

DOI: 10.11835/j.issn.2096-6717.2022.115



开放科学(资源服务)标识码 OSID:



# 基于轻量化卷积神经网络的桥梁斜拉索 PE 护套 损伤识别方法

刘啸宇<sup>1,2</sup>, 黄永<sup>2</sup>, 徐峰<sup>1</sup>, 李惠<sup>2</sup>

(1. 上海交通大学 船舶海洋与建筑工程学院, 上海 200240; 2. 哈尔滨工业大学 土木工程学院, 哈尔滨 150090)

**摘要:**深度神经网络和计算机视觉技术近年来在结构健康监测中发挥了越来越重要的作用。利用无人机航拍采集的桥梁斜拉索损伤图像数据,研究基于深度学习技术的斜拉索 PE 护套损伤识别方法。为实现在较低运算能力设备上对大跨度桥梁斜拉索表面局部损伤的智能快速识别,解决传统深度卷积神经网络的运算效率相对较低、模型参数规模较大的问题,提出轻量化处理的区域推荐型卷积神经网络模型。介绍区域推荐网络与其轻量化改进方法的理论基础,分析轻量化模型处理的必要性,其能在保证识别精度的前提下降低模型训练与预测的设备性能需求,达到节约计算资源与时间的目的;通过数据增广等手段解决损伤样本数据量不足的问题,设置对比试验,统计分析结果,验证了轻量化神经网络模型的优越性。结果表明,轻量化网络在牺牲少量识别准确度的前提下,能够在较大程度上实现对模型复杂度与计算量的改进,在工程应用中能有效拓展神经网络的实用性。

**关键词:**桥梁斜拉索;智能损伤识别;轻量化神经网络;计算机视觉;深度学习

**中图分类号:** TU997 **文献标志码:** A **文章编号:** 2096-6717(2025)01-0167-12

## Damage identification method of PE sheath of bridge stay cable based on lightweight convolutional neural network

LIU Xiaoyu<sup>1,2</sup>, HUANG Yong<sup>2</sup>, XU Feng<sup>1</sup>, LI Hui<sup>2</sup>

(1. School of Naval Architecture, Ocean and Civil Engineering, Shanghai Jiao Tong University, Shanghai, 200240, P. R. China; 2. School of Civil Engineering, Harbin Institute of Technology, Harbin 150090, P. R. China)

**Abstract:** In recent years, deep neural network and computer vision techniques have played an increasingly important role in structural health monitoring. In this paper, deep learning technology is used to identify the PE sheath damage through the image data of bridge stay cable damage collected by UAV. This paper aims to realize the intelligent and rapid identification of local damage on the surface of stay cables of long-span bridges on devices with low computational ability, and to solve the problems of relatively low computational efficiency and large scale of model parameters in the current research of traditional deep convolution neural network. A

**收稿日期:** 2022-07-07

**基金项目:** 国家重点研发计划(2021YFF0501003)

**作者简介:** 刘啸宇(1998-), 男, 主要从事结构健康监测研究, E-mail: liuxiaoyu\_sjtu@sjtu.edu.cn。

黄永(通信作者), 男, 教授, 博士生导师, E-mail: huangyong@hit.edu.cn。

**Received:** 2022-07-07

**Foundation item:** National Key Research and Development Program (No. 2021YFF0501003)

**Author brief:** LIU Xiaoyu (1998-), main research interest: structure health monitoring, E-mail: liuxiaoyu\_sjtu@sjtu.edu.cn.

HUANG Yong (corresponding author), PhD, professor, doctoral supervisor, E-mail: huangyong@hit.edu.cn.

lightweight region proposal convolution neural network model is proposed. Firstly, the theoretical basis of region proposal network and its lightweight improvement method is introduced, and the necessity of lightweight model processing is analyzed. It reduces the performance requirements of devices for model training and prediction under the premise of ensuring identification accuracy, achieving the purpose of saving computational resources and time. Secondly, the problem of insufficient data of damage samples is solved by multiple means of data augmentation. The contrast experiment and the analysis of statistical results verify the superiority of the lightweight neural network model. The results show that the lightweight network can improve the complexity and quantity of calculation of the model to a large extent under the premise of a small sacrifice of recognition accuracy. It effectively expands the practicability of the neural network in engineering applications.

**Keywords:** bridge stay cable; intelligent damage identification; lightweight neural network; computer vision; deep learning

近年来,随着桥梁基础设施建设迅速发展,结构安全问题时有发生。结构发生损伤后,若不能及时发现,极有可能造成重大安全事故,所以建立可靠的结构检测和监测系统对延长桥梁工程结构使用寿命和减小损失具有重大意义。计算机视觉和深度学习技术近年来在结构检测和健康监测领域中受到大量关注,取得了很好的进展<sup>[1-3]</sup>。但当前研究大多集中于提升损伤检测的准确性,而少有研究对嵌入式设备与移动设备的运算能力、内存空间进行改进。

以图像进行结构检测的相关研究中,被广泛采用的是深度卷积神经网络<sup>[4-5]</sup>,然而,对于传统的深度卷积神经网络而言,最突出的问题是模型参数量过于庞大,在实际应用中面临着设备内存可能不足的问题;其次,在多类实际应用场景下,存在低延迟,或者响应速度快的需求<sup>[6]</sup>。所以,研究轻量而高效的深度卷积网络模型至关重要。

对于基于计算机视觉的工程结构检测和监测,目前研究者很少考虑深度神经网络模型的复杂度与运算量,训练与识别大多以办公主机端为载体,没有为结构检测和监测现场设备提供实时低运算方法。虽然有研究已经实现了对桥梁的实时监测,但其计算性能仍然依赖于地面端上位机<sup>[7]</sup>,若模型性能需求过高,将进一步提高工程监测成本,限制模型的可应用性。也有研究以传感器或传统图像识别完成实时桥梁结构监测,存在传感器成本较高或抗干扰能力较差等问题<sup>[8]</sup>。卷积神经网络以大数据与深度学习为支撑,具有较强的泛用性和复杂背景适应性,但多篇文献提到,在传统卷积神经网络中训练过程耗时较长。文献综述<sup>[9]</sup>指出,普通的卷积神经网络在大型数据集中训练时间可达到80 h。文献<sup>[5]</sup>提到,即便只有400个训练样本,其训练过程耗时也可达到8~10 h。如此庞大的运算量,时间成本较高,低运算能力设备可能难以胜任。

笔者将对针对此类问题,从计算机视觉和深度学习技术较少关注的大跨度桥梁斜拉索PE护套损伤识别问题出发,针对现场结构非均质背景的强干扰下、由无人机采集的斜拉索表面损伤图像,在嵌入式设备与移动设备上运行轻量化的区域推荐型卷积神经网络对损伤进行识别。旨在保证识别准确率的前提下,降低模型所需要的运算能力与内存占用,使深度神经网络模型能够在运算能力相对较低、内存空间相对较小的嵌入式设备与移动设备上自主训练与预测,达到通过低运算能力设备实现工程结构损伤实时检测与识别的目标。

## 1 轻量化卷积神经网络构建

### 1.1 区域推荐型卷积神经网络

考虑桥梁斜拉索损伤样本的特性问题,选取区域推荐型卷积神经网络针对性地完成对损伤目标的智能检测。该方法相比其他目标检测方法具有明显优势。如,以YOLO<sup>[10]</sup>为代表的单阶段方法(One-stage Approach)虽然在多次迭代升级后,在标准数据集上具备较好的检测性能,但由于其架构特性,容易产生过量负样本,从而导致前景与背景类别不均衡,最终导致在特定数据集下的性能表现不佳<sup>[11]</sup>。而在本研究中,桥梁斜拉索PE套的损伤不显著且数量较少,负样本过多将进一步产生不利影响。因此,若使用目前性能更优的YOLO等单阶段方法,模型将难以避免结构性劣势。另外,以区域推荐型卷积神经网络为代表的两阶段法(Two-stage Approach)采用先生成候选框,再进行分类与回归的分步方法。其相比于YOLO等单阶段方法避免了负样本过多的问题,契合本研究所使用的斜拉索PE护套样本特征,能够有效发挥模型效能。在实际应用中,得益于两阶段方法的优势,在同一条件下其准确率也往往更高<sup>[12]</sup>。此外,相比于Mask RCNN<sup>[13]</sup>等实例分割网络,省去了掩码分支和

过多的全连接层等复杂结构<sup>[14]</sup>即可以达到检测目的,节约了大量计算资源。

从斜拉索样本特征进行分析,矩形候选区域生成机制的特性契合了斜拉索二维平面形状在整幅图像中的面积占比相对较小的实际情况,以多尺度的矩形参考框(Anchors)在图像矩阵上的滑动完成对斜拉索 PE 护套的损伤定位,充分发挥了以矩形边界框进行目标检测的计算简便优势<sup>[15]</sup>。样本特征与方法特性具备高匹配度,最终形成高效的注意力集中机制。

在两阶段方法的结构性优势基础上,区域推荐型卷积神经网络将注意力机制与目标检测相结合,能够快速确定感兴趣区域。区域推荐网络模块(Region Proposal Networks, RPN)通过生成约 2 000 个矩形候选区域,大概率包含待检测目标,能够提供候选对象,便于后续网络模块进行目标定位<sup>[16-18]</sup>。

研究中,独立的区域推荐网络模块与普通的卷积神经网络结构类似,包含卷积、激活、池化层和全连接层。该模块通过成组的卷积、激活、池化操作以后,最终通过全连接层同时输出分类和回归两类目标函数的运算结果,在输出包含待检测目标的矩形定位框的同时,判断候选矩形区域有无损伤。在此过程中,模块的分类层最终输出一个包含 2 个元素的一维数组,分别对应候选矩形框内前景概率(包含目标概率)与背景概率,用以确定候选区域包含待检测损伤对象的可能性;RPN 的回归层输出一个包含 4 个元素的一维数组。总而言之,区域推荐网络模块 RPN 仅用于确定所建议的若干矩形区域是否大概率囊括损伤目标,用于后续模型训练<sup>[19]</sup>。

文献[18]将区域推荐型卷积神经网络总结为一个独立且统一的目标检测网络,RPN 模块为此网络提供“注意力集中”的作用,其工作机制总结如图 1 所示。可以将其分为 4 步:1)特征提取。使用由成组的卷积、激活、池化层(Conv & ReLU & Pooling Layers)构成的特征提取模块(Extractor)提取输入图像(Input Image)的特征图(Feature Maps)。该特征图作为一个共享模块,同时用于后续全连接层和 RPN 层。2)区域推荐。RPN 模块用于生成候选区域(Proposals)。该层通过分类层 softmax 函数判断参考框(Anchors)属于待检测目标还是背景,再利用其中的边界框回归方法(Bounding Box Regression)修正参考框获得精确的候选区域。3)感兴趣区域池化(RoI Pooling)。该层同时接收输入的特征图和候选区域,综合两者后输出候选区域特征图(Proposal Feature Maps),送入后续 softmax 全连接层,根据输出判定目标类别。4)分类。利用前层输

入的候选区域特征图通过全连接层得到候选区域的类别,同时再次使用边界框回归获得检测框最终的精确位置。

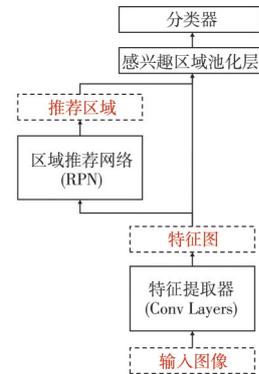


图 1 区域推荐网络模块工作机制示意图

Fig.1 Region proposal network working mechanism

本网络的目标损失函数  $L(p_i, t_i)$  由分类损失与回归损失构成,表达式为

$$L(p_i, t_i) = \frac{1}{N_{\text{cls}}} \sum_i L_{\text{cls}}(p_i, p_i^*) + \lambda \frac{1}{N_{\text{reg}}} \sum_i p_i^* L_{\text{reg}}(t_i, t_i^*) \quad (1)$$

式中:  $p_i, p_i^*$  分别为参考框的预测与真实分类概率;  $t_i, t_i^*$  分别为预测与真实边界框坐标;  $N_{\text{cls}}$  为每一批训练的规模(batch size);  $N_{\text{reg}}$  为边界框数量;  $L_{\text{cls}}$  指使用 softmax 函数进行分类;  $L_{\text{reg}}$  指使用 Smooth L1 函数进行回归;  $\lambda$  为权重平衡参数。其  $p_i^* L_{\text{cls}}$  表示只有在正样本时回归边界框坐标,即:在正样本时计算分类与回归损失之和,在负样本时计算回归损失无意义,故仅计算分类损失。

在实际工程中,首先需要判断结构有无损伤,进而细化判断结构损伤区域与类型。因此,基于深度卷积网络的 softmax 分类层,建立先判断结构有无损伤、再判断其损伤类型的方法流程。

待预测图像输入深度卷积神经网络后,输出层同时进行分类与回归。其中回归层负责矩形框的生成与定位,分类层采用 softmax 函数计算各类别的置信概率。对于斜拉索 PE 保护层损伤识别问题,虽然一共有 2 类损伤目标(螺旋线损伤、非螺旋线损伤),但实际分类时包含背景层,共涉及 3 类。经过 softmax 分类层输出后,得到 3 类目标的置信概率分别为  $a\%、b\%、(1-a-b)\%$ 。设置阈值  $X\%$ ,若 3 类目标中任意目标的置信概率均小于  $X\%$ ,则认为该区域无损伤;反之,若 2 类损伤目标中存在目标的置信概率大于  $X\%$ ,则认为该区域有损伤,且输出最大置信概率与相应的损伤类型。判断流程如图 2 所示。

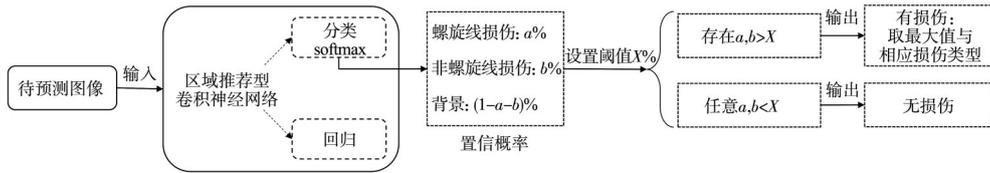


图 2 判断斜拉索 PE 护套有无损伤与损伤类型的流程图

Fig. 2 Flow chart for determining the presence or absence of damage and the type of damage

1.2 区域推荐型卷积神经网络的轻量化处理方法

在区域推荐型卷积神经网络中,多层的网络结构会包含大量的参数,尤其是来自卷积层的参数,其数量在全部参数中占比极高<sup>[20]</sup>。已有研究指出<sup>[21]</sup>,卷积神经网络仅需很少一部分参数即可准确地预测结果。如果不对其结构进行优化,卷积过程中存在冗余信息较多,那么计算机需要较大的存储空间和运行空间来完成模型训练和预测任务。此外,传统形式的卷积过程计算相对复杂,文献[20]提到,在一些网络结构中,仅卷积层的计算量甚至能达到总计算量的 97%,这说明传统卷积操作具备一定的优化空间。

轻量化网络能够在有限的网络模型参数量和运算能力条件下,对给定的一个网络在保证其精度的情况下进行有效压缩<sup>[22]</sup>。笔者在 MobileNet 方法的基础上<sup>[23-24]</sup>,提出对区域推荐型卷积神经网络的模型轻量化方法,相比文献[18]提出的 Faster-RCNN 网络运算效率更高,如图 3 所示。

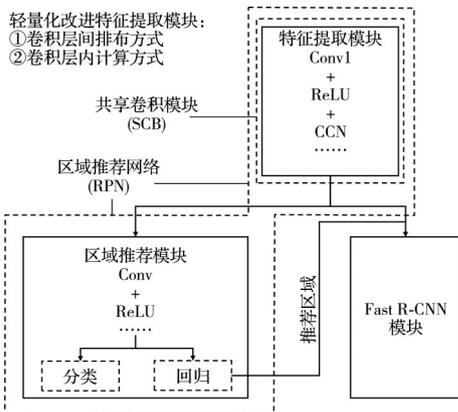


图 3 区域推荐型卷积神经网络中轻量化处理示意图

Fig. 3 Lightweight disposal in region proposal convolutional neural network

1.2.1 基于 MobileNet 方法的模型计算量改进

MobileNet 将传统卷积(PointWise)替换为深度可分离卷积(DepthWise,如图 4),在卷积过程中可减少计算次数,大大降低模型训练的计算量<sup>[23]</sup>。

假设输入的特征映射卷积核  $F$  尺寸为  $(D_F, D_F, M)$ ,采用的标准卷积核  $K$  的尺寸为  $(D_K, D_K, M, N)$ ,输出的特征映射卷积核  $G$  的尺寸为  $(D_G, D_G, N)$ 。单次标准卷积的计算公式为

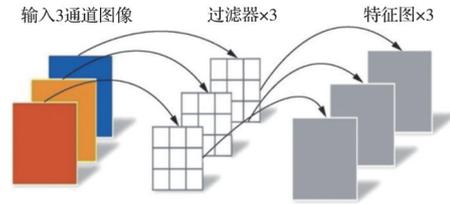


图 4 深度可分离卷积的运算过程示意图

Fig. 4 Operation process of DepthWise convolution

$$G_{k,l,n} = \sum_{i,j,k} K_{i,j,m,n} \cdot F_{k+i-1,l+j-1,m} \quad (2)$$

式中:  $K_{i,j,m,n}$  为第  $n$  个大小为  $(i,j,m)$  的卷积核以滑动窗的方式对大小为  $(k,l,m)$  的输入特征图  $F_{k+i-1,l+j-1,m}$  进行卷积,输出特征图  $G$  的第  $n$  个通道。即如果输入的通道数为  $M$ ,输出的通道数为  $N$ ,对应这一次标准卷积的理论计算量为:  $\Omega_1 = D_K \cdot D_K \cdot M \cdot N \cdot D_F \cdot D_F$ 。可将标准卷积  $(D_K, D_K, M, N)$  拆分为深度卷积和逐点卷积:深度卷积起滤波效果,卷积核尺寸为  $(D_K, D_K, 1, M)$ ;逐点卷积起转换通道的效果,卷积核尺寸为  $(1, 1, M, N)$ 。

深度卷积的计算公式为

$$\hat{G}_{k,l,n} = \sum_{i,j} \hat{K}_{i,j,m} \cdot F_{k+i-1,l+j-1,m} \quad (3)$$

式中:  $\hat{K}$  是深度卷积,其他下标含义同式(2)。卷积核为  $(D_K, D_K, 1, M)$ ,其中  $m_{th}$  个卷积核应用在  $F$  的第  $m_{th}$  个通道上,产生  $\hat{G}$  上第  $m_{th}$  个通道输出。此时深度卷积与逐点卷积计算量之和为:  $\Omega_2 = D_K \cdot D_K \cdot M \cdot D_F \cdot D_F + M \cdot N \cdot D_K \cdot D_K$ 。深度可分离卷积与普通卷积计算量之比为

$$\rho = \frac{\Omega_1}{\Omega_2} = \frac{D_K \cdot D_K \cdot M \cdot D_F \cdot D_F + M \cdot N \cdot D_K \cdot D_K}{D_K \cdot D_K \cdot M \cdot N \cdot D_F \cdot D_F} = \frac{1}{N} + \frac{1}{D_F^2} \quad (4)$$

若设置卷积核尺寸  $D_F$  为  $3 \times 3$ ,由式(4)可得出普通卷积计算量是深度可分离卷积的 8~9 倍。

1.2.2 基于 MobileNet 方法的模型参数规模改进

MobileNet 引入倒残差结构(Inverted Residual Block)与线性瓶颈激活层(Linear Bottlenecks),如图 5<sup>[24]</sup>所示。其残差(Residual Block)的概念首先出现在文献[25]中,最初目的是用于增加特征矩阵的维度,从而加大网络的训练深度,以达到更好的训练效果。

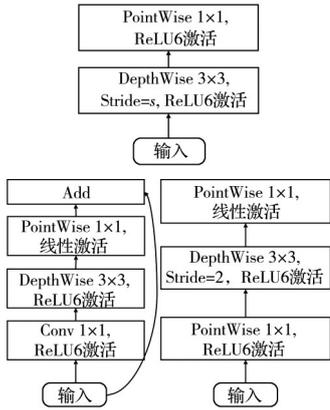


图 5 模型参数规模改进方法

Fig. 5 Method of model parameter scale improvement

倒残差结构通过先升维再降维的操作,增强梯度的传播,避免在深度网络中的梯度弥散或爆炸问题;线性瓶颈激活层通过将 ReLU6 函数激活层的非线性激活改进为 ReLU 函数线性激活,普通 DW 卷积操作中使用 ReLU6 函数的方式如图 5(a)所示,经过改进后如图 5(b)所示,使模型在低精度计算时具有更强的鲁棒性,同时保留特征多样性,增强网络的表达能力,改善了非线性激活层在低维时的特征丢失问题。对于低维特征丢失问题,可以理解为:ReLU 激活层对于负的输入,全部输出为零;而特征信息已经被“压缩”,若再经过 ReLU 线性激活,将加剧特征的损失,不采用 ReLU 函数进行激活。

## 2 基于轻量化卷积神经网络的斜拉索 PE 护套损伤识别

### 2.1 斜拉索表面图像数据预处理

#### 2.1.1 大尺寸样本图像预处理

基于武汉天兴洲大桥斜拉索无人机航拍图像进行研究<sup>[26]</sup>,由于桥梁斜拉索具有大跨度的特性,搭载的拍摄设备通常需要具备较高的分辨率。最初获得的斜拉索数据集为 8 K (约 8 000×5 300) 分辨率的大尺寸图像。

而在深度卷积神经网络中,输入图像样本的分辨率不能过大。即便是内存为 16 G 的较高性能主机端也难以在卷积运算中多次堆叠分辨率为 8 K 的大尺寸图像矩阵。受限于区域推荐型卷积神经网络的工作机制,不宜向其输入尺寸过大的图像<sup>[27]</sup>。因而,需要对大尺寸样本图像做切割处理。由于斜拉索轴向尺寸远远大于其横向尺寸,在使用的图像样本中,目标主体斜拉索往往在图像中占比很低(约 8%),图像中大部分区域为背景干扰(约 92%)。

在样本图像的长和宽各取 1/2 作为切割线,对得到的包含斜拉索的子图(即有效子图集)继续进行切割,如此反复,直到获得分辨率适宜、目标主体

占比足够大的子图像。以切割 3 次为例,切割后目标主体占比提升 48%,提升效果显著。然而,如此切割得到子图像,存在部分目标主体丢失的问题,如图 6 的左上子图与右下子图,分别有一小段斜拉索被错误丢失。为解决以上问题,提出改进切割方法:增加超参数  $\Delta$ ,用以控制切割框的重合程度,使切割得到的有效子图全覆盖目标主体,达到“宁复检、不漏检”地识别目标。在本样本集中,超参数  $\Delta$  增加至 1/8 倍子图长边时,可以实现这一目标。

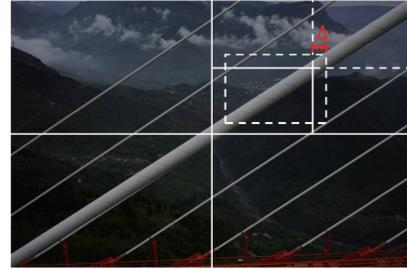


图 6 对 8 K 图像的切割方法

Fig. 6 Segmentation method for 8 K images

由于二分切割的特性,切割后得到  $2^4$  即 16 张有效子图,且有效子图长宽比与原图相同,即原图尺寸 7 952×5 304 得子图尺寸 550×365。

#### 2.1.2 斜拉索表面不同类型损伤划分

在切割得到数据集的有效子图后,对斜拉索图像数据集进行分析。由于斜拉索各类型损伤的样本量不足,在模型训练前,初步对斜拉索数据集进行划分:首先,斜拉索由螺旋线包裹的 PE 套组成。如果斜拉索 PE 护套螺旋线脱落,易产生风雨激振现象<sup>[28]</sup>,因此,将螺旋线作为划分界线,即将斜拉索表面损伤划分为螺旋线损伤(String)与非螺旋线损伤(Non-String)。在螺旋线有关的损伤中,以螺旋线脱落损伤为主;而在非螺旋线损伤中,主要存在破损(Crack)与污渍(Smudge),如图 7 所示。其中,非螺旋线损伤中的破损主要由于 PE 护套长期使用而产生老化与表面裂缝扩展等现象,容易因内部钢丝与外部空气接触而锈蚀。在实际工程中,有安全问题的斜拉索大多由于 PE 护套的破损贯穿至内部钢丝,该类损伤需要及时维修<sup>[29]</sup>。而螺旋线损伤以螺旋线脱落为主,由于斜拉索螺旋线缠绕间距越大<sup>[30]</sup>,平衡位置稳定性越差,因此,螺旋线的脱落将降低斜拉索的稳定性,从而更容易产生风雨激振等气动稳定性问题。

考虑到深度神经网络本质上为黑箱问题,难以确定某种分类方法的准确性,且数据集有限,故对数据集进行模型预训练后,将对类别划分进一步改进、测试。就后续实验的结果而言,而以图 7(a)、(b)所示对斜拉索 PE 护套损伤进行分类,两类损伤数

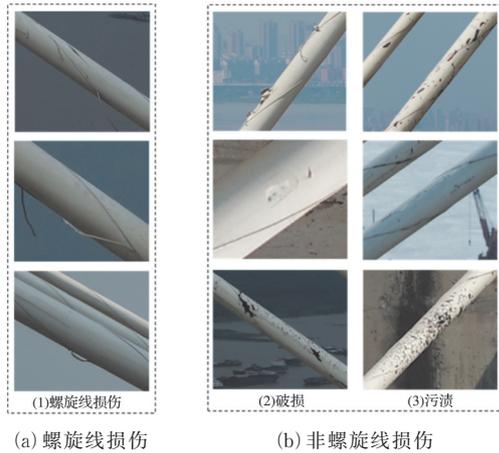


图 7 螺旋线表面损伤划分

Fig. 7 Spiral wire surface damage classification

数据集比例接近 1:1, 实验结果较为理想。

### 2.1.3 多手段数据增广技术

由于武汉天兴洲大桥处于正常服役阶段, 其斜拉索 PE 护套并没有出现大规模的损伤, 大部分为未损伤图像, 因此, 可用于训练的斜拉索 PE 护套损伤样本数据集不足, 需要针对损伤特征进行数据增强。

1) “简单”复制粘贴数据增广法。“简单”复制粘贴数据增广法 (Simple Copy-Paste) 由 Google Research 团队提出<sup>[31]</sup>。此方法不需要使用公式量化, 实验效果良好。以此方法做数据增广, 结果如图 8 所示。



图 8 斜拉索图像数据集的复制粘贴增广结果

Fig. 8 Result of Simple Copy-Paste augmentation of stay cable dataset

2) 过渡融合数据增广法。过渡融合法 (Mix-up) 由 Zhang<sup>[32]</sup> 提出, 可让深度卷积神经网络倾向于训练呈线性关系, 在已有的数据集上选取两个子集进行线性变换, 从而降低可能出现的模型过拟合现象。

选取简单数据增强后的样本与增强前的自身样本进行过渡融合, 如图 9 所示, 左上角与右下角为两样本的初始图像。

3) 噪声干扰数据增广法。在数据采集可能存在噪声干扰, 如无人机搭载的相机设备老化、采集对象处于暗光环境、传感器因长期工作而过热等情况, 都可能使样本图像产生噪声<sup>[33]</sup>。

为进一步证实提升噪声抗干扰能力对模型的重要性, 加入噪声训练数据集之前的模型用于预测加噪声后的图像样本, 结果对比显著: 原模型能较

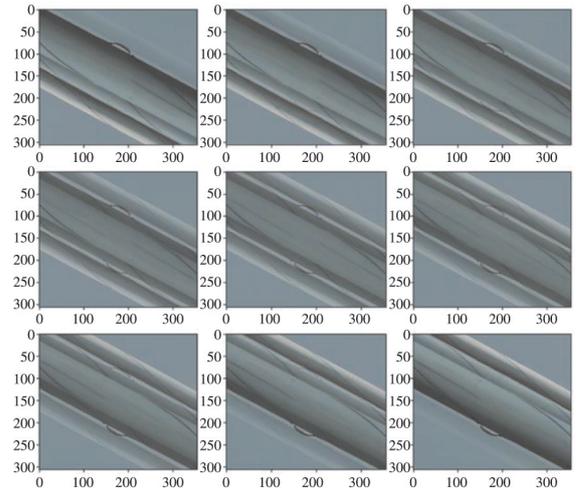


图 9 斜拉索数据集的过渡融合增广结果示例

Fig. 9 Result of Mix-up data augmentation of stay cable dataset

好预测原样本, 但不能预测加噪声后的样本, 如图 10 所示。可见, 若在模型训练时进行有噪声干扰的数据增广, 能够解决原有模型对噪声鲁棒性低的问题。

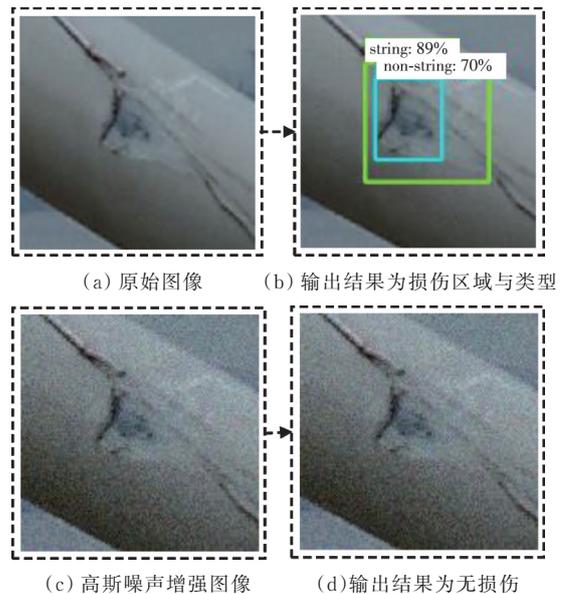


图 10 模型对噪声干扰的鲁棒性实验

Fig. 10 Experiments on the robustness of models to noise disturbances

采用开源工具 Skimage (Scikit-image), 选取高斯噪声 (Gauss Noise) 与椒盐噪声 (Salt Noise) 对斜拉索样本图像进行数据增广, 噪声强度为 Skimage 默认值。噪声干扰数据增广结果如图 11 所示。

## 2.2 轻量化卷积神经网络训练学习

经过大尺寸样本图像预处理后, 得到有效的原始数据集 50 份 (分辨率约  $550 \times 365$ )。其中, 螺旋线损伤 26 份, 非螺旋线损伤 24 份, 样本比例接近 1:1, 样本分布较为合理均衡。再进行数据增广处理: 旋



图 11 斜拉索图像数据集的噪声干扰增广结果

Fig. 11 Result of noise interference augmentation of stay cable dataset

转 90°、旋转 180°、旋转 270°、水平镜像翻转共获得数据集  $50 \times 5 = 250$  份。以原始数据集进行“简单”复制粘贴数据增广,获得数据集 120 份。以原始数据集进行过渡-融合数据增广获得数据集  $50 \times 4 = 200$  份。以原始、翻转样本之和进行高斯与椒盐噪声增广,均获得数据集 100 份。经处理后,原始数据集与增广数据集合计为 820 份。

完成斜拉索图像数据集增广后,通过开源项目 labelImg,以矩形框选择待检目标,完成数据集的标注工作。标注完成后,数据集不以图片特征为区分,将其随机划分为训练集、验证集与测试集,划分方式:首先取原始训练集 50 份作为测试集。再取增广数据集 770 份作为训练集和验证集,文献[34]中的实验表明,在数据集相对较小时,应该适量增加训练集的占比、减少验证集的占比。因此,参照文献[34]取训练集与验证集比例为 9:1,即取训练集共 693 份,取验证集共 77 份。

使用 Pytorch 开源框架,首先搭建区域推荐型卷积神经网络,再根据基于 MobileNet 的轻量化改进方法对网络模型的计算量与参数量进行改进优化,达到网络模型轻量化的目标。最后将预处理好的斜拉索图像数据集输入网络中进行训练。网络训练的超参数设置情况如下。

### 2.2.1 模型评价指标

目标检测网络训练效果一般采用 mAP(mean Average Precision)指标进行评估,其中 mAP 指标由每个目标类别的 AP(Average Precision)值加权平均得到。AP 为 Precision-Recall 曲线积分求得结果。因二者均无法单独衡量目标检测的准确性,本文采用 P-R 曲线积分来综合衡量。Precision(查准率)与 Recall(查全率)计算式为

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}, \text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (5)$$

其中,TP(True Positive)为真阳性,定义为  $\text{IoU} > 0.7$ ,指检测出的目标中是真目标的样本;FP(False Positive)为假阳性,定义为  $\text{IoU} < 0.3$ ,指检测出的目标中不是真目标的样本。

### 2.2.2 置信概率阈值 $X\%$

判断图像中是否有损伤需要设置置信概率阈值超参数  $X\%$ 。考虑到在工程结构损伤的目标检测关

系到安全问题,应该以“宁错检、不漏检”为原则设置预测网络,即  $X\%$  设置值应相对较低。考虑到斜拉索图像数据集最终以 3 分类的形式(即螺旋线损伤、非螺旋线损伤、背景)进行分类标注,因此,取值  $X\% = 33.33\%$ 。

### 2.2.3 epoch 取值

轮次(epoch)定义了学习算法在整个训练数据集中的工作轮次。区域推荐型卷积神经网络将特征提取模块(Extractor Module)作为网络的共享卷积层模块(Shared Convolutional Base, SCB)。因此,该网络存在 2 个轮次取值,分别控制第 1 阶段 SCB 的训练轮次及第 2 阶段后续网络的训练轮次。

若轮次过大,在训练过程中多次出现下降阶段,同时 mAP 增长缓慢,耗时增加,效率低下,不符合轻量化处理的初衷。经过多次实验,确定效率较高的取值为:epoch1=6,epoch2=18。

### 2.2.4 其他超参数

每批数据量的大小(Batch\_size)设置为 2,加载数据的线程(Num\_Workers)设置为 2,学习率(Learning\_Rate)设置为 0.005,权值衰减(Weight\_Decay)设置为 0.0005。

## 3 实验结果

### 3.1 多手段数据增广前后对比试验

多手段数据增广前,训练轮次设置为:epoch1=6,epoch2=18。由于原始训练集仅 50 份样本,数据量严重不足,每个轮次中 mAP 指标上升极其缓慢,尤其在第 1 阶段的共享卷积层训练中,mAP 增长值不足 0.01。进入第 2 阶段后,增长斜率相比第 1 阶段明显提升,但在短暂的上升期后迅速进入瓶颈期,mAP 值不再随轮次的迭代而增长,最大 mAP 仅达到 0.18,如图 12 所示。其轮次已经偏高,尤其在第 2 阶段,已经在最后两个轮次连续出现下降。在多手段数据增广前,模型 mAP 在第 23 轮次左右达到极限。

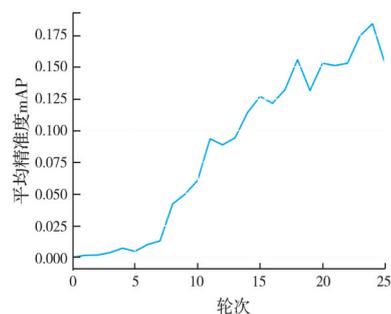


图 12 多手段数据增广前的网络训练过程

Fig. 12 Training process before multi-method data augmentation

多手段数据增广后,训练集与验证集总计 770 份。训练轮次设置为:epoch1=6,epoch2=16。由于训练集数据量足够,轻量网络的训练效果明显提升。在第 1 阶段的共享卷积层训练中,mAP 上升至 0.05,相比于多手段数据增广前的 0.01 提升 400%;在第 2 阶段,mAP 迅速上升至 0.55 左右,之后进入瓶颈期,缓慢上升,最终稳定在 0.6~0.65,最大 mAP 达到 0.65,如图 13 所示。

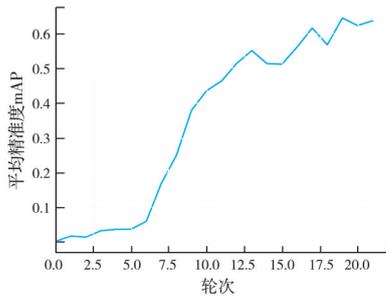


图 13 多手段数据增广后的网络训练过程

Fig. 13 Training process after multi-method data augmentation

### 3.2 轻量与非轻量化网络对比实验

分别构建轻量化处理前与轻量化处理后的区域推荐型卷积神经网络,基于斜拉索图像数据集进行模型训练与预测,对比改进前后的两种模型在训练过程中主机端的各项性能参数。

#### 3.2.1 模型准确度指标对比

采用 mAP 值衡量非轻量化与轻量化网络模型准确率,以轮次为横轴绘制折线图,如图 14 所示。可见,两种网络的 mAP 最大值均出现在第 19 个轮次。相比于非轻量化的普通网络,轻量化网络在一定程度上降低模型准确率,但是准确率下降较少。

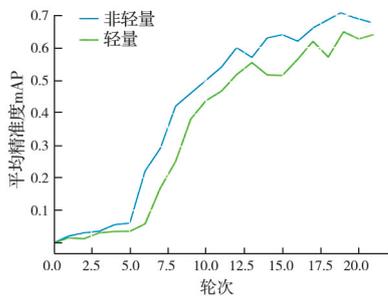


图 14 非轻量网络与轻量网络 mAP 走势对比图

Fig. 14 mAP of non-lightweight network & lightweight network

由图 14 可知,轻量化与非轻量化网络的 mAP 在训练多个轮次后上升趋势减小,其最大值均出现在第 19 个轮次,最大值对比见表 1。

轻量化网络训练结束后,部分测试集结果如图 15 所示。其中,矩形检测框对应损伤区域,相应文

表 1 轻量化与非轻量化网络的准确度对比

Table 1 Accuracy of lightweight network & non-lightweight network

网络类型	MAX(mAP)/%
非轻量化网络	70.91
轻量化网络	65.32
$\Delta$	-5.59

字对应其损伤类型和置信概率,由于置信概率阈值的设置,网络仅输出大于 33.33% 置信概率的检测框。

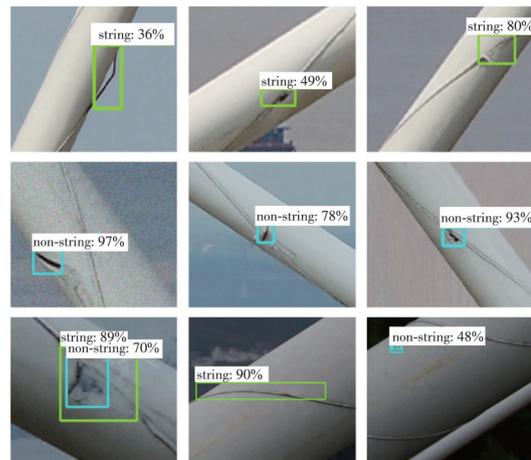


图 15 斜拉索 PE 护套损伤识别部分结果展示

Fig. 15 Partial results of stay cable damage identification

根据识别结果可得出,区域推荐型卷积神经网络对于斜拉索表面损伤识别分类与定位效果较好,准确率较高。尤其在非螺旋线损伤类型中,由于非螺旋线损伤多为裂痕、破损,图像特征较为明显,其置信概率相比于螺旋线损伤明显更高。由于对数据集进行了噪声干扰增广,模型对于带有噪声的测试集表现良好,几乎能够完全消除噪声干扰。而对于小目标病害,根据测试集结果展示右下图可得,较小目标也以较低的置信概率(48%)被检出,实现了“宁错检、不漏检”的检测目标。虽然置信概率较低,但该检测结果能为工作人员提供有效的支持,弥补了人工检测难以发现小目标病害的劣势。此外,从结果展示中可以看出,该模型在样本的不同背景下都能达到一定的识别准确率,能够胜任复杂背景下的识别任务。

#### 3.2.2 模型运算性能指标对比

使用的训练设备性能参数:CPU 为 Intel(R) Core (TM) i7-7700HQ,内存为 8 GB(2 400 MHz),GPU 为 NVIDIA GeForce GTX 1050Ti,显存为 4 GB。该设备与实验室的高性能主机端相比性能较弱,能够视作小型设备,通过记录在训练过程中电脑端的 CPU 占用率、内存占用率、GPU 占用率、显存占用

率变化趋势,以验证是否能代替高性能设备完成相应工作。

在记录过程中,为直观地展示轻量化处理前后两种模型在训练过程中计算机的各项指标变化情况,将CPU、内存、GPU、显存4项指标统一使用占用率百分数来衡量。首先记录整个训练开始前的该项指标初始值,在训练中每间隔1s对上述4项指标当前值进行读取,按照式(6)计算该项指标在当前时刻占用率。

$$R_p = \frac{V_p - V_i}{V_t} \quad (6)$$

式中: $R_p$ 为当前时刻占用率; $V_p$ 为当前值; $V_i$ 为初始值; $V_t$ 为总值。

对轻量化处理前后的两种模型进行训练,设备的各项指标随时间的变化趋势图如图16~图19所示。可以看出,轻量化处理后的总运行时间大幅减少。且在CPU、内存、GPU、显存4个性能维度上,经轻量化处理后的模型都有更低的占用率,意味着其对硬件性能需求明显降低。

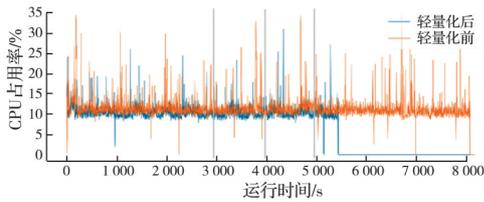


图 16 两种模型在训练中 CPU 占用率随时间的变化  
Fig. 16 CPU usage over time for the two models in training

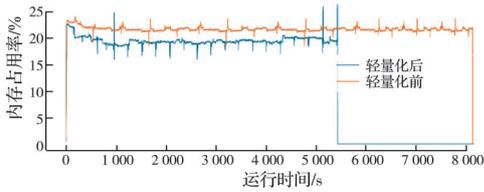


图 17 两种模型在训练中内存占用率随时间的变化  
Fig. 17 Memory usage over time for the two models in training

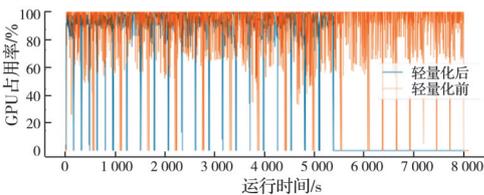


图 18 两种模型在训练中 GPU 占用率随时间的变化  
Fig. 18 GPU usage over time for the two models in training

### 3.3 结果讨论

为更加直观地对比非轻量网络与轻量网络的模型运算性能指标,首先将折线图数据进行处理,

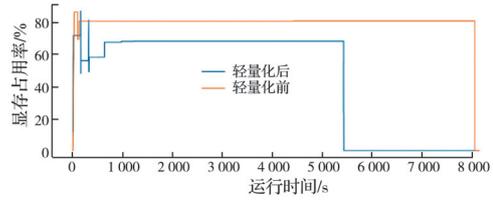


图 19 两种模型在训练中显存占用率随时间的变化  
Fig. 19 Display memory usage over time for the two models in training

在每条折线中,去除所有值为0的数据,再对折线取均值,得到该类型网络的该项性能评价指标,仍然以百分数表示。各项数据处理后,结果汇总于表2。

表 2 轻量化与非轻量化网络的性能参数对比与其轻量化改进率

网络类型	运行时间/s	CPU /%	内存 /%	GPU /%	显存 /%
轻量化网络	5 518	10.40	19.48	92.81	67.43
非轻量化网络	8 162	11.42	21.68	94.04	80.76
改进值	-2 644	1.02	2.20	1.23	13.33
轻量化改进率/%	47.92	9.81	11.29	1.32	19.77

由表2可知,轻量化模型在准确度仅仅降低5.59%的情况下,比非轻量化网络节约了接近50%的计算时间,同时节约了CPU与GPU资源,尤其是降低了模型约20%的显存占用,降低了对高性能显卡的依赖性。

由于目标检测任务的评估相比于分类任务的评估更加困难,目标检测框的评估标准难以同分类任务一样准确定义,例如,交占比的取值将较大程度影响目标检测最终的准确度指标,而选取的交占比比较为保守。使用最通用的mAP指标衡量检测框的准确性得到的数值结果往往偏低,例如当前目标检测领域主流的网络模型在PASCAL VOC等数据集上的mAP最高能够达到约80%<sup>[35]</sup>,相比而言,提出的网络在桥梁斜拉索PE护套损伤识别问题上mAP仅达到65.32%。较低的mAP数值一方面是由于较保守的交占比取值,实际模型表现将会更优;另一方面模型的确存在一定程度的性能不足,主要原因如下。

1)对轻量化的要求一定程度影响了算法性能。在训练时取每批数据量的大小(Batch\_size)为2,加载数据的线程(Num\_Workers)为2。二者皆取值较低,前者取值过低往往会影响模型拟合效果,一般在性能允许的情况下取值越高,模型越容易拟合。

后者取值不影响模型拟合效果,一般在性能允许的情况下取值越高,计算速度越快,消耗时间越短。以轻量化为出发点,为尽可能模拟低运算能力设备,将性能参数设置得较低,性能化向轻量化有所妥协,以满足模型能够在更多场景设备上适用的需求。

2)原始数据集样本规模过小。相比 PASCOL VOC 等数据集数万份的训练样本<sup>[35]</sup>,由于武汉天兴洲大桥处于健康状态,无人机未能采集足够的斜拉索 PE 护套损伤样本。采集的数据集中,绝大部分为未损伤样本,原始损伤样本仅 50 份。同时损伤区域往往面积较小,加剧了以负样本为主的问题。虽然本研究所采用的二阶段区域推荐型卷积神经网络与多手段数据增广技术一定程度上缓解了这一问题<sup>[36]</sup>,但仍然无法从根本上解决深度学习中数据集不足的结构性问题。若在后续研究中要进一步改善网络模型,将以增加实际采集的正样本规模为主要手段。

根据以上结果可以发现:轻量神经网络在牺牲少量准确度的前提下,能够在较大程度上实现对模型参数与计算量的改进,使模型能够以更低的性能需求、更短的计算时间完成对桥梁斜拉索 PE 护套识别的训练与预测。

## 4 结论

1)提出基于区域推荐型卷积神经网络的斜拉索 PE 护套损伤识别方法。在实现区域推荐的基础上,基于无人机航拍采集的桥梁斜拉索损伤图像数据,在分类网络中判断斜拉索 PE 护套有无损伤及损伤类型。

2)提出区域推荐型深度卷积神经网络的轻量化处理方法。通过改进网络模型参数规模与计算量,使神经网络能够在较低运算能力设备上完成训练与预测,增强网络模型泛用性。

3)完成斜拉索图像数据集预处理,以多手段数据增广解决数据不足的问题。构建轻量化的区域推荐型卷积神经网络模型。

4)通过对比试验,从模型准确度与性能指标的角度验证轻量化网络在较低运算能力设备上运行的可行性。结果表明,轻量化网络在牺牲少量准确度的前提下,能够在较大程度上实现对计算效率的改进,有效实现对桥梁斜拉索 PE 护套的智能识别。

## 参考文献

[1] BAO Y Q, CHEN Z C, WEI S Y, et al. The state of

the art of data science and engineering in structural health monitoring [J]. *Engineering*, 2019, 5(2): 234-242.

- [2] AZIMI M, ESLAMLOU A D, PEKCAN G. Data-driven structural health monitoring and damage detection through deep learning: State-of-the-art review [J]. *Sensors*, 2020, 20(10): 2778.
- [3] SUN L M, SHANG Z Q, XIA Y, et al. Review of bridge structural health monitoring aided by big data and artificial intelligence: From condition assessment to damage detection [J]. *Journal of Structural Engineering*, 2020, 146(5): 04020073.
- [4] 刘程程. 机器视觉在工程检测领域的应用研究[D]. 辽宁大连: 大连理工大学, 2020.
- LIU C C. Application research of machine vision in the field of engineering inspection [D]. Dalian, Liaoning: Dalian University of Technology, 2020. (in Chinese)
- [5] 许可. 卷积神经网络在图像识别上的应用的研究[D]. 杭州: 浙江大学, 2012.
- XU K. Study of convolutional neural network applied on image recognition [D]. Hangzhou: Zhejiang University, 2012. (in Chinese)
- [6] 刘洪利. 基于深度学习的轻量化目标检测算法研究[D]. 北京: 北京交通大学, 2020.
- LIU H L. Lightweight object detection algorithm based on deep learning [D]. Beijing: Beijing Jiaotong University, 2020. (in Chinese)
- [7] 曾世钦, 唐朝, 陈可. 基于深度学习和无线传输的桥梁裂缝图像识别系统[J]. *建材世界*, 2019, 40(2): 78-82, 98.
- ZENG S Q, TANG C, CHEN K. Construction of bridge crack image recognition system based on deep learning and wireless transmission [J]. *The World of Building Materials*, 2019, 40(2): 78-82, 98. (in Chinese)
- [8] 陶晓力, 武建, 杨坤. 基于无人机视觉的桥梁裂缝检测[J]. *计算机技术与发展*, 2018, 28(3): 174-177.
- TAO X L, WU J, YANG K. Bridge crack detection based on unmanned aerial vehicle vision [J]. *Computer Technology and Development*, 2018, 28(3): 174-177. (in Chinese)
- [9] 陈辉东, 丁小燕, 刘艳霞. 基于深度学习的目标检测算法综述[J]. *北京联合大学学报*, 2021, 35(3): 39-46.
- CHEN H D, DING X Y, LIU Y X. Review of target detection algorithm based on deep learning [J]. *Journal of Beijing Union University*, 2021, 35(3): 39-46. (in Chinese)
- [10] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection [C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA. 2016: 779-788.
- [11] 李会军, 王瀚洋, 李杨, 等. 一种基于视觉特征区域建议的目标检测方法[J]. *控制与决策*, 2020, 35(6): 1323-

- 1328.
- LI H J, WANG H Y, LI Y, et al. An object detector based on visual feature region proposal [J]. *Control and Decision*, 2020, 35(6): 1323-1328. (in Chinese)
- [12] 何丹妮. 基于深度学习的多车辆检测及跟踪算法研究[D]. 辽宁 大连: 大连理工大学, 2019.
- HE D N. Research on multi-vehicle detection and tracking algorithm based on deep learning [D]. Dalian, Liaoning: Dalian University of Technology, 2019. (in Chinese)
- [13] HE K M, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN [C]//2017 IEEE International Conference on Computer Vision. Venice, Italy, 2017: 2980-2988.
- [14] 石杰, 周亚丽, 张奇志. 基于改进 Mask RCNN 和 Kinect 的服务机器人物品识别系统[J]. *仪器仪表学报*, 2019, 40(4): 216-228.
- SHI J, ZHOU Y L, ZHANG Q Z. Service robot item recognition system based on improved Mask RCNN and Kinect [J]. *Chinese Journal of Scientific Instrument*, 2019, 40(4): 216-228. (in Chinese)
- [15] 薛明. 基于稀疏表示的在线目标跟踪研究[D]. 上海: 上海交通大学, 2014.
- XUE M. Research on online object tracking based on sparse representation [D]. Shanghai: Shanghai Jiao Tong University, 2014. (in Chinese)
- [16] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]//2014 IEEE Conference on Computer Vision and Pattern Recognition. Columbus, OH, USA, 2014: 580-587.
- [17] GIRSHICK R. Fast R-CNN [C]//2015 IEEE International Conference on Computer Vision. Santiago, Chile, 2015: 1440-1448.
- [18] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(6): 1137-1149.
- [19] 徐阳. 基于计算机视觉的桥梁结构局部损伤识别方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2019: 1-15.
- XU Y. Structural local damage detection methods for bridges based on computer vision techniques [D]. Harbin: Harbin Institute of Technology, 2019: 1-15. (in Chinese)
- [20] 林景栋, 吴欣怡, 柴毅, 等. 卷积神经网络结构优化综述[J]. *自动化学报*, 2020, 46(1): 24-37.
- LIN J D, WU X Y, CHAI Y, et al. Structure optimization of convolutional neural networks: A survey [J]. *Acta Automatica Sinica*, 2020, 46(1): 24-37. (in Chinese)
- [21] DENIL M, SHAKIBI B, DINH L, et al. Predicting parameters in deep learning [C]//Proceedings of the 26th International Conference on Neural Information Process-  
ing Systems. Lake Tahoe, Nevada, USA: Curran Associates Inc., 2013: 2148-2156.
- [22] 杨玉敏, 廖育荣, 林存宝, 等. 轻量化卷积神经网络目标检测算法综述[J]. *舰船电子工程*, 2021, 41(4): 31-36.
- YANG Y M, LIAO Y R, LIN C B, et al. A survey of object detection algorithms for lightweight convolutional neural networks [J]. *Ship Electronic Engineering*, 2021, 41(4): 31-36. (in Chinese)
- [23] HOWARD A G, ZHU M L, CHEN B, et al. MobileNets: Efficient convolutional neural networks for mobile vision applications [EB/OL]. <https://arxiv.org/abs/1704.04861>.
- [24] SANDLER M, HOWARD A, ZHU M L, et al. MobileNetV2: Inverted residuals and linear bottlenecks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA, 2018: 4510-4520.
- [25] HE K M. Identity mappings in deep residual networks [C]//European Conference on Computer Vision, 2016.
- [26] 梁亚斌, 蔡思佳, 冯谦, 等. 基于无人机航拍的武汉天兴洲长江大桥桥索 PE 外观检测技术[J]. *大地测量与地球动力学*, 2019, 39(11): 1207-1210.
- LIANG Y B, CAI S J, FENG Q, et al. Cable PE appearance inspection in the tianxingzhou river bridge using unmanned aerial vehicle based aerial photo technique [J]. *Journal of Geodesy and Geodynamics*, 2019, 39(11): 1207-1210. (in Chinese)
- [27] 李放. 基于深度卷积神经网络的高分辨率图像目标检测研究[D]. 辽宁 阜新: 辽宁工程技术大学, 2019.
- LI F. Research on object detection of high resolution images based on convolution neural network [D]. Fuxin, Liaoning: Liaoning Technical University, 2019. (in Chinese)
- [28] 关健. 斜拉索风雨激振理论模型及参数化分析[D]. 天津: 天津大学, 2018.
- GUAN J. Theoretical models and parametric analysis of rain-wind induced vibration of stay cable [D]. Tianjin: Tianjin University, 2018. (in Chinese)
- [29] 要军霞. 斜拉索的防护[J]. *山西建筑*, 2008, 34(12): 300-301.
- YAO J X. Protection of stayed cables [J]. *Shanxi Architecture*, 2008, 34(12): 300-301. (in Chinese)
- [30] 刘庆宽, 王晓江, 卢照亮, 等. 螺旋线对斜拉桥斜拉索横风向气动力和稳定性的影响[J]. *振动与冲击*, 2019, 38(6): 108-113.
- LIU Q K, WANG X J, LU Z L, et al. Effect of helical line on the aerodynamic force and stability of stay cables [J]. *Journal of Vibration and Shock*, 2019, 38(6): 108-113. (in Chinese)
- [31] GHIASI G, CUI Y, SRINIVAS A, et al. Simple copy-paste is a strong data augmentation method for instance

- segmentation [C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville, TN, USA, 2021: 2917-2927.
- [32] ZHANG H Y. Mix up: Beyond empirical risk minimization [C]//The International Conference on Learning Representations (ICLR), 2018.
- [33] 刘平平. 机器视觉系统中的图像噪声处理算法研究[D]. 武汉: 华中科技大学, 2011.  
LIU P P. Research on image denoising algorithm in machine vision system [D]. Wuhan: Huazhong University of Science and Technology, 2011. (in Chinese)
- [34] 朱劲松, 李欢, 王世芳. 基于卷积神经网络和迁移学习的钢桥病害识别[J]. 长安大学学报(自然科学版), 2021, 41(3): 52-63.  
ZHU J S, LI H, WANG S F. Defect recognition for steel bridge based on convolutional neural network and transfer learning [J]. Journal of Chang'an University (Natural Science Edition), 2021, 41(3): 52-63. (in Chinese)
- [35] 许德刚, 王露, 李凡. 深度学习的典型目标检测算法研究综述[J]. 计算机工程与应用, 2021, 57(8): 10-25.  
XU D G, WANG L, LI F. Review of typical object detection algorithms for deep learning [J]. Computer Engineering and Applications, 2021, 57(8): 10-25. (in Chinese)
- [36] 徐子同. 基于改进的Faster RCNN交通目标检测算法研究[D]. 西安: 长安大学, 2021.  
XU Z T. A study on object detection for traffic scene based on improved faster RCNN [D]. Xi'an: Chang'an University, 2021. (in Chinese)

(编辑 胡玲)