

基于机器视觉的桥梁裂缝识别方法研究

吴正思¹ 倪言希² 应旭永³

1. 福州市公路事业发展桥隧中心 福建福州 350001

2. 福州市公路事业发展桥隧中心 福建福州 350001

3. 苏交科集团股份有限公司 江苏南京 211112

摘要: 随着国内桥梁运营里程的增长与服役时间的推移,桥梁作为生命线工程的健康状态亟需关注。对桥梁进行服役性能的健康状态评估,及时监测并识别病害,对潜在的异常状况进行预警,具有重大的现实与经济价值。本文利用机器视觉技术,对混凝土桥梁中最常见的病害——裂缝进行图像识别,利用卷积神经网络算法对4000张裂缝图像进行识别训练,生成裂缝识别模型,实现对水平、竖直、斜向和交叉等多种类型裂缝的图像识别,识别结果准确率达90%以上,实现了病害智能识别的功能需求。

关键词: 桥梁健康监测; 机器视觉系统; 桥梁裂缝; 卷积神经网络; 图像识别

引言:

伴随着改革开放后经济的发展,中国桥梁建设发展迅速,桥梁数量不断攀升、规模持续扩大,逐渐成为世界第一桥梁大国。当今社会正在快速发展,在此背景下交通荷载引发的桥梁承载性能下降的情况日益普遍。因此实时对桥梁结构健康状态进行评估,评定桥梁服役期间的承载性能就显得尤其重要。

随着在役桥梁数目的增多和监测需求的不断增长,监测数据的理解和管理效率会产生很大的困难。传统的桥梁病害监测方法基本依赖人工巡检、人为判断病害,并且借助传统检测仪器,来测量病害几何特征。该方法易受到测试专业人员自身的技术和经验等人为主观因素的影响,且检测效率低下,难以适应现代桥梁结构健康状态评估监测数据多且杂的情况。

作者简介:

吴正思,1968年1月13日,男,汉,福建仙游,福州市公路事业发展桥隧中心,主任,高级工程师,本科,毕业院校:福州大学,研究方向:桥梁养护管理,邮箱:WZS55555@126.com;

倪言希1976年3月20日,男,汉,福建福州,福州市公路事业发展桥隧中心,副主任,高级工程师,本科,毕业院校:西安公路学院,研究方向:桥梁养护管理,邮箱:496408410@qq.com;

应旭永,1987年6月,男,汉,浙江台州,苏交科集团股份有限公司,副主任,高级工程师,博士,毕业院校:大连理工大学,研究方向:桥梁检测,邮箱:yxy612@jsti.com。

近年来,这个问题在现代机器视觉技术的支持之下得到了良好的改善。机器视觉是人工智能领域正在蓬勃发展的一个分支,简而言之就是用“机器眼”代替人眼采集所需图像,并自动对图像进行测量和判断。如今,机器视觉代替人工视觉进行测量和判断的能力一般通过深度学习获取。深度学习是一种基于大量样本数据的机器挖掘内在规律过程,它的最终目的是学习样本的内在规律,通过对所给文字、声音、图像、视频等数据信息进行理解,实现像人一样识别能力^[1]。桥梁健康状态评估的监测数据种类多,数据数量巨大,采用机器视觉技术能很好地适应大批量重复性工作^[2],加快数据处理速度,提高数据处理精度,使得桥梁健康状态评估工作发生了质的飞跃。

深度学习的概念起源于对人工神经网络的研究,并经过不断演化和发展^[3]。卷积神经网络(CNN)作为目前研究最热的神经网络,在图像识别中常常作为分类器使用^[4]。而SSD目标检测算法(Single Shot Multi-Box Detector)是当下检测速率较快且精确度较高的机器学习算法。SSD以VGG16作为基础模型,继承了YOLO的回归思想和Faster-RCNN中的方法,新增了卷积层来获得一系列的特征图以用来检测^[5]。

考虑到桥梁结构裂缝作为结构损伤最主要最普遍的形式之一,不断地危害着桥梁结构的健康状态,本文将探索利用Tensorflow深度学习框架(TensorFlow是由Google Brain团队开发,基于python的开源机器学习架构,于2015年11月首次发布),以卷积神经网络为基础的SSD目标检测算法框架对海量数据集训练,得到裂缝图

像识别模型, 用该模型对混凝土桥梁裂缝进行智能识别。

1 数据集的制备

由于没有公开的规模大且质量高的混凝土裂缝数据集, 本文采用了同课题组制备的数据集。该数据集裂缝图像主要来源于烈士河大桥、京桥运河特大桥和土木实验室破坏的混凝土梁, 照片的格式均为 .jpg, 分辨率均为 2448×3264 。采集图像时考虑了各种不同的环境条件, 对不同光照、不同角度或不同背景颜色等条件下的裂缝都进行了拍摄。

1.1 数据集制备的步骤

在工作目录新创建三个文件夹以存放数据集:

JPEGImages: 用于存放原始图像, 格式为 .jpg;

Annotations: 用于存放图像的标签, 文件格式为 .xml, 每个 .xml 文件都对应 JPEGImages 中的一张特定 .jpg 图像;

TFRecords: 用于存放 SSD 框架可识别文件, 格式为 .tfrecord, 它是一种二进制格式文件。

建完文件夹便可以开始制备数据集:

① 为了扩大数据集, 先对拍摄获取的图像进行分割, 水平和垂直方向分别十等分, 如图 1 所示, 然后选择含裂缝的“小图像”作为 .jpg 原始图像, 存放到 JPEGImages 文件夹中。




图 1 图像分割

② 使用 LabelImg 工具标记裂缝, 首先打开 JPEGImages 文件夹并选择某张原始图像, 接着对图像中的裂缝建立 Box 边框, 如图 2 所示, 然后输入标记的名称 (注意名称不能有中文), 这里用“ck”作为裂缝标记的名称, 最后保存生成 .xml 文件并将其保存至工作目录的 Annotations 文件夹中。对所有原始图像都执行此操作。

③ 由于 SSD 框架无法直接使用 .xml 文件, 所以需要生成 .tfrecord 文件, 格式转换代码可参考 <https://www.cnblogs.com/Allen-rg/p/10245729.html>。




图 2 标记裂缝

1.2 数据增强

数据增强也叫数据扩增, 旨在不增加同源数据量的情况下, 让现有的有效数据进行变化生成等价值的可使用数据, 进而使得数据量满足制作数据集的要求。使用深度学习方法的前提是有大规模、有效的数据集, 因此采用数据增强技术来扩充样本数据集。本文采用以下数据增强方法:

① 翻转

翻转的方法根据翻转的基准边分水平翻转和垂直翻转, 如图 3 所示。




(a) 原图 (b) 水平翻转 (c) 垂直翻转

图 3 数据增强 - 翻转

② 随机旋转

如图 4 所示。




(a) 原图 (b) 顺时针旋转 45° (c) 顺时针旋转 90°

图 4 数据增强 - 随机旋转

③ 随机缩放

如图 5 所示。




(a) 原图 (b) 缩小 (c) 放大

图 5 数据增强 - 随机缩放

④变形

如图6所示。



(a) 原图 (b) 压缩 (c) 拉伸

图6 数据增强-变形

前文采用的图像分割方法实际上也是数据增强的一种方式。这里将数据按照比例分配为训练集、验证集、测试集，数据增强只针对训练数据进行数据扩增，验证和测试数据不做处理。最后生成的混凝土裂缝数据集包含5000张图像，选择其中4000张为训练集，500张为验证集，500张为测试集。训练集用来训练模型，验证集用来验证模型是否过拟合，测试集用来测试模型的准确程度。

2 训练模型

本文基于python语言使用Tensorflow环境运行裂缝图像分类器。TensorFlow是一个开源的、基于Python的机器学习框架，是目前最热门的机器学习框架。

2.1 训练超参数设定

①学习率

学习率是指在优化算法中更新网络权重的幅度大小，其决定着损失函数能否收敛到局部最小值以及何时收敛到局部最小值。当学习率取值过小时，计算收敛进行得十分缓慢且需要耗费大量计算资源；而当学习率设定得过大时，梯度可能会在最小值附近来回震荡，甚至可能无法收敛，可见学习率的设置对于模型训练效果的影响是十分显著的。

此次训练设定的初始学习率=0.01。

②批次大小 (Batch Size)

批次大小 (Batch Size) 指单次训练所需要的样本数。在没有使用批次大小之前，都是一次性将所有数据输入网络进行训练，由于在计算梯度时使用了整个训练集，所以得到梯度方向更为准确，但是使用全局数据集进行计算所得到的梯度值存在着巨大的差异，难以得出一个统一的、全局的学习率，而且虽然批次大小设定为较大值时，可以使训练时间缩短和收敛更快，但是由于计算机内存的限制，过大的批次值会导致程序内核崩溃。

本训练过程的 Batch Size=4。

③动量优化值

随机梯度下降速度一般较慢，因此需要加入动量来加快收敛。采用带动量的随机梯度下降法可以使得模型

训练的效果提高，得出更好的最优解，即模型收敛后会有更高的准确性。

本训练过程的动量优化值=0.9。

④迭代次数

迭代次数是指将训练集输入到神经网络后进行训练的次数，迭代次数影响着训练的精度大小，随着迭代次数的不断增大，训练模型识别数据内在规律的准确性也在不断提高。当测试错误率和训练错误率的值比较接近时，可认为当前两者相差较小迭代次数符合要求；当测试错误率先变小后变大时则说明迭代次数过大了，需要减小迭代次数，否则容易出现过拟合。

本训练过程的迭代次数=50000。

⑤激活函数

此次训练过程的激活函数选取Relu函数。Relu是对矩阵元素（图像像素）的操作，将卷积特征图中的所有负的像素值替换为零。由于现实世界的大部分数据都是非线性的，因此我们通过引入诸如Relu之类的非线性激活函数来解决非线性问题。

2.2 训练过程

迭代训练如图7所示。



图7 迭代训练

经过50000次迭代，损失函数趋于收敛，损失函数的值逐渐稳定在4.5左右，收敛过程可见图8。



图8 损失函数迭代曲线

3 识别测试

3.1 评价指标

一般用精确率、召回率和IoU等指标对图像识别的效果进行评价^[6]。

①精确率 (Precision)

True positives (TP): 实际为裂缝且被识别为裂缝的样本数;

False positives (FP): 实际非裂缝且被识别为裂缝的样本数;

True negatives (TN): 实际非裂缝且被识别为非裂缝的样本数;

False negatives (FN): 实际为裂缝却被识别为非裂缝的样本数。

$$precision = \frac{TP}{TP + FP} \times 100\% \quad (1)$$

②召回率 (Recall)

$$recall = \frac{TP}{TP + FN} \times 100\% \quad (2)$$

③交并比 (IoU)

SSD目标检测算法的输出结果是带有标签和概率的标记框。IoU表示识别结果标记框 (Candidate Bound) 与真实目标标记框 (Ground Truth Bound) 的交集与它们的并集的比值, 如图9所示。

$$IoU = \frac{area(C) \cap area(G)}{area(C) \cup area(G)} \quad (3)$$





图9 交并比 (IoU)

3.2 裂缝识别


采用滑动窗口对测试集图像进行分割, 将图像分割成 20×20 份, 每张小图像尺寸控制相同, 图像的像素设定为 120×120 。在目标识别过程中, 取阈值为0.5, 只有IoU大于阈值时目标才能被正确识别并标记。本文对水平裂缝、竖直裂缝、斜裂缝和交叉裂缝等各种裂缝进行了识别测试, 识别结果如图10所示。




(a) 水平裂缝




(b) 竖直裂缝



(c) 斜裂缝



(d) 交叉裂缝



(e) 局部放大图

图10 识别结果

由局部放大图可以看到识别出来的裂缝被带标签和概率的标记框所圈出, 很直观地显示了图像中哪些部分是裂缝。识别效果总体较好, 但是仍有实际为裂缝却没被标记出来或者实际不是裂缝却被标记出来的情况。本文采用精确率和召回率两个指标对识别效果进行评价, 如表1所示。

表1 精确率和召回率

裂缝分类	TP/ (TP+FP)	精确率 (%)	TP/ (TP+FN)	召回率 (%)
水平裂缝	82/ (82+4)	95.3%	82/ (82+6)	93.2%
竖直裂缝	77/ (77+3)	96.3%	77/ (77+7)	91.7%
斜裂缝	81/ (81+9)	90.0%	81/ (81+13)	86.2%
交叉裂缝	90/ (90+5)	94.7%	90/ (90+5)	94.7%

可以看到对于不同类型的裂缝, 识别的精确率都在90%以上, 召回率都在85%以上, 机器视觉很好地代替了人工视觉进行分类。另外, 本文还对识别速度进行了统计, 识别50张测试集图像共耗时17.42秒, 平均每秒识别2.87张裂缝图像, 机器视觉的识别效率明显优于人工视觉。

4 结论

本文首先实现了数据集的制备: 介绍了数据集制备的步骤, 实现了数据集格式从.jpg格式→.xml格式→.tfrecord格式的转换, 并且介绍了数据增强方法并用其扩充裂缝图像数据集以达到良好训练效果。接下来训练模型: 首先对神经网络训练的各项超参数(学习率、批次大小、动量优化值、迭代次数和激活函数等)进行了合理的设置, 使用Tensorflow环境对输入的训练集图像进行迭代运算, 经过50000次迭代后, 损失函数收敛于4.5附近。最后进行识别测试: 用训练得到的模型对水平裂缝、竖直裂缝、斜裂缝和交叉裂缝等各种类型的裂缝进行识别测试, 识别的精确率均在90%以上, 识别精度满

足要求, 召回率均在85%以上, 识别速度达到了每秒2.87张, 识别获得了很好的效果。

参考文献:

- [1]夏长林.深度学习在图像识别中的应用[J].电脑识与技术, 2019, 15(33): 185-186.
- [2]覃仁超.基于机器视觉的图像识别技术应用[J].电气时代, 2006, (2): 7-9.
- [3]刘曙光.人工神经网络基本特征与思维能力[J].自然辩证法研究, 1996, (4): 6-9.
- [4]胡貌男, 邱康, 谢本亮.基于改进卷积神经网络的图像分类方法[J].通信技术, 2018, 51(11): 72-78.
- [5]陈幻杰, 王琦琦, 杨国威等.多尺度卷积特征融合的SSD目标检测算法[J].计算机科学与探索, 2019, 13(6): 1049-1061.
- [6]马天娇.基于机器视觉的缺陷检测与识别方法研究[D]: 硕士学位论文.中国科学院大学(中国科学院长春光学精密机械与物理研究所), 2018.