

基于改进 SSD 算法的铁路隧道漏缆卡具检测

张云佐*, 杨攀亮, 李文轩

石家庄铁道大学信息科学与技术学院, 河北 石家庄 050043

摘要 针对目前隧道内漏缆卡具检测数据量大、人工检测效率低的问题,提出了一种基于改进 single shot MultiBox detector(SSD)算法的隧道漏缆卡具检测算法。该算法使用不同尺度的特征图检测卡具目标,并在网络宽度和网络深度上对 SSD 网络结构进行改进。结合 Inception 结构,增加网络宽度;采用残差结构,在提高网络深度的同时优化网络深度结构;使用深度可分离卷积和 1×1 卷积结构,减少模型参数量,改善模型结构,从而提高模型检测效率。将改进后的模型应用于隧道漏缆卡具图像检测,实验结果表明,该算法检测的平均准确率达到 86.6%,检测速度达到了 26.6 frame/s,相较于原始 SSD 算法和 MobileNet SSD 算法,具有明显优势。

关键词 机器视觉; 图像处理; 卡具检测; SSD; 残差结构; 深度可分离卷积

中图分类号 TP391

文献标志码 A

doi: 10.3788/LOP202158.2215005

Detection of Cable Leakage Fixture in Railway Tunnel Based on Improved SSD Algorithm

Zhang Yunzuo*, Yang Panliang, Li Wenxuan

School of Information Science and Technology, Shijiazhuang Tiedao University, Shijiazhuang, Hebei 050043, China

Abstract Aiming at the problems of large amount of detection data of cable leakage fixtures and low manual detection efficiency in tunnel, a cable leakage fixture detection algorithm in tunnel based on the improved single shot MultiBox detector (SSD) algorithm is proposed. This algorithm uses feature maps with different scales to detect fixture objects, and improves the SSD network structure in terms of network width and network depth. The network width is deepened by combining the Inception structure, the residual structure is used to optimize network depth structure while increasing network depth, the depthwise separable convolution and 1×1 convolution structure are used to reduce the amount of model parameters and improve the model structure, so as to improve the model detection efficiency. The improved model is applied to the image detection of cable leakage fixture in tunnel. Experimental results show that the average detection accuracy of this algorithm reaches 86.6%, and the detection speed reaches 26.6 frame/s, which has obvious advantages over the original SSD algorithm and MobileNet SSD algorithm.

Key words machine vision; image processing; fixture detection; SSD; residual structure; depthwise separable convolution

OCIS codes 100.3008; 100.4996; 150.1135

1 引言

随着高速铁路的快速发展,高铁运营安全的重要性日益凸显。铁路移动通讯系统是保障铁路无线

通信的重要环节,山区、隧道通信网络的覆盖主要依靠泄漏电缆。通信泄漏同轴电缆通常悬挂在隧道壁上,并由卡具固定。高速行驶的列车经过时产生的气压和能量波会对卡具产生一定的冲击,同时卡具

收稿日期: 2020-12-03; 修回日期: 2021-01-08; 录用日期: 2021-01-27

基金项目: 国家自然科学基金(61702347)、河北省自然科学基金(F2017210161)

通信作者: *zhangyunzuo888@sina.com

还受到各种环境因素的影响^[1-2],很容易松动甚至脱落,一旦发生故障很容易造成交通事故,并严重影响铁路的运营安全。

为了确保铁路移动通信系统的安全运行,有必要定期检查隧道内的漏缆卡具。目前,隧道内漏缆卡具检测方法主要有纯手动检测方法和采集视频回放检测方法两种^[3]。目前,铁路部门隧道内漏缆卡具的检测大多还停留在纯手动检测阶段,每月进行一次人工检查。人工检查受到环境因素、地理因素和人为因素的影响,检查效率低、工作量大,不仅耗费大量的人力、资金和设备等,而且在崎岖的地形或隧道内照明不足的情况下难以进行检查,最重要的是极易发生漏检的情况,检测结果难以保证。另外,随着高速铁路的不断发展,隧道的数量和长度也在不断增加,有时一条隧道甚至长达几十千米,给卡具维护人员带来了巨大的挑战。在采集视频回放检测方法中,通常在火车窗口中安装一个高速摄像机,以收集并存储火车整个运行过程中拍摄的图像。尽管这些图像经过了一些简单的处理,例如压缩处理和定位识别,但它们存储了列车运行过程中所有的视频数据,并且只能通过手动回放来确认故障点。故采集视频回放检测方法存在存储数据量大、检测周期长及定位到故障点困难等缺点。因此,铁路部门对解决隧道内漏缆卡具的智能检测问题有着十分迫切的需求。

近年来,深度学习以强大的学习能力在目标检测领域得到了广泛应用^[4-5]。与机器学习相比,深度学习不需要人工提取目标特征,可以实现端到端的检测。目前主流的基于深度学习的目标检测算法通常可分为 one-stage 算法和 two-stage 算法。其中,基于区域的 two-stage 算法主要包括 R-CNN 算法^[6]、Fast R-CNN 算法^[7]和 Faster R-CNN 算法^[8];基于回归的 one-stage 算法主要有 YOLO 算法^[9]和 Single Shot MultiBox Detector (SSD)^[10]。基于 two-stage 的算法一般精度高,但速度慢,实时性较差。在基于回归的 one-stage 算法中,YOLO 算法速度较快,但精度不高。SSD 算法结合了 YOLO 的回归思想和 Faster R-CNN 的 anchor 机制,既保持了 YOLO 速度快的特性,也保证了检测结果跟 Faster R-CNN 一样比较精准,具有广阔的应用前景。

本文提出了一种基于改进 SSD 算法的隧道漏缆卡具检测算法,在保证漏缆卡具检测精度的同时,提高了模型检测速度。该算法在 SSD 算法的基础

上,结合 Inception 结构提高网络宽度,并采用残差结构优化网络深度,提高了模型的特征提取能力。为了优化模型结构,该算法采用深度可分离卷积和 1×1 卷积降低了网络模型总的参数量。实验结果表明,所提算法能快速准确地检测隧道内的漏缆卡具,具有很高的工业应用价值。

2 SSD 目标检测算法

2.1 SSD 模型

SSD 是一种直接预测目标包围框的坐标和类别的目标检测算法,利用具有不同分辨率卷积层的特征图,可以对不同大小的物体进行检测。SSD 模型的主网络结构是 VGG16,但是将 VGG16 的最后 2 个全连接层改成了卷积层,接着增加了 4 个卷积层来构造网络结构。该模型一共从网络结构中抽取了 6 层特征图用于检测,这些层的大小逐渐减小,呈现出金字塔结构^[11],使其可以在大的特征图上检测小目标,在小的特征图上检测大目标,从而实现多尺度目标检测。

2.2 先验框计算

SSD 模型主要在大小为 $(38, 38)$, $(19, 19)$, $(10, 10)$, $(5, 5)$, $(3, 3)$ 和 $(1, 1)$ 的特征图上进行检测。在不同的特征图上先验框的设置不同。

在生成先验框时,以每个特征图上的点作为中心点,生成了一系列的同心先验框,同时在不同特征图上,每个中心点生成的先验框个数并不完全相同。先验框的设置,主要包括尺度和宽高比两个方面。当使用 m 个特征图进行预测时,每个特征图默认框的比例为

$$s_k = s_{\min} + \frac{s_{\max} - s_{\min}}{m - 1}(k - 1), k \in (1, 2, 3, \dots, m), \quad (1)$$

式中: s_{\min} 取 0.2; s_{\max} 取 0.95。所有层规矩间隔,先验框的宽度和高度可以通过 a_r 来进行调整,计算公式为

$$w_k^a = s_k \sqrt{a_r}, \quad (2)$$

$$h_k^a = \frac{s_k}{\sqrt{a_r}}, \quad (3)$$

式中: $a_r \in (1, 2, 3, \frac{1}{2}, \frac{1}{3})$ 。此外,当 $a_r = 1$ 时,增加了一种先验框,表达式为

$$s'_k = \sqrt{s_k s_{k+1}}. \quad (4)$$

先验框的中心坐标为 $(\frac{m+0.5}{|f_k|}, \frac{n+0.5}{|f_k|})$, f_k

是第 k 层特征图的大小, $m, n \in (0, |f_k|)$ 。

2.3 损失函数

一般通过损失函数计算真实值与预测值的误

差。SSD 算法的损失函数是对分类置信度损失和位置回归损失两部分进行加权求和得到的, 表达式为

$$L(x, c, l, g) = \frac{1}{N} [L_{\text{conf}}(x, c) + \alpha L_{\text{loc}}(x, l, g)], \quad (5)$$

其中, 分类置信度损失

$$L_{\text{conf}}(x, c) = - \sum_{i \in O_{\text{Pos}}} x_{ij}^p \log c_i^p - \sum_{i \in O_{\text{Neg}}} \log c_i^0, \quad (6)$$

当 $c_i^p = \frac{\exp(c_i^p)}{\sum_p \exp(c_i^p)}$ 时, 位置回归损失为

$$L_{\text{loc}}(x, l, g) = \sum_{i \in O_{\text{Pos}}} \sum_{m \in \{cx, cy, w, h\}} x_{ij}^k \text{smoothL1}(l_i^m - g_j^m) \quad (7)$$

式中: O_{Pos} 是正样本数据集; O_{Neg} 是负样本数据集; c_i^p 表示第 i 个预测框对应类别 p 的预测概率; l_i^m 表示第 i 个预测框 (l) 的坐标 m ; g_j^m 表示第 j 个真实框 (g) 的坐标 m ; smoothL1 函数为常用的损失函数; $x_{ij}^p = \{0, 1\}$ 表示第 i 个预选框与类别 p 的第 j 个真实框是否匹配。

3 模型改进

SSD 算法的主网络是 VGG16, 所提算法主要采用了增加网络深度和网络宽度的方法提高网络性能。其中, 网络的深度指的是网络的层数, 宽度指的

是每层的通道数。改进后的模型主要采用 Inception 网络来优化网络宽度^[12], 每个 Block 均结合了 1×1 卷积、 3×3 深度可分离卷积及 3×3 最大池化, 使每个 Block 可以提取到更多的特征信息。该模型通过堆叠 Block, 增加了网络深度, 并结合残差机制^[13] 解决网络深度增加而带来的模型退化问题。为了解决模型复杂度增加而带来的参数量急剧上升的问题, 加入了深度可分离卷积和 1×1 卷积, 来提高检测速度。改进后的网络结构如图 1 所示, Block 内的结构模块如图 2 所示。特征图大小的过渡采用步长为 2 的深度可分离卷积实现。

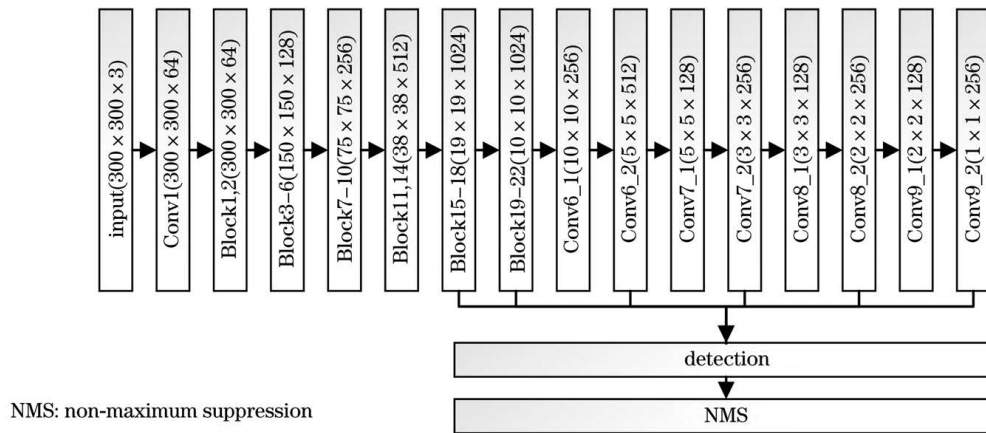


图 1 改进 SSD 的网络结构

Fig. 1 Network structure of improved SSD

3.1 网络宽度

网络宽度与每层网络可以提取到的特征数量相关, 在一定程度上提升模型的网络宽度可以使特征提取网络得到更多的特征信息, 对提高目标检测的精度有一定的帮助。所提改进的 SSD 网络模型结合了 Inception 网络的相关组成结构, 通过对输入的

上层网络分别进行 1×1 卷积、 3×3 深度可分离卷积和 3×3 最大池化, 以增加网络宽度和网络对尺度的适应性; 而且将检测结果拼接起来传入下层网络的操作为模型引入了一定的非线性属性, 提高了模型的特征提取能力。为了减少模型参数, 模型没有采用 5×5 卷积。改进后的结构结合了稀疏结

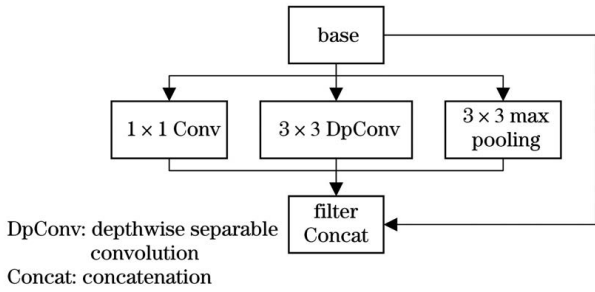


图 2 改进 SSD 的 Block 结构

Fig. 2 Block structure of improved SSD

构^[13],将不同大小的卷积核卷积得到的结果和池化得到的结果进行了整合,通过密集的结构模块来替代最优的局部系数结构,可以抑制由于参数增加而带来的过拟合现象。

3.2 网络深度

所提改进 SSD 模型通过堆叠 Block 加深网络深度,以提高模型特征提取能力。由于网络层数的加深在一定程度上可以提高模型的非线性表达能力,模型可以学习到一些更加复杂的变换,有效提高模型对特征的拟合能力。较深的网络模型汇集了各种低、中、高不同层次的特征,具有鲜明的特征层次。因此,在构建卷积网络时,网络的深度越深,可抽取的特征层次就越丰富。为此,该模型使用更深层次的网络结构,以便取得更多层次的特征。对于梯度消失和爆炸问题,在卷积层之后激活函数(ReLU)之前加入批量归一化算法^[14],将需要传递的特征规范化,可以有效地解决此问题,保证网络的稳定性。同时在网络训练中,批量归一化算法将一个最小批次中的所有样本关联起来,使得网络可以从同一批次的所有样本中关联得出结果。因为每次网络选取的样本批次都是随机的,所以网络不会单独朝一个方向学习,在一定程度上减小了过拟合的风险。

网络深度增加会使模型发生退化现象。如深层的网络结构可能比浅层的网络效果更差,这并不是

过拟合导致的,而主要是冗余的网络层学习了不是恒等映射的参数造成的。为了解决模型退化问题,所提算法引入了 ResNet 网络^[15]中的残差结构。从图 2 可以看出,每个 Block 的输入都可以在输出前直接叠加在 Inception 结构的输出中,保证随着网络深度的增加,该模型可以通过恒等映射退化为一个浅层网络,保证模型的检测效果。

残差结构主要解决了网络深度增加时,深层网络实现恒等映射的问题。即当深层网络的后面层是恒等映射时,该模型就退化为一个浅层网络。残差单元如图 3 所示。该结构可以将学习一个恒等映射函数 $H(x)=x$ 转化成学习一个残差函数 $F(x)=H(x)-x$,这样拟合残差函数更加容易。当残差 $F(x)=0$ 时,叠加的卷积层只是做了恒等映射,可以保证网络性能至少不会下降,也使得深层网络在输入特征基础上学习到新的特征,从而拥有更好的性能。




图 3 残差单元

Fig. 3 Residual unit

3.3 网络参数优化

随着结构的调整,模型的复杂度明显增加,模型总的参数量也逐渐增大。为了保证模型的检测速度不至于大幅度降低,所提算法使用深度可分离卷积替换了传统的卷积运算。深度可分离卷积将传统卷积分成了深度卷积和点卷积^[16-17]。当输入特征图为 $F_s \times F_s \times M$,输出特征图为 $F_s \times F_s \times N$,卷积核为 $F_k \times F_k$ 时,传统的卷积参数量 S_c 为

$$S_c = F_k \times F_k \times M \times N \times F_s \times F_s. \quad (8)$$

深度可分离卷积的参数量 S_n 为深度卷积和点卷积的参数量之和,表达式为

$$S_n = F_k \times F_k \times M \times F_s \times F_s + M \times N \times F_s \times F_s. \quad (9)$$

深度可分离卷积与传统卷积的参数量之比为

$$\frac{S_n}{S_c} = \frac{F_k \times F_k \times M \times F_s \times F_s + M \times N \times F_s \times F_s}{F_k \times F_k \times M \times N \times F_s \times F_s} = \frac{1}{N} + \frac{1}{F_k^2}. \quad (10)$$

通过深度可分离卷积,可以将传统卷积的参数量减少到原来的 $1/N + 1/F_k^2$,从而有效降低模型运算量,大幅度提升检测速度。

4 实验与分析

4.1 实验过程

本实验采用 Intel Xeon E5-2697 v2 的服务器和

NVIDIA GeForce GTX 1080 Ti 的显卡,在 tensorflow 平台上进行训练和测试工作。实验数据源于架设在高铁窗上的高速双线 CMOS 相机采集的隧道内视频

数据,处理后共获得 3552 张原始卡具数据。采集到的卡具及背景示例如图 4 所示。其中,75%的图像作为训练数据集,剩下的 25%作为测试数据集。



图 4 卡具及背景示例。(a)故障卡具;(b)良好卡具;(c)背景

Fig. 4 Examples of fixtures and background. (a) Fault fixture; (b) good fixture; (c) background

本实验将原始卡具分为良好卡具和故障卡具两种类型,并对卡具目标进行标注。在训练过程中,网络模型较为复杂,因此在批量归一化操作中设置输入的批次大小为 4。在网络的训练过程中,将一定批次大小的卡具图片及其对应的真实框坐标和标签输入到网络,把图片尺寸调整为 300×300 ,通过 SSD 算法的主干网路提取特征,在 Block18、Block22、Conv6_1、Conv7_1、Conv8_1、Conv9_1 这 6 个特征层上分别生成 anchor。结合分类置信度损失和位置回归损失,预测 anchor 的分类及坐标;然后将预测结果整合在一起,通过与真实框的交并补 (IOU) 匹配,返回 anchor 对应的包围框坐标及分类标签;最后通过非极大值抑制得到置信度最高的检测结果。此外在先验框生成中,结合实验中卡具的结构特征,将先验框宽高比由 $(1/3, 3)$ 改为了 $(2/3, 3/2)$ 。

实验中对训练数据进行了数据增强,是因为当训练数据不足时,模型从原始数据中获得的信息相对较少,可能会导致过拟合的发生。在这种情况下,模型的效果很难保证。因此,需要用先验信息对原始数据进行处理,通过对原始数据进行亮度调节、对比度调节、旋转、翻转、模糊和加噪声等操作,实现数据增强。

在训练过程中,改进后的 SSD 模型及对照模型的训练损失和验证损失随迭代次数的变化情况如图 5 所示。其中,SSD 算法和 MobileNet SSD 算法均加载了预训练模型,损失函数在初始时较低,损失函数随迭代次数的增加逐渐降低,但是变化的幅度相对较小。改进后的模型在训练过程中并未加载预训练模型,因此初始时损失函数较高,随着迭代次数的增加,模型逐渐学习到的特征信息逐渐增多,损失函数也能够逐渐降低至较低值。




图 5 不同模型训练损失图。(a) SSD; (b) MobileNet SSD; (c) 所提改进 SSD

Fig. 5 Training loss diagram of different models. (a) SSD; (b) MobileNet SSD; (c) proposed improved SSD

4.2 实验结果

在检测精度方面,一般使用 mean Average Precision (mAP) 衡量所有类别的平均准确率。在本实验中,所提算法和对照算法之间的精度对比如表 1 所示。

所提改进 SSD 算法对故障卡具的检测精度有了一定的提升,部分原因是模型增加了网络宽度和网络深度,可以提取到更多的卡具特征。这些特征对模型学习故障卡具类型起到更好的效果。相较于原始的 SSD 算法,MobileNet SSD 算法和所提改进

表 1 精度对比

Table 1 Precision comparison

Algorithm	Good_fixture	Bad_fixture	mAP / %
	AP / %	AP / %	
SSD	97.0	75.0	86.0
MobileNet SSD	92.1	67.3	79.7
Proposed improved SSD	92.2	81.0	86.6

SSD 算法在良好卡具的检测精度上降低了 5 个百分点左右,与特征提取层有一定的关系。原始的 SSD

算法在大小为 (38, 38), (19, 19), (10, 10), (5, 5), (3, 3) 和 (1, 1) 的特征图上进行检测, 而所提改进 SSD 和 MobileNet SSD 并没有利用 (38, 38) 特征图上的信息, 而是在大小为 (3, 3) 和 (1, 1) 的特征图之间添加了一层 (2, 2) 大小的特征图, 即利用 (19, 19), (10, 10), (5, 5), (3, 3), (2, 2), (1, 1) 大小的特征图进行检测, 增加了模型对高层信息的处理能力, 也减少了模型的参数总量, 提高了模型检测速度。改进后的模型虽然对良好卡具的检测精度有所降低, 但是对故障卡具的检测精度有了较大幅度的提升, 综合性能更加优异。

在故障卡具的检测上, MobileNet SSD 算法的精度比原始 SSD 算法降低了 7.7 个百分点, 而所提改进 SSD 算法的精度比原始 SSD 算法提高了 6 个百分点, 从一定程度上证明了改进后的模型的特征提取能力有了显著的提高。产生这个结果的原因可能是 MobileNet SSD 模型较小, 模型的能力相对于原始 SSD 有所下降; 而改进后的模型更加复杂, 参数量较多, 使用深度可分离卷积能达到更好的效果。同时, 改进后的模型在较小的特征图上提取的特征相对更多, 所以在高层特征图上能够获得更加有效的故障卡具特征, 对提高故障类型卡具的检测精度也有一定的帮助。结合实际应用场景, 改进后的模型对故障卡具检测精度的提升更有益于指导工程项目的运行。

在检测速度方面, 由于模型的检测速度与模型总的参数量相关, 一般情况下, 随着参数量的减少, 模型的检测速度逐渐增加。为此, 统计了不同模型在训练过程中的参数量个数, 检测结果如表 2 所示。

表 2 检测速度对比

Table 2 Comparison of detection speed

Algorithm	Number of parameters	Speed / (frame·s ⁻¹)
SSD	23879570	21.5
MobileNet SSD	6408110	31.9
Proposed improved SSD	10692590	26.6




图 6 所提算法检测结果示例

Fig. 6 Examples of detection results of proposed algorithm

从表 2 中可以看出, 以 VGG16 为主网络结构的 SSD 算法模型参数量为 23879570, 是 MobileNet SSD 算法的 3.7 倍, 是所提改进 SSD 算法的 2.2 倍, 因此使用深度可分离卷积和 1×1 卷积可以有效地减少模型参数量。但是由表 1 可知, MobileNet SSD 模型的 mAP 为 79.7%, 且对于故障卡具的 AP 只有 67.3%, 在实际的检测中虽然速度较快, 但是精度难以满足实际需求。所提改进 SSD 算法在一定程度上提高了模型复杂度, 相较于 MobileNet SSD 算法, 模型的参数量有所增加, 但还是远少于 SSD 算法的参数量。改进后的模型在检测速度上相较于原始的 SSD 算法有了明显提升。

所提改进 SSD 算法的部分实验检测结果如图 6 所示。结合表 1 和表 2 中的数据可知: 原始的 SSD 算法整体模型参数量较多, 检测速度较慢为 $21.5 \text{ frame} \cdot \text{s}^{-1}$, 平均检测精度为 86%; MobileNet SSD 算法整体参数量最少, 但由于模型简单, 模型的检测能力较差; 所提改进 SSD 模型通过采用深度可分离卷积和大量 1×1 卷积有效减少了模型参数量, 相较于原始的 SSD 算法, 检测速度有了明显提升, 同时改进后的模型从网络宽度和网络深度两个方向对模型进行优化, 提高了模型复杂度, 模型的特征提取能力也得到了进一步改善, 相较于原始的 SSD 算法, mAP 提高了 0.6 个百分点。此外, 所提模型对故障卡具的检测精度不够好, 有一定原因是虽然对卡具数据进行了一定的数据增强操作, 但相较于良好卡具, 故障卡具的数量依然较少, 模型对故障卡具的学习并没有达到最好效果。随着后期工作的进展, 采集的故障数据增多, 模型能够从这些数据中提取更加丰富的特征, 对故障卡具的检测精度也能进一步提高。此外, 针对低层网络感受野较小、几何细节信息表征能力强、语义信息表征能力弱以及高层网络感受野较大、语义信息表征能力强、几何信息的表征能力弱的特点, 后期工作将主要集中在多尺度特征融合的方式, 融合低层网络和高层网络的优点, 以进一步提升检测准确率。

5 结 论

提出了一种基于改进 SSD 算法的隧道漏缆卡具检测方法,该方法通过结合 Inception 结构和残差结构优化了网络宽度和网络深度,提高了网络模型的特征提取能力,有助于实现 SSD 算法的多尺度检测。通过深度可分离卷积和 1×1 卷积有效减少了模型参数量,提高了模型的检测速度。实验结果表明,在隧道漏缆卡具检测场景中,所提方法检测的平均准确率达到 86.6%,检测速度达到了 $26.6 \text{ frame} \cdot \text{s}^{-1}$,对实际卡具检测具有一定的指导意义。下一步将研究多尺度特征融合方法,进一步提升模型的检测精度。

参 考 文 献

- [1] He Y J, Song X, Li B. RFID-based video inspection plan for leaky coaxial cables in railway tunnels [J]. China Railway, 2018(11): 104-108.
何玉娟, 宋鑫, 李斌. 基于 RFID 定位的铁路隧道漏缆视频巡检方案 [J]. 中国铁路, 2018(11): 104-108.
- [2] Du X Y, Chang K, Xu P F. Analysis about influence of cable trough on subgrade structure of high speed railway and optimization suggestion [J]. Railway Engineering, 2019, 59(3): 69-72.
杜晓燕, 常凯, 许鹏飞. 高速铁路路基电缆槽对路基结构的影响分析及优化建议 [J]. 铁道建筑, 2019, 59(3): 69-72.
- [3] Yi S J. A vehicle detection system based on visual image of the cable fault [D]. Beijing: Beijing University of Chemical Technology, 2015.
易尚杰. 基于视觉图像的铁路漏缆故障车载检测系统 [D]. 北京: 北京化工大学, 2015.
- [4] Duan Z J, Li S B, Hu J J, et al. Review of deep learning based object detection methods and their mainstream frameworks [J]. Laser & Optoelectronics Progress, 2020, 57(12): 120005.
段仲静, 李少波, 胡建军, 等. 深度学习目标检测方法及其主流框架综述 [J]. 激光与光电子学进展, 2020, 57(12): 120005.
- [5] Dong Y F, Zhang C T, Wang P, et al. Airplane detection of optical remote sensing images based on deep learning [J]. Laser & Optoelectronics Progress, 2020, 57(4): 041007.
董永峰, 仇长涛, 汪鹏, 等. 基于深度学习的光学遥感图像飞机检测算法 [J]. 激光与光电子学进展, 2020, 57(4): 041007.
- [6] 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, June 23-28, 2014, Columbus, OH, USA. New York: IEEE Press, 2014: 580-587.
- [7] Girshick R. Fast R-CNN [C]//2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2015: 1440-1448.
- [8] Ren S Q, He K M, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [C]//IEEE Transactions on Pattern Analysis and Machine Intelligence, New York: IEEE Press, 2016: 1137-1149.
- [9] 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 (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 779-788.
- [10] Liu W, Anguelov D, Erhan D, et al. SSD: single shot MultiBox detector [M]//Leibe B, Matas J, Sebe N, et al. Computer vision-ECCV 2016. Lecture notes in computer science. Cham: Springer, 2016, 9905: 21-37.
- [11] Yao W M, Wang X H, Wu N. Sewing gesture image detection method based on improved SSD model [J]. Laser & Optoelectronics Progress, 2020, 57(18): 181017.
姚炜铭, 王晓华, 吴楠. 基于改进 SSD 模型的缝纫手势图像检测方法 [J]. 激光与光电子学进展, 2020, 57(18): 181017.
- [12] Yang W, Zhou K X, Liu J J, et al. Method of dry and wet state recognition of pavement based on migration learning and Inception-v3 model [J]. China Sciencepaper, 2019, 14(8): 912-916.
杨炜, 周凯霞, 刘佳俊, 等. 结合迁移学习和 Inception-v3 模型的路面干湿状态识别方法 [J]. 中国科技论文, 2019, 14(8): 912-916.
- [13] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions [C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015.
- [14] Wang Y, Wu X F. Novel normalization algorithm for training of deep neural networks with small batch sizes [J]. Computer Science, 2019, 46(S2): 273-276, 308.
王岩, 吴晓富. 深度神经网络训练中适用于小批次的归一化算法 [J]. 计算机科学, 2019, 46(S2): 273-276, 308.
- [15] Quan Y, Li Z X, Zhang C L, et al. Fusing deep dilated convolutions network and light-weight

network for object detection [J]. *Acta Electronica Sinica*, 2020, 48(2): 390-397.

权宇, 李志欣, 张灿龙, 等. 融合深度扩张网络和轻量化网络的目标检测模型 [J]. *电子学报*, 2020, 48(2): 390-397.

- [16] Xu L X, Chen X J, Ban Y, et al. Method for intelligent detection of parking spaces based on deep learning [J]. *Chinese Journal of Lasers*, 2019, 46(4): 0404013.

徐乐先, 陈西江, 班亚, 等. 基于深度学习的车位智能检测方法 [J]. *中国激光*, 2019, 46(4): 0404013.

- [17] Zhang Y F, Zheng Z L, Liu H W, et al. A lightweight convolutional neural network architecture with slice feature map [J]. *Pattern Recognition and Artificial Intelligence*, 2019, 32(3): 237-246.

张雨丰, 郑忠龙, 刘华文, 等. 基于特征图切分的轻量级卷积神经网络 [J]. *模式识别与人工智能*, 2019, 32(3): 237-246.