

基于改进 RetinaNet 的跑道边灯亮度检测

侯启真, 孙景彦*, 王浩, 段惠英

中国民航大学电子信息与自动化学院, 天津 300300

摘要 为了解决机场跑道边灯亮度检测任务中小目标检测精度低、检测速度慢的问题,提出了一种基于改进 RetinaNet 的跑道边灯亮度检测方法。在 RetinaNet 的基础上,引入倒残差结构和深度可分离卷积,以提升网络的特征提取能力和检测速度。采用 K-means 聚类算法优化目标样本的锚点框尺寸,以提升网络的检测精度。实验结果表明,相比原始方法,本方法的性能有明显提升,平均检测精度达到 97.2%,检测速度达到 25.9 frame/s。

关键词 图像处理; 跑道边灯; 亮度检测; 聚类分析; 轻量化网络

中图分类号 TP391.4

文献标志码 A

doi: 10.3788/LOP202259.0210012

Runway Edge Lights Brightness Detection Based on Improved RetinaNet

Hou Qizhen, Sun Jingyan*, Wang Hao, Duan Huiying

College of Electronic Information and Automation, Civil Aviation University of China, Tianjin 300300, China

Abstract To solve the problems of low detection accuracy and slow detection speed of small targets in the task of detecting the brightness of the runway edge lights in the airport, a method for detecting the brightness of the runway edge lights based on improved RetinaNet is proposed in this paper. Based on the RetinaNet, the inverted residual structure and depth separable convolution are introduced to improve the feature extraction ability and detection speed of the network. The K-means clustering algorithm is used to optimize the size of the anchor box of the target sample to improve the detection accuracy of the network. The experimental results show that compared with the original method, the performance of the method is significantly improved, with the average detection accuracy of 97.2% and detection speed of 25.9 frame/s.

Key words image processing; runway edge lights; brightness detection; clustering analysis; lightweight network

1 引言

机场跑道边灯是引导和指示飞行员安全着陆的必要目视助航设备,因此,对跑道边灯进行检测使其亮度符合要求,对提高飞行安全保障水平至关重要。国内机场跑道边灯亮度的现场检测方法有人工巡检^[1]和光强检测车检测等,这些检测方法只能在停航后进行,且耗时较长,不能达到实时检测的要求。

何骏^[2]通过分析单帧灯光图像光斑亮像素的方法检测跑道边灯亮度,该方法的实时性较高,但图像中的光斑状态易受图像拍摄时间、天气状况和相机参数等因素的影响,检测准确度较低。深度学习目标检测模型 RetinaNet^[3]能提取图像中丰富的特征信息并自主完成特征学习,从而实现目标的识别和分类,具有较强的鲁棒性^[4-5],被广泛应用于行人检测^[6]、交通标志识别^[7]和光学遥感图像检测^[8]等领域,并取得了良好的效果。因此,将

收稿日期: 2020-12-27; 修回日期: 2021-02-22; 录用日期: 2021-03-16

基金项目: 国家重点研发计划(2016YFB0502401)

通信作者: *1056462879@qq.com

RetinaNet 应用在不同亮度灯光的识别和分类回归中,以达到亮度检测的目的,在理论上是可行的。

RetinaNet 作为通用目标检测网络,其锚点框尺寸不完全适用于跑道边灯灯光,导致网络的检测精度较低。深层网络的参数多、模型大,无法满足低精度移动端或嵌入式设备的运行要求,难以部署到应用现场。为了更好地满足应用需求,本文基于改进 RetinaNet 模型提出了一种跑道边灯亮度检测方法。首先,建立跑道边灯灯光图像数据集,将合格与不合格的亮度灯光分别标注为 bright 类和 weak 类。然后,依据跑道边灯灯光图像中的光斑尺寸,用 K-means 聚类算法获得最佳尺寸 anchor,并去除适用于大物体检测的 anchor(尺寸为 512×512 和 256×256),增加两个尺寸为 8×8 和 16×16 的 anchor,以更好地匹配光斑。在特征提取网络中引入深度可分离卷积模块,在不影响精度的前提下减少模型参数,提升其运行速度。最后,通过数据增强方法扩充灯光图像样本,避免了训练过程中的过拟合情况,增强了网络的鲁棒性。

2 相关原理

2.1 图像采集方案

在跑道两侧符合净空要求^[9]的安全位置设置图像采集点,用 CCD 相机作为图像采集设备。以长为 3600 m、边灯间距为 60 m 的跑道为例,每个 CCD 相机的视野约覆盖 5~7 个跑道边灯,沿跑道两侧共设置 24 个图像采集点,可完成所有跑道边灯的灯光图像采集工作。跑道边灯的灯光图像采集系统如图 1 所示。

2.2 深度学习目标检测方法

基于深度学习的目标检测方法包括基于候选区域的两阶段方法和基于回归的一阶段方法^[10]。一阶段方法中,SSD(Single shot multi box detector)^[11]利




图 1 跑道边灯灯光图像采集系统示意图

Fig. 1 Schematic diagram of image acquisition system for runway edge lights

用多层卷积特征预测特定尺度范围的目标,对小目标的检测效果不理想。相比 YOLO(You only look once)方法,YOLOv2^[12]和 YOLOv3^[13]通过 anchor 机制列举目标潜在位置的检测目标,进一步提升了检测精度。二阶段方法中的区域卷积神经网络(R-CNN)^[14]和 Fast R-CNN^[15]利用线性搜索(SS)^[16]生成候选区域,再对候选区域进行特征提取,这种非端到端的网络运行速度非常缓慢;Faster R-CNN^[17]通过引入区域候选网络(RPN)获得候选区域,实现了端到端的网络训练,大大提升了网络的检测速度。一阶段目标检测方法的检测速度通常较快,但检测精度不高;而二阶段目标检测方法的检测精度较高,但检测速度略慢。

Lin 等^[18]提出了一种基于 anchor 的单阶段通用目标检测网络 RetinaNet,用 Focal Loss 函数解决了 anchor 机制密集采样引发的正负样本不均衡问题,并提升了模型的检测速度;同时,采用特征金字塔网络(FPN)进行多尺度特征融合,兼顾了模型的检测精度。RetinaNet 包括 3 部分,具体结构如图 2 所示。首先,以深度残差网络(ResNet)^[19]作为主干网络对图像进行特征提取;然后,用 FPN^[20]对各个特征层提取到的图像信息进行特征融合;最后,采用两层全卷积神经网络(FCN)进行预测,第一层子网




图 2 RetinaNet 的结构

Fig. 2 Structure of the RetinaNet

网络负责对 FPN 输出的特征图进行分类,第二层子网络负责目标位置的回归。

3 基于改进 RetinaNet 的跑道边灯亮度检测

3.1 特征提取网络

ResNet 的网络深度通常为 50 层或 101 层,实验用 101 层的 ResNet 作为基础网络。ResNet 以残差网络模块为基础构建,具有跨层连接 (Shortcut connection) 的残差模块极大减轻了深度神经网络在训练过程中的网络退化和梯度爆炸、梯度消失问题,从而为更深层的神经网络奠定了基础。随着模型卷积深度的增加,其运行时间逐渐变长,而对于应用在移动端或嵌入式设备的模型,深层卷积模型的运行速度显得尤为重要。借鉴轻量化网络 MobileNet 的设计思想,对特征提取网络进行的改进:1) 引入深度可分离卷积;2) 采用倒残差网络结构;3) 将修正线性单元 (ReLU) 激活函数替换为 ReLU6 和线性激活函数。

相比传统网络,MobileNet 引入了深度可分离卷积,可在不改变模型性能的前提下大幅减少参数量和计算量。标准卷积和深度可分离卷积的计算过程如图 3 所示,其中, M 为输入特征图的通道数, N 为输出特征图的通道数和标准卷积核的数量, D_K 为卷积核的大小。可以发现,标准深度卷积输入特征图的尺寸为 (D_w, D_h, M) , 用尺寸为 (D_K, D_K, M, N) 的标准卷积进行特征提取,输出特征图的尺寸为 (D_w, D_h, N) , 对应的计算量为 $D_K \times D_K \times M \times N \times D_w \times D_h$ 。深度可分离卷积先用尺寸为 $(D_K, D_K, 1, M)$ 的深度卷积进行单通道特征提取,再用尺寸为 $(1, 1, M, N)$ 的点卷积对特征图进行升维,输出特征图的尺寸同样为 (D_w, D_h, N) , 对应的计算量为 $D_K \times D_K \times M \times D_w \times D_h + M \times N \times D_w \times D_h$ 。其中, D_w 和 D_h 分别为特征图的宽和高。

相比标准卷积,深度可分离卷积减少的计算量可表示为




图 3 标准卷积和深度可分离卷积的计算过程。(a) 标准卷积; (b) 深度卷积; (c) 点卷积
Fig. 3 Calculation process of standard convolution and depth separable convolution. (a) Standard convolution; (b) depthwise convolution; (c) pointwise convolution

$$\frac{D_K \times D_K \times M \times D_w \times D_h + M \times N \times D_w \times D_h}{D_K \times D_K \times M \times N \times D_w \times D_h} = \frac{1}{N} + \frac{1}{D_K^2} \quad (1)$$

深度卷积网络中的卷积核数量 N 较大,卷积核大小 D_K 为 3,则深度可分离卷积可将模型参数减少至原始网络的 $1/9 \sim 1/8$ 。

特征提取网络中卷积层对特征图的提取受限于特征矩阵的维度,若先对特征图进行降采样再进行特征提取,提取的特征信息较少。因此,用倒残差网络先对特征矩阵进行扩张,再经过深度可分离卷积层进行特征提取,提高了网络的特征提取能力。倒残差模块将 M 维特征矩阵转换为 N 维特征矩阵输出的步骤如表 1 所示,其中, t 为扩展因子, s 为步长,本方法中取扩展因子为 4,步长为 1 和 2。首先用点卷积对输入特征图进行 t 倍上采样,然后将低维特征信息映射到高维空间,以扩大网络的感受野,强化模型的特征提取能力。

表 1 倒残差模块的计算步骤

Table 1 Calculation steps of the inverted residual module

Input	Operator	Output
$D_w \times D_h \times M$	Conv 1×1 , ReLU	$D_w \times D_h \times tM$
$D_w \times D_h \times tM$	D_w Conv 3×3 , step size is s , ReLU	$D_w/s \times D_h/s \times tM$
$D_w/s \times D_h/s \times tM$	Conv 1×1 , ReLU	$D_w/s \times D_h/s \times N$

用倒残差模块将高维特征映射回低维空间时,对特征矩阵的压缩会造成部分特征信息的丢失。ReLU 激活函数会增加网络的稀疏性,进一步扩大丢失的特征信息,将最后一层 ReLU 激活函数替换为线性激活函数,可缓解特征信息丢失的问题。本方法的应用场景包括低精度的移动端

备,因此,将标准卷积的激活函数 ReLU 改为 ReLU6 激活函数,并增加模型的非线性变化,以增强模型的泛化能力,改进后的线性倒残差块网络结构如图 4 所示。其中, BN 为批归一化, Conv、Conv dw 和 Conv pw 分别为标准卷积、深度卷积和点卷积。

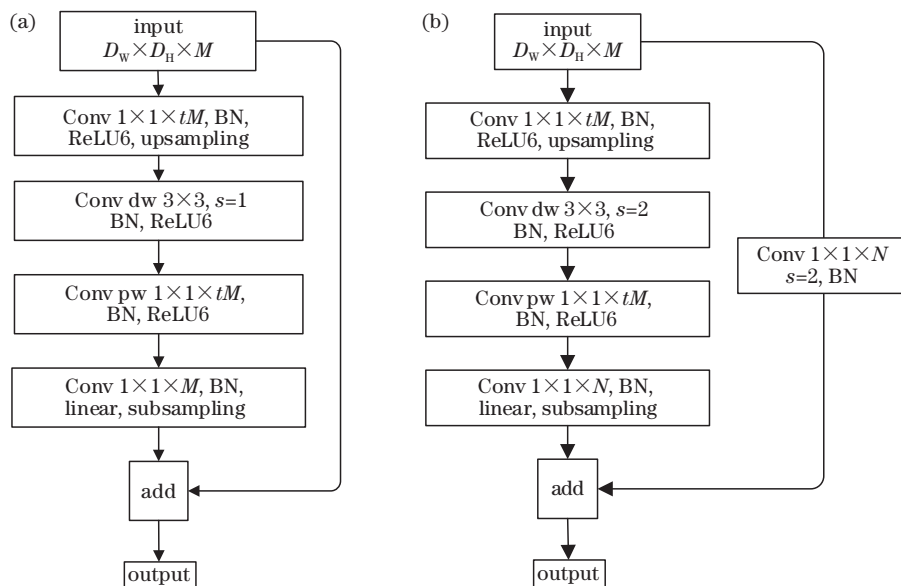


图 4 线性倒残差模块的结构。(a)恒等残差块;(b)卷积残差块

Fig. 4 Structure of the linear inverted residual module. (a) Identity residual block; (b) convolutional residual block

融合 MobileNet 的设计思想对特征提取网络进行改进,以减少模型参数,提升其运行速度,使本方法更好地应用于移动端,满足实际应用需求。改进后的特征提取网络结构如表 2 所示。其中, MaxPool 为最大池化操作, Stage 2 的 Conv block 步长 $s=1$ 。

表 2 改进特征提取网络的结构

Table 2 Structure of the improved feature extraction network

Stage	Operator	Input size
Stage 1	Conv $7 \times 7 \times 64, s=2$	$224 \times 224 \times 3$
	MaxPool $3 \times 3, s=2$	$112 \times 112 \times 64$
Stage 2	Conv block	$56 \times 56 \times 64$
	identity block $\times 2$	$56 \times 56 \times 256$
Stage 3	Conv block	$56 \times 56 \times 256$
	identity block $\times 3$	$28 \times 28 \times 512$
Stage 4	Conv block	$28 \times 28 \times 512$
	identity block $\times 22$	$14 \times 14 \times 1024$
Stage 5	Conv block	$14 \times 14 \times 1024$
	identity block $\times 2$	$7 \times 7 \times 2048$

3.2 特征金字塔网络和跑道边灯数据集的标签聚类分析

图像经过特征提取网络不同次数的下采样,得

到不同尺寸的特征图(C1~C5层),即自底向上(Bottom-up)的采样过程;自顶向下(Top-down)的采样过程则将更抽象、语义更强的高层特征图进行上采样。首先,FPN用 1×1 卷积对 C5 层进行双线性插值的上采样,生成尺寸与 C4 层相同的 P5 层;然后,通过横向连接(Lateral connection)将 P5 层和 C4 层相加,得到 P4 层。横向连接将上采样的结果和自底向上生成的相同尺寸特征图进行融合,更好地利用了底层定位细节信息。为了减轻上采样的混叠效应(Aliasing effect),P4 层经过 3×3 卷积生成最终的特征映射层 M4。FPN 经过自顶向下更新生成最终的特征映射集合 $\{M2, M3, M4, M5\}$ 。FPN 的结构如图 5 所示。

特征金字塔网络通过自底向上、自顶向下以及横向连接将不同层的特征图高效整合起来,在不增加计算量的情况下,大幅提升了网络对小物体的检测性能,并解决了物体检测中的多尺度问题。但 RetinaNet 模型中的锚点框基于人工设计,基础尺寸包括 $32 \times 32, 64 \times 64, 128 \times 128, 256 \times 256$ 和 512×512 五种,锚点框的宽高比例为 $\{1:2, 1:1, 2:1\}$,缩放比例为 $\{2^0, 2^{1/3}, 2^{2/3}\}$,每层共有 9 个 anchor。原始模型

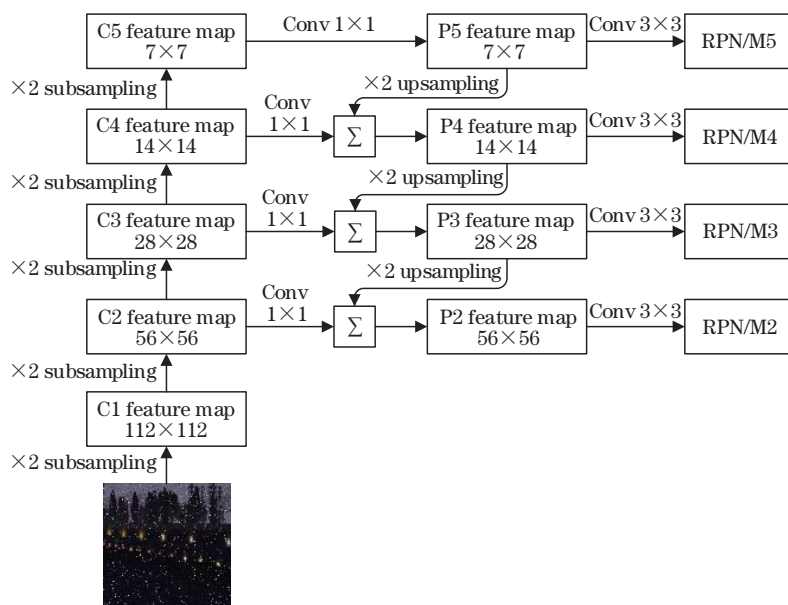


图 5 FPN 的结构

Fig. 5 Structure of the FPN

为通用的目标检测网络,对不同数据集和不同目标类型的适应性较差,而本方法根据跑道边灯灯光在图像中占比较小且大小均衡的特点,采用维度聚类方法选定尺寸和宽高比合适的跑道边灯锚点框,大大减少了原始模型中不适合跑道边灯的锚点框和运算量,加快了网络的收敛和检测速度。交并比(IoU)可以改善检测模型的性能,用锚点框 B_2 和标注框 B_1 的交并比 $X_{IoU}(B_1, B_2)$ 作为数据标签聚类的指标,则两者之间的距离 $d(B_1, B_2)$ 可表示为

$$d(B_1, B_2) = 1 - X_{IoU}(B_1, B_2) \quad (2)$$

聚类算法的步骤:1)选择 K 个标记框为初始聚类中心;2)计算每个标记框与 K 个聚类中心的距离,按照最小距离原则将其分配到最近的聚类中心;3)将每个聚类所属样本的均值作为新的聚类中心;

4)重复步骤2)和步骤3),直到聚类中心不再变化;5)得到 K 个聚类。根据实验结果最终选定适合跑道边灯灯光的锚点框尺寸为 $4 \times 4, 8 \times 8, 16 \times 16, 32 \times 32, 64 \times 64$,最佳宽高比为 $\{1:2, 1:1, 2:1\}$ 。用真实标记框进行维度聚类的方法使 anchor 尺寸更接近真实值,使模型更容易拟合待检测目标的真实位置,从而降低网络的训练难度,提高目标检测的准确度。

4 实验结果与分析

4.1 数据集

由于目前没有跑道边灯灯光图像公开数据集,因此,需要自制实验使用的数据集。在相同亮度和不同自然光干扰条件下获取跑道边灯的强自然光图像、弱自然光图像和无自然光图像,如图6(a)~




图 6 数据集图像示例。(a)强自然光图像;(b)弱自然光图像;(c)无自然光图像;(d) 1级光图像;(e) 2级光图像;(f) 3级光图像
Fig. 6 Data set image example. (a) Strong natural light image; (b) weak natural light image; (c) image without natural light; (d) image of 1-level light; (e) image of 2-level light; (f) image of 3-level light

图 6(c)所示。在无自然光且跑道边灯不同亮度的情况下,获取跑道边灯 1 级光图像、2 级光图像和 3 级光图像,如图 6(d)~图 6(f)所示。6 组跑道边灯光图像共 3600 张。

为了增加网络的鲁棒性,对跑道边灯灯光数据集进行了数据增强。考虑到跑道边灯亮度检测对图像亮度变化比较敏感,未采用曝光、高亮和模

糊等操作,而是选择水平翻转、垂直翻转、剪切和添加随机噪声操作对数据集进行增强,数据增强后的部分图像如图 7 所示。用图像标注工具 LabelImg 对灯光图像进行标注,将亮度合格与不合格的灯光分别标注为 bright 类和 weak 类,并将灯光数据集按 7:2:1 的比例随机划分为训练集、测试集和验证集




图 7 数据增强后的跑道边灯图像

Fig. 7 Runway edge light image after data enhancement

4.2 实验结果

实验环境:CPU 为 Intel Core i7-9750H,内存为 16 GB, GPU 为 NVIDIA GeForce RTX 2060, PyTorch 版本为 1.3.0, torchvision 版本为 0.4.1, CUDA 版本为 10.1, CUDNN 版本为 7.6.1。训练参数:训练轮数(Epoch)为 50,批训练数(Batch size)为 4。采用随机梯度下降算法进行参数优化,动量为 0.9,初始学习率(Learning rate)为 0.0001,权值衰减系数为 0.0001。

机场跑道边灯还包括跑道中线灯、滑行道边灯等其他助航灯,且部分助航灯与跑道边灯的相似度较高,检测时容易出现漏检和错检情况。因此,针对机场跑道边灯的图像检测,除了将平均精度均值(mAP)作为主要评价指标外,还选择召回率(Recall)和准确率(Precision)作为模型评价指标,可表示为

$$X_{\text{Recall}} = \frac{X_{\text{TP}}}{X_{\text{TP}} + X_{\text{FN}}}, \quad (3)$$

$$X_{\text{Precision}} = \frac{X_{\text{TP}}}{X_{\text{TP}} + X_{\text{FP}}}, \quad (4)$$

式中, X_{TP} 为正确检测到的跑道边灯样本数量, X_{FP} 为将非跑道边灯误检为跑道边灯的样本数量, X_{FN} 为被漏检的跑道边灯数量。考虑到将助航边灯检测应用于移动端的可能,将每秒传输帧数(FPS)也作为各模型的检测指标之一。

为了更好地评估深度学习目标检测方法对跑道边灯图像的检测性能,设计了 2 组实验。实验 1 用 SSD、Faster R-CNN、YOLOv4、RetinaNet 和改进 RetinaNet(本方法)对跑道边灯数据集中的所有图像进行训练,并在测试集上进行测试;实验 2 用改进 RetinaNet 模型在 6 组数据集上分别进行训练,并在测试集上进行测试。检测结果如表 3 和表 4 所示,跑道边灯图像测试集的检测结果显示如图 8 所示。

表 3 不同模型对机场跑道边灯的检测结果

Table 3 Test results of different models on airport runway edge lights

Model	AP (weak) /%	AP(bright) /%	mAP /%	Recall /%	FPS
SSD	84.6	85.3	85.0	85.4	24.7
Faster R-CNN	86.5	84.2	85.5	86.2	22.4
YOLOv4	94.3	95.5	95.6	95.8	26.5
RetinaNet	95.2	96.4	96.4	96.3	25.2
Ours	96.2	97.5	97.2	96.5	25.9

从实验 1 的检测结果可以发现,RetinaNet 模型的检测性能优于其他模型,而改进 RetinaNet 模型的准确率在此基础上也有一定提升。从实验 2 的检测

结果可以发现,改进 RetinaNet 模型对不同自然光照和不同亮度跑道边灯的平均检测精度无明显差异;且对白光、黄光、立式和嵌入式跑道边灯也取得了

表 4 本方法对不同数据集的检测结果

Table 4 Test results of our method on different data sets

Data set	AP (weak) /%	AP (bright) /%	mAP /%	Recall /%	FPS
Strong natural light image	94.5	95.7	95.6	95.0	26.0
Weak natural light image	96.2	96.7	96.6	96.0	25.6
Image without natural light	96.2	96.5	96.5	95.9	25.9
Image of 1-level light	96.7	96.2	96.7	96.1	25.3
Image of 2-level light	96.5	96.6	96.1	96.3	25.8
Image of 3-level light	96.2	96.5	96.7	96.0	25.9




图 8 测试集的检测结果。(a) 1级光图像;(b) 2级光图像;(c) 3级光图像;(d)强自然光图像

Fig. 8 Test results of the test set. (a) Image of 1-level light; (b) image of 2-level light; (c) image of 3-level light; (d) strong natural light image

良好的检测效果。对比发现,训练集中灯光图像的构成差异会影响模型的检测准确率。

不同焦距和天气状况下的跑道边灯图像如图 9 所示,可以发现,相机焦距、天气条件、自然光和杂

散光干扰等因素会直接影响图像中灯光的特征信息。本方法对跑道边灯图像的亮度检测具有一定的局限性,在特定条件的灯光图像训练集得到的模型不适用于检测其他条件下的跑道边灯图像。不




图 9 不同焦距和天气状况的跑道边灯图像

Fig. 9 Images of runway edge lights with different focal lengths and weather conditions




图 10 不同模型对相同图像的检测结果。(a) 3级光图像所得模型对3级光图像的检测结果;(b) 1级光图像所得模型对3级光图像的检测结果

Fig. 10 Detection results of different models on the same image. (a) Detection results of the model obtained from 3-level light image on 3-level light image; (b) detection results of the model obtained from 1-level light image on 3-level light image

同训练集所得模型对 3 级光图像的检测结果如图 10 所示,可以发现,检测结果中存在明显的误检现象,2 号灯和 3 号灯均被误检为亮度合格的灯光。

5 结 论

建立了机场跑道边灯灯光数据集,通过样本增强方法扩充了数据集,在此基础上用基于深度学习的目标检测方法对跑道边灯亮度是否合格进行定性检测。实验结果表明,本方法在相机参数固定、无杂散光干扰的跑道边灯图像数据集上的检测准确率较高,验证了本方法应用于机场跑道边灯图像亮度检测的有效性和可靠性。基于 RetinaNet 模型使用维度聚类方法确定适合跑道边灯的预选框,借鉴 MobileNet 的思想使模型轻量化,提升了检测速度。考虑到实际应用场景,未对满足复杂条件和兼容性强的通用检测模型进行研究。为了增强实际检测场景下模型的稳定性和兼容性,还需要建立更大容量和更多样的数据集,如利用跑道边灯红外图像通过图像融合^[21]方法对跑道边灯图像进行增强,以更全面准确地描述光斑的细节特征,完善模型的检测性能。虽然本方法仅适用于特定情况下获取的跑道边灯图像,但为后续相关研究提供了研究思路和借鉴,具有一定的实用价值。

参 考 文 献

- [1] Han H M. Development of the state detection and early warning system of airport runway side lights [D]. Jinan: Shandong Normal University, 2015.
韩慧敏. 机场跑道边灯状态检测和预警系统的研制 [D]. 济南: 山东师范大学, 2015.
- [2] He J. Design and realization of image analization-based airport navigation light surveillance system[J]. Equipment Manufacturing Technology, 2010(6): 57-59.
何骏. 基于图像分析的机场助航灯光监控系统的设计与实现[J]. 装备制造技术, 2010(6): 57-59.
- [3] Lin T Y, Goyal P, Girshick R, et al. Focal Loss for dense object detection[C]//2017 IEEE International Conference on Computer Vision (ICCV), October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 2999-3007.
- [4] Zhang R, Li W P, Mo T. Review of deep learning [J]. Information and Control, 2018, 47(4): 385-397, 410.
张荣, 李伟平, 莫同. 深度学习研究综述[J]. 信息与控制, 2018, 47(4): 385-397, 410.
- [5] Hua X, Wang X Q, Wang D, et al. Multi-objective detection of traffic scenes based on improved SSD[J]. Acta Optica Sinica, 2018, 38(12): 1215003.
华夏, 王新晴, 王东, 等. 基于改进 SSD 的交通大场景多目标检测[J]. 光学学报, 2018, 38(12): 1215003.
- [6] Yuan P P, Zhang L. Pedestrian attribute recognition based on deep learning[J]. Laser & Optoelectronics Progress, 2020, 57(6): 061001.
袁配配, 张良. 基于深度学习的行人属性识别[J]. 激光与光电子学进展, 2020, 57(6): 061001.
- [7] Qu Z H, Shao Y M, Deng T M, et al. Traffic sign detection and recognition under complicated lighting conditions[J]. Laser & Optoelectronics Progress, 2019, 56(23): 231009.
屈治华, 邵毅明, 邓天民, 等. 复杂光照条件下的交通标志检测与识别[J]. 激光与光电子学进展, 2019, 56(23): 231009.
- [8] 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.
- [9] Civil Aviation Industry Standard of the People's Republic of China MH-5001—2013 Technical Standard for Civil Airport Flight Area[S]. Beijing: Civil Aviation Administration of China, 2013: 33-39.
中华人民共和国民用航空行业标准 MH-5001—2013 民用机场飞行区技术标准[S]. 北京: 中国民用航空局, 2013: 33-39.
- [10] Zhao Z Q, Zheng P, Xu S T, et al. Object detection with deep learning: a review[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30(11): 3212-3232.
- [11] 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.
- [12] Redmon J, Farhadi A. YOLO9000: better, faster, stronger[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 6517-6525.
- [13] Redmon J, Farhadi A. YOLOv3: an incremental improvement[EB/OL]. (2018-04-08) [2020-12-10]. <https://arxiv.org/abs/1804.02767>.
- [14] 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.
- [15] 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.
- [16] Uijlings J R R, Sande K, Gevers T, et al. Selective search for object recognition[J]. International Journal of Computer Vision, 2013, 104(2): 154-171.
- [17] 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.
- [18] Lin T Y, Goyal P, Girshick R, et al. Focal Loss for dense object detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2): 318-327.
- [19] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [20] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 936-944.
- [21] Li H, Zhang L M, Jiang M R, et al. An infrared and visible image fusion algorithm based on ResNet152[J]. Laser & Optoelectronics Progress, 2020, 57(8): 081013. 李恒, 张黎明, 蒋美容, 等. 一种基于 ResNet152 的红外与可见光图像融合算法[J]. 激光与光电子学进展, 2020, 57(8): 081013.