using deep learning the network extracts image disease features and performs disease classification, which improves the detection ability of diseases. In the cable channel of the cross-river tunnel, the data set is used to be obtained from the video taken by special robots; The experimental results show that the proposed network has higher accuracy and generalization, and the accuracy mAP of multi-disease detection reaches 0.891 4, which makes the inspection and monitoring of the cross-river tunnel more efficient and low-cost, and finally realizes automation.

Keywords: cross-river tunnel; cable channel; tunnel disease detection; deep learning; automation

0 引言

地铁是当今城市人民的主要公共交通基础设施, 在世界范围内有广泛的应用, 由于隧道在地下受到综合压力的作用会发生变形^[1-2], 严重时盾构隧道衬砌表面会出现渗漏、裂缝、腐蚀、缺损等病害^[3-4], 隧道内病害的出现对隧道的安全带来了巨大的安全隐

患, 比如, 裂缝的出现会引起隧道内的衬砌表面出现渗水、漏水, 渗水和漏水的出现会引起隧道内的钢结构出现电化学腐蚀, 电化学腐蚀进一步导致渗漏水的发生, 导致隧道内的病害出现恶性循环, 严重的影响了隧道的使用寿命和正常的运营。人工检测的方法, 具有较高的主观性, 并且随着视觉的疲劳会引起误检、漏检等, 这种主观性较强的检测方法是很低效

收稿日期: 2021-08-10; 修回日期: 2021-09-08。

作者简介: 高新闻(1975-), 男, 安徽桐城人, 博士, 讲师, 主要从事隧道病害检测方向的研究。

引用格式: 高新闻, 王龙坤. 基于深度学习的隧道病害图像检测[J]. 计算机测量与控制, 2022, 30(2): 58-64.

的,而且隧道中检测人员的安全也是一个需要考虑的问题。传统的基于视觉的方法来完成隧道病害的检测^[5-6];因此,人们开发了基于图像处理的半自动和全自动方法以促进隧道内的健康检测,机器人的应用减少了人工的干预并且提高了检测人员的安全性。此外隧道的照明条件较差,因此开发自动检测的方法变得尤为重要。

1 检测系统组成及检测方法原理

地铁隧道一般位于地下,其工作环境较差,而对于上海跨黄浦江的越江隧道,其工作环境恶劣,地下能够行走的空间狭小,光线微弱,空气尤为污浊。为此,本课题组设计了一种履带式巡检机器人进行地下隧道中结构病害的检测,该巡检机器人由履带式行走本体和激光扫描仪、拍摄隧道结构病害的运动相机、避障的红外传感器等组成。由于该巡检机器人工作环境中光照非常弱,导致拍摄的隧道视频质量具有较低的清晰度和较多的阴影,甚至拍摄的视频还具有一定的虚影。同时,由于本巡检车检测的越江隧道的结构衬砌由于工作年限比较长,在其表面很多地方都覆盖了一层修补的混凝土或环氧树脂,导致在该隧道中拍摄的视频具有较多的相似性,这为后期的高精度隧道结构病害自动检测带来了一定的困难。

本研究针对地下隧道的特殊环境设计了一种残差融合模块网络(Resfmnet);Resfmnet网络主要包括7个部分:1)特征提取网络resnet50用于提取隧道图像的特征;2)PFnet网络块,此网络块的作用是进行不同层次间的特征融合;3)RFB-F网络块,RFB-F网络块主要是为了针对隧道图像中具有模糊和阴影而设计的;4)TRI-T网络块用来检测不同尺度的目标;5)FPN模块,利用低层特征高分辨率和高层特征的高语义信息,通过融合这些不同层的特征达到预测的效果;6)分类模块(C模块),用来确定病害的类别信息;7)回归模块(C模块),用来确定病害的位置信息。本研究设计的Resfmnet网络的具体结构如图1所示。

2 相关研究

随着人工智能的发展,特别是深度学习在计算机视觉上的应用,为基于图像的目标检测提供了新的机遇,如今深度学习技术已经被应用于工程设施的检测和维护,而且被证明了是一种有效的方法^[7-8],深度

学习在图像分类^[9-10]、目标检测^[11]、语义分割^[7,12]等方面表出了较好的性能;近年来随着深度学习的发展,计算机视觉中的像素级语义分割得到迅速发展^[13-17]。高^[18]等人提出一种将DenseNet用于隧道裂缝的检测,该算法对隧道裂缝的分类取得了较好地效果,但是其检测方法偏向一种病害检测;Long^[22]等人首先提出了全卷积神经网络[FCN]进行语义分割,与普通的CNN相比,FCN可以接受任意大小的输入,通过高效的推理和学习输出相应大小的图像,FCN的应用已经解决了许多难题^[4,19-20];Ren^[21]等人提出了一种基于改进的深度全卷积神经网络,用于进行密集的像素级裂缝分割,提出的网络由骨干网络、扩张卷积、空间金字塔池化和跳接模块组成,提高了网络对裂缝的检测能力。

使用深度学习对地铁盾构隧道衬砌表面的病害进行识别可以分为3个主要目标:包括目标分类、目标检测和语义分割:目标分类是将图像中的物体进行类别划分,目标检测不仅要要将图像中的物体进行分类,而且还要确定物体的位置;由于要进行病害检测的一张图像上可能含有多种病害,而且需要对检测的病害进行分类和定位,以便于后期评估和检测人员的观察,而语义分割侧重于对每个像素进行分类。因此,本文将采用目标检测的方法,实现对隧道的病害检测。

本文主要研究对越江隧道中的电缆通道衬砌表面的多病害进行检测;越江隧道为了防止江水的灌入,在隧道的衬砌表面采取了防护措施,比如在隧道的表面覆盖了一层混凝土,受到隧道衬砌表面混凝土的影响,采集的图像中相似性特征较多;虽然开发的移动机器人能够提供光源,但是光源还是不足以提供足够的光照强度,拍摄的视频序列图像的清晰度相对较弱,并且部分图像中还具有阴影,大大增加了隧道病害检测的难度;由于越江隧道的电缆通道中没有轨道,我们需要自己铺设移动机器人的行驶路线,以保证移动机器人按照合理的路线行驶,机器人在隧道中行驶会出现一定的摆动,导致采集的视频具有一定量的虚影,也增加了对隧道病害的检测难度。因此,本文提出了一种新的网络结构来进行隧道多病害的检测与分类,以便于后期人员的维护,数据的采集是由自主开发的机器人获得。

3 检测方法

本文所提出的 Resfmnet 检测算法结构如图 1 所示。该算法主要包括 4 个部分：1) 特征提取网络 resnet50 用于提取隧道图像的特征；2) PFnet 网络块，此网络的作用是进行不同层次间的特征融合；3) RFB-F 网络块，RFB-F 网络块主要是为了针对隧道图像具有模糊和阴影而设计的；4) TRI-T 网络块用来检测不同尺度的目标。

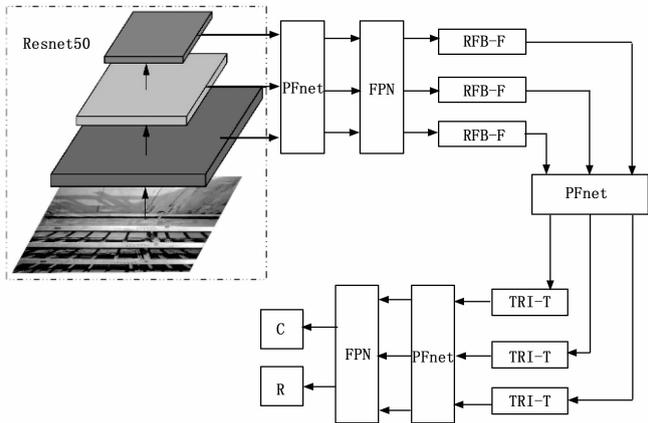


图 1 Resfmnet 检测算法网络结构图

3.1 数据集的采集和制作

本实验用到的数据集来自于上海的一条越江地铁隧道中的电缆通道，地铁隧道是一种位于地下的管状结构，一般光照环境较差，为了捕获越江隧道的衬砌表面的图像数据，自行开发一种移动机器人，机器人具有 3 个 Gopro 相机、1 个光源 (LED 灯)、1 个激光雷达、监视器、电池组成，使用的相机具有单线光敏传感器，为单色互补金属氧化物半导体 (CMOS)，静态有效像素 1 200 万，视频拍摄规格为 4 K。

移动机器人在隧道内以一定的速度行驶，设定拍摄视频时的帧率为 30 帧/s；在提取视频时以每 60 帧提取一张视频序列图像；总共提取出 1 961 张有病害的图像；由于训练数据集有限，减少图像数据过度拟合的一种常用方法是通过标签保留变换人为地扩大数据集。为了增加数据集的数量和考虑到光照强度的影响，因此，在本实验中对现有的数据集实施了数据增强，数据增强后总共获取 7 964 张病害图像，最终将训练数据集的图像数量与测试数据集的数量和验证集数据集的数量之比按 0.8 : 0.1 : 0.1 进行随机分配，训练集用于训练模型参数，验证集用以验证当前模型

泛化能力，而测试集用于评估最终模型的准确性。

3.2 模型的骨干网络

传统的 CNN 网络，如果只是简单的增加网络的深度，会导致梯度消失或梯度爆炸，对于梯度消失或爆炸的问题，我们一般采用正则化和 batch normalization 的方法，但是这种方法会引起梯度退化问题，即在训练集上准确率会出现过饱和甚至下降的情况，为了解决梯度退化的问题，引入了残差连接。Resnet 网络引入残差块来解决网络的梯度退化问题，深度残差网络能通过连接前面网络的特征，使得后面的网络能够学习到残差特征。

本节针对地铁盾构隧道的病害 (渗漏、裂缝、腐蚀、缺损) 构建网络架构；采用的深度学习架构是 keras，来完成这项任务；本文采用 resnet50 作为基线网络，如图 1 所示。

3.3 子模块网络的设计

在本节中我们选择了多尺度融合的思想，我们的思想是进行跨尺度的多级融合，利用低层次的特征可以检测小目标，但是低层次的语义信息较低，导致检测的准确性较低。而特征金字塔网络 [FPN] 通过自顶向下的过程和横向连接来解决低层次语义信息较低的问题，保持低层次特征有利于检测小目标而且能提高检测精度。为了能较好地融合不同层次的语义信息，在将骨干网络提取的特征 C_5 、 C_4 、 C_3 导入 FPN 网络之前先进行层级融合，受到单向信息流的限制，我们采用一个自底向上和跨尺度的连接来解决这个问题；在跨尺度融合之前先将不同尺度的特征图调整为相同大小的分辨率，然后对其进行求和，其次求和后的特征进行 1×1 的卷积，最后进行 3×3 的卷积，融合的方式如式 (1) ~ (6) 所示。具体的网络结构参考图 2。

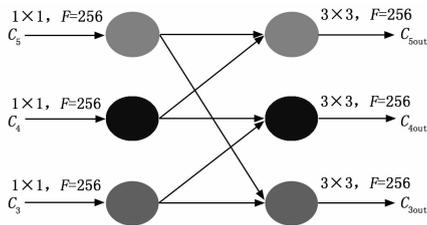


图 2 PFnet 网络的结构图

$$C_{5_1} = Conv_{1 \times 1}(C_5) \tag{1}$$

$$C_{4_1} = Conv_{1 \times 1}(C_4) \tag{2}$$

$$C_{3_1} = Conv_{1 \times 1}(C_3) \quad (3)$$

$$C_{5_{out}} = Conv_{3 \times 3}(C_{5_1} + C_{4_{1vp}}) \quad (4)$$

$$C_{4_{out}} = Conv_{3 \times 3}(C_{4_1} + C_{3_{1vp}}) \quad (5)$$

$$C_{3_{out}} = Conv_{3 \times 3}(C_{3_1} + C_{5_{1vp}}) \quad (6)$$

其中: C_5 、 C_4 、 C_3 代表上一级网络的输出即 Resnet 网络的输出, $C_{5_{1vp}}$ 、 $C_{4_{1vp}}$ 、 $C_{3_{1vp}}$ 代表 C_{5_1} 、 C_{4_1} 、 C_{3_1} 的上采样, $C_{5_{out}}$ 、 $C_{4_{out}}$ 、 $C_{3_{out}}$ 是 PFnet 网络的输出, $Conv_{1 \times 1}$ 、 $Conv_{3 \times 3}$ 分别代表 1×1 和 3×3 的卷积, F 代表通道数。

在隧道中由于光照强度非常弱, 需要为移动机器人提供光源, 但是人为提供的光源强度还是相对来说较弱, 甚至还由于遮挡物的干扰, 造成拍摄的视频中具有阴影。移动机器人在隧道中行驶会遇到障碍, 受到颠簸的移动机器人拍摄的视频具有一定的虚影, 为了更好地检测那些具有黑暗和低对比度的图像, 我们加入了 RFB-F 网络和 TRI-T 网络中, 在网络中加入了扩张卷积保持了网络的分辨率和感受野, 可以对病害的类别进行更准确的预测。图 3 是 RFB-F 网络结构图, 图 4 是 TRI-T 网络结构图, 其中 d 代表扩张率。

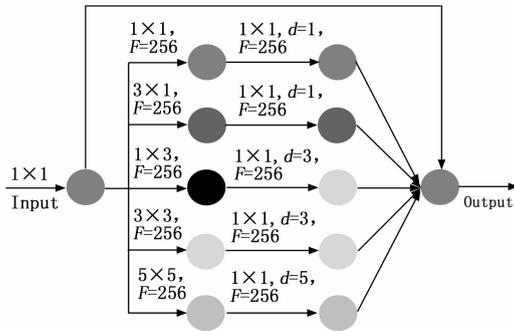


图 3 RFB-F 网络结构图

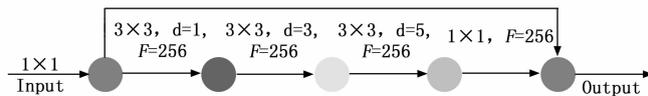


图 4 TRI-T 网络结构图

RFB-F 网络有 3 部分组成: 1) 用不同尺度的卷积核用来提取不同尺度的特征; 2) 对不同尺度的特征图进行扩张卷积; 从而用不同尺度的感受野来描述提取的特征; 3) 跳接块用来防止梯度消失, 解决了网络退化的问题。RFB-F 网络的公式如下:

$$Input_1 = Conv_{1 \times 1}(Input) \quad (7)$$

$$Output_1 = Conv_{1 \times 1, d=1} Conv_{1 \times 1}(Input_1) \quad (8)$$

$$Output_2 = Conv_{1 \times 1, d=1} Conv_{3 \times 3}(Input_1) \quad (9)$$

$$Output_3 = Conv_{1 \times 1, d=3} Conv_{1 \times 3}(Input_1) \quad (10)$$

$$Output_4 = Conv_{1 \times 1, d=3} Conv_{3 \times 3}(Input_1) \quad (11)$$

$$Output_5 = Conv_{1 \times 1, d=5} Conv_{5 \times 5}(Input_1) \quad (12)$$

$$Output = Conv_{1 \times 1}(Input_1 + Output_i) \quad (13)$$

其中: $Input$ 是上一级网络的输出即为 $\{C_{5_{out}}$ 、 $C_{4_{out}}$ 、 $C_{3_{out}}\}$ 中的任意一个, $Output$ 是 RFB-F 网络的输出, $Output_i$ ($i=1, 2, 3, 4, 5$) 是 RFB-F 网络的中间计算结果, $Output$ 是 RFB-F 网络的输出结果, F 代表通道数, d 代表扩张率。

TRI-T 网络有 2 部分组成: 1) 3×3 的卷积和不同大小的空洞卷积; 用于提高检测尺度的敏感性; 2) 跳接块用来防止梯度消失, 解决了网络退化的问题。TRI-T 网络的公式如下:

$$Input_1 = Conv_{1 \times 1}(Input) \quad (14)$$

$$Output_1 = Conv_{1 \times 1} Conv_{3 \times 3, d=j}(Input_1) \quad (15)$$

$$Output = Conv_{1 \times 1}(Input_1 + Output_1) \quad (16)$$

其中: $Input$ 是上一级网络的输出, $Output$ 是 TRI-T 网络的中间计算结果 $Conv_{1 \times 1}$ 代表 1×1 的卷积, $Conv_{3 \times 3, d=j}$ 代表了 3×3 的卷积, 其中 d 代表扩张率, $j = \{1, 3, 5\}$, F 代表通道数。

3.4 模型的训练

本文所采用的实验均在台式计算机上实现, 其详细的参数为: 1 个 Intel core i7-4790@3.60 Hz CPU 8 核处理器, 1 个 16 GB RAM, 1 个 NVIDIA GTX1070 GPU 和 GPU 内存 8 G, 64 位系统类型。基于深度学习的算法中使用 GPU 进行训练网络, 并且部署了 CUDNN 深度神经网络库, 在 Resfmnet 网络中, 将多尺度特征进行融合对目标进行准确的识别和定位, 在本实验中设置训练轮次 Epoch=100。该算法的步骤为:

- 1) 随机初始化网络的权重;
- 2) 输入图像至 Resfmnet 并进行预测;
- 3) 计算预测值与标签值之间的差别;
- 4) 更新网络的权重 w^t :

$$w^{t+1} = w^t - \alpha \frac{\partial L}{\partial w} \quad (17)$$

其中: α 是学习率, L 是损失函数, 代表预测值与真实值之间的差别, w^t 表示 t 次迭代时的权重, 为了解决类别的不平衡问题我们选择了 Focal loss 损失函数:

$$L_p = -\alpha_i(1 - p_i)^\gamma \log(p_i) \quad (18)$$

其中： α_i 、 γ 是固定值， α_i 调节正负样本的比例， p_i 是不同类别的概率。最终将隧道的数据集运行在此深度学习网络上，经过多个轮次的调参之后，以最大化损失函数向全局最优的收敛，训练过程中的模型在每个 epoch 后保存，并监控最小损失值。然后在测试集上验证 Resfmnet 模型的准确性，并将具有最高准确性的模型保存为最终模型。

4 实验分析

在隧道运营过程中，隧道土建结构维护较为复杂，有着众多干扰，如图 5 所示，其主要有以下几种病害：裂缝、渗漏水、缺损、腐蚀、起壳、树脂修补和混凝土出现漏筋。在对本文做试验的越江隧道实际检查后发现，起壳、树脂修补和漏筋出现较少，因此本文主要对腐蚀、裂缝、缺损和渗漏 4 种病害进行检测，其中腐蚀病害的数量有 499 个，裂缝病害的数量有 1 760 个，缺损的数量有 1 306 个，渗漏的数量有 13 726 个。腐蚀占比为 0.028 8，裂缝占比为 0.101 8，缺损的占比为 0.075 5，渗漏的占比为 0.793 9；数据存在严重的不平衡现象。为了较好地评估网络的检测结果，根据目标检测的特性选取了一些评价指标。



图 5 隧道衬砌表面及影响识别的干扰物

4.1 评价指标

深度学习在评估模型的时候，经常会使用一些特定的评价指标，根据数据集的分布和侧重的效果选择不同的评价标准，一般的评价指标有 F1-score、AP 和 mAP。在多目标检测中一般选择 AP 和 mAP 作为评价指标。因此本文选择 AP 和 mAP 作为评价指标，用来综合评价本文模型检测结果的准确性。

$$P = \frac{TP}{TP + FP} \quad (19)$$

$$R = \frac{TP}{TP + FN} \quad (20)$$

$$AP = \int_0^1 PR dr \quad (21)$$

$$mAP = \frac{\sum_{p=1}^q AP_p}{q} \quad (22)$$

其中： TP 表示实际上是正样本，预测的结果也是正样本， FP 实际为正样本，预测结果为负样本， FN ：实际为负样本，预测结果为正样本， q 是隧道中病害的类别数量， P 是精确率， R 是召回率， AP 是每个类别的平均精确率， mAP 是检测的所有类别的平均精确率。

4.2 结果对比

表 1 列出了 Resfmnet 与 Retinanet 对比的评估指标对比结果。从表 1 可以看出 Resfmnet 的方法在各方面的指标均优于 Retinanet 的方法，Resfmnet 的 mAP 比 Retinanet 高出 0.064 6；说明了 Resfmnet 的方法更有利于提高隧道中病害的检测能力，与传统的网络相比本文的算法采用了模块化设计，而且每个模块都是单独的，可以根据实际需要进行更换或删除相关模块，从而大大方便了更换网络的效率。

表 1 算法指标对比

方法	基线	腐蚀 AP	裂缝 AP	缺损 AP	渗漏 AP	mAP
Retinanet	Resnet50	0.876 5	0.751 9	0.959 5	0.719 2	0.826 8
Resfmnet	Resnet50	0.981 9	0.778 2	0.984 5	0.817 3	0.891 4

表 2 检测算法对不同病害的误检率结果对比

方法	腐蚀	裂缝	缺损	渗漏	平均误检率
Retinanet	0.065	0.117	0.041 5	0.084	0.076 9
Resfmnet	0.028 1	0.062	0.016 5	0.06	0.041 7

表 2 显示了 Resfmnet 检测算法与 Retinanet 检测算法对不同病害的误检率结果对比，通过对比可以发现 Resfmnet 检测方法的平均误检率低于 Retinanet 方法，说明对于恶劣的隧道环境 Resfmnet 方法具有较好的表现性能。为了验证本文提出的方法的准确性，将 Resfmnet 与 Retinanet 的方法的检测结果进行对比，比较结果如图 6 所示，图 6 (a) 是漏水检测原图，图 6 (d) 是裂缝检测原图，从图 6 (b)、

(c) 漏水检测可以看出, Retinanet 方法检测的结果在同一个病害上出现了两个锚框, 而 Resfmnet 的方法只有一个锚框, 说明了 Resfmnet 的方法能有效地提高检测的准确率, 从而对同一病害进行有效的区分; 从图 6 (e)、(f) 可以看出, Retinanet 方法对病害的检测结果出现了漏检, 而 Resfmnet 的方法能有效地将病害检测出来, 说明了我们的方法对清晰度较低的图像或有阴影的图像, 甚至出现了模糊的图像, 仍然具有较好地检测效果。

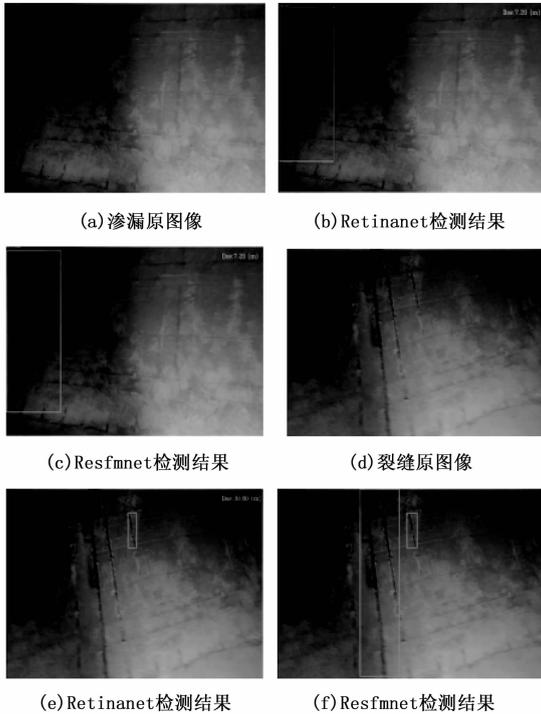


图 6 检测算法对不同病害的检测结果对比

5 结束语

本文提出了一种针对越江隧道衬砌病害快速识别的目标检测方法, 针对网络层次的加深出现饱和的问题, 提出了 PFnet 网络进行层级融合, 为了解决在隧道中拍摄视频时, 移动机器人的光照强度不足, 导致图像出现黑暗、对比度和亮度的微弱变化, 本文加入了 RFB-F 模块和 TRI-T 模块。通过对比 Resfmnet 与 Retinanet 的方法的检测结果, 验证了 Resfmnet 的方法具有较高的准确率。随着深度学习技术特别是目标检测技术的快速发展, 使得深度学习技术越来越多的应用到建筑领域的维护方面, 对于民用技术设施的检测和维护提供了强有力的技术支持。在隧

道检测领域深度学习技术被证明是一项可靠、安全的技术。

参考文献:

- [1] CAO Z, CHEN D, SHI Y, et al. A flexible architecture for extracting metro tunnel cross sections from terrestrial laser scanning point clouds [J]. Remote Sensing, 2019, 11 (3): 297.
- [2] STIROS S, KONTOGIANNI V. Mean deformation tensor and mean deformation ellipse of an excavated tunnel section [J]. International Journal of Rock Mechanics and Mining Sciences, 2009, 46 (8): 1306 - 1314.
- [3] YUAN Y, JIANG X, LIU X. Predictive maintenance of shield tunnels [J]. Tunnelling and Underground Space Technology, 2013, 38: 69 - 86.
- [4] HUANG H, LI Q, ZHANG D. Deep learning based image recognition for crack and leakage defects of metro shield tunnel [J]. Tunnelling and Underground Space Technology, 2018, 77: 166 - 176.
- [5] SASAMA H. Maintenance of railway facilities by continuously scanned image inspection [J]. Japanese Railway Engineering, 1994, 33 (2): 1 - 5.
- [6] UKAI M. Development of image processing technique for detection of tunnel wall deformation using continuously scanned image [J]. Quarterly Report of RTRI, 2000, 41 (3): 120 - 126.
- [7] MAKANTASIS K, PROTOPAPADAKIS E, DOULAMIS A, et al. Deep convolutional neural networks for efficient vision based tunnel inspection [C] //2015 IEEE International Conference on Intelligent Computer Communication and Processing (ICCP), IEEE, 2015: 335 - 342.
- [8] CHA Y J, CHOI W, BUYUKOZTURK O. Deep learning-based crack damage detection using convolutional neural networks [J]. Computer-Aided Civil and Infrastructure Engineering, 2017, 32 (5): 361 - 378.
- [9] MOLINA M, FRAU P, MARAVALL D. A collaborative approach for surface inspection using aerial robots and computer vision [J]. Sensors, 2018, 18 (3): 893.
- [10] PROTOPAPADAKIS E, DOULAMIS N. Image based approaches for tunnels' defects recognition via robotic inspectors [C] //International Symposium on Visual Computing, Springer, Cham, 2015: 706

- 716.

[11] EVERINGHAM M, VAN G L, WILLIAMS C K I, et al. The pascal visual object classes (voc) challenge [J]. International Journal of Computer Vision, 2010, 88 (2): 303 - 338.

[12] HUANG H, LI Q, ZHANG D. Deep learning based image recognition for crack and leakage defects of metro shield tunnel [J]. Tunnelling and Underground Space Technology, 2018, 77: 166 - 176.

[13] FARABET C, COUPRIE C, NAJMAN L, et al. Learning hierarchical features for scene labeling [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 35 (8): 1915 - 1929.

[14] ZHAO H, SHI J, QI X, et al. Pyramid scene parsing network [C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2881 - 2890.

[15] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation [C] //International Conference on Medical Image Computing and Computer - assisted Intervention, Springer, Cham, 2015: 234 - 241.

[16] HARIHARAN B, P ARBELÁEZ, GIRSHICK R, et al. Simultaneous detection and segmentation [C] // ECCV, 2014: 297 - 312.

[17] HARIHARAN B, P ARBELÁEZ, GIRSHICK R, et al. simultaneous detection and segmentation [C] //

European Conference on Computer Vision, Springer, Cham, 2014.

[18] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 3431 - 3440.

[19] 高新闻, 李帅青, 金邦洋. 基于 DenseNet 分类的隧道裂缝检测研究 [J]. 计算机测量与控制, 2020, 28 (8): 58 - 61.

[20] KRUTHIVENTI S S S, AYUSH K, BABU R V. Deepfix: a fully convolutional neural network for predicting human eye fixations [J]. IEEE Transactions on Image Processing, 2017, 26 (9): 4446 - 4456.

[21] YUAN Y, CHAO M, LO Y C. Automatic skin lesion segmentation using deep fully convolutional networks with Jaccard distance [J]. IEEE Transactions on Medical Imaging, 2017, 36 (9): 1876 - 1886.

[22] REN Y, HUANG J, HONG Z, et al. Image - based concrete crack detection in tunnels using deep fully convolutional networks [J]. Construction and Building Materials, 2020, 234: 117367.

[23] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 3431 - 3440.

(上接第 57 页)

[15] 陈 杰. 北京市水土保持行政管理问题及创新研究 [D]. 北京: 首都经济贸易大学, 2017.

[16] 谢永生. 中国黄土高原水土保持与农业可持续发展 [M]. 北京: 科学出版社, 2014.

[17] MIGABO E M, DJOUANI K D, KURIEN A M. The narrowband internet of things (NB - IoT) resources management performance state of art, challenges, and opportunities [J]. IEEE Access, 2020, 8 (2): 323 - 326.

[18] CHEN Y L, HUANG C C, ZHANG Y Z, et al. palae of lood events during the last deglaciation in the yellow river source area on the northeast tibetan plateau [J]. Geological Journal, 2021, 56 (8): 4293 - 4309.

[19] ANOUK H, REMLEY K A, JONES R D. et al. NB - IoT devices in reverberation chambers; a comprehensive uncertainty analysis [J]. International Journal of Microwave and Wireless Technologies, 2021, 13 (6): 561 - 568.

[20] MIKHAYLOV K, PETROV V, GUPTA R, et al. Energy efficiency of multi - radio massive machine - type communication (MR - MMTTC): applications, challenges, and solutions [J]. IEEE Commun. Mag. , 2019, 57 (8): 100 - 106.

[21] GAO X, WANG W, XIA X, et al. Cyclic prefixed OQAM - OFDM and its application to single - carrier FDMA [J]. IEEE Trans. Commen. , 2011, 59 (5): 1467 - 1480.