

基于计算机视觉的客机舱门识别与定位技术研究

叶 润¹, 张 成¹, 李 旭², 陈 铭¹

(1. 电子科技大学 自动化工程学院, 成都 611731;

2. 北京博维航空设施管理有限公司, 北京 100621)

摘要: 登机桥是机场将航站楼与飞机连接的活动通道, 登机桥与客机舱门对接系统的智能化变得尤为重要; 对于基于计算机视觉的客机舱门识别与定位系统, 其关键组成部分是目标检测系统; 传统的目标检测算法通过提取传统手工特征进行学习, 不能达到鲁棒性好、速度快、准确性高的检测要求; 基于迁移学习在深度学习上的应用, 利用 SSD (Single Shot Multibox Detector) 算法, 以轻量化的 MobileNet 作为特征提取网络, 实现了鲁棒性好、准确度高的目标检测模型, 完成对客机舱门的识别与定位, 对不同样式的舱门、部分遮挡、背景变化、光照变化、运动模糊具有鲁棒性, 能准确完成识别功能, 完成对舱门在当前视觉图像中的相对位置的解算。

关键词: 深度学习; 目标检测; MobileNet; SSD; 登机桥; 飞机舱门

Research on Recognition and Positioning Technology of Passenger Aircraft Door Based on Computer Vision

Ye Run¹, Zhang Cheng¹, Li Xu², Chen Ming¹

(1. School of Automation Engineering, University of Electronic Science and Technology,

Chengdu 611731, China; 2. Beijing Bowei Aviation Facilities Management Co., Ltd., Beijing 100621, China)

Abstract: The boarding bridge is the active passageway connecting the terminal with the aircraft at the airport. The intelligentization of the docking system between the boarding bridge and the passenger cabin door becomes particularly important. For the passenger cabin door recognition and positioning system based on computer vision, the key component is the target detection system. The traditional target detection algorithm learns by extracting traditional manual features, which cannot meet the detection requirements of good robustness, fast speed and high accuracy. Based on the application of transfer learning in deep learning, using the SSD (Single Shot Multibox Detector) algorithm, using lightweight MobileNet as a feature extraction network, the target detection model with good robustness and high accuracy is achieved. The identification and positioning of the model are robust to different styles of doors, partial occlusion, background changes, lighting changes, and motion blur, and can accurately complete the recognition function and solve the relative position of the doors in the current visual image.

Keywords: deep learning; target detection; MobileNet; SSD; boarding bridge; aircraft door

0 引言

旅客登机桥是大型的机电设备, 作为活动通道将飞机与航站楼连接在一起, 实现飞机与机场航站楼之间的活动联接, 供旅客及工作人员方便安全地通行。旅客登机桥包含旋转平台、活动通道以及帮助通道运动的运动机构等。旅客登机桥有效利用了多层空间, 节省运营成本, 提高机场运行效率, 优化机场的管理, 对发展现代化机场有重要意义^[1]。

登机桥的发明和使用最早是在欧美等国家开始研究^[2-4]。2002年, 德温·C·斯潘塞等提出自动登机桥成像

系统^[5-6], 在飞机舱门附近安装多个光学反射装置, 在登机桥端设置照明装置和摄像头, 通过计算机软件进行处理并控制登机桥实现对接。该方法缺点在于需要对飞机机身进行改造。2012年, 邓览提出利用基于数字图像处理技术和双目视觉测量原理的登机桥全自动系统^[7], 提取图像边缘, 生成舱门的外接矩形框, 与舱门模板进行比对识别, 利用矩形框坐标实现舱门的定位对接, 但该方法对图像质量敏感。2017年, 马科斯·佩雷斯·佩雷斯和赫塞·门迪奥拉歌蒂亚·朱莉安娜申请了用于将乘客登机桥定位在飞机上的方法^[8]。该方法类似人脸识别的思路, 从舱门周围其他多个特征入手, 是先对飞机舱门和舷窗的形状位置分布特

收稿日期: 2020-08-05; 修回日期: 2020-08-31。

基金项目: 国家自然科学基金资助项目(61703060, 61973055); 四川省科技计划项目(2019YJ0165)。

作者简介: 叶 润(1986-), 男, 安徽庐江人, 博士, 助理研究员, 主要从事无线传感器、定位技术、智能控制、机器视觉等方向的研究。

引用格式: 叶 润, 张 成, 李 旭, 等. 基于计算机视觉的客机舱门识别与定位技术研究[J]. 计算机测量与控制, 2021, 29(3): 224-229.

征进行检测,再计算拟合它们中心点的沿线,并分析图像的透视情况来计算桥头转动的角度。2016年, Tan Hong Soon 等^[9]提出使用摄像头和传感器识别飞机,并使用高精度有源线激光轮廓传感器检测飞机舱门的垂直边缘和下边缘,通过控制器模块对登机桥进行控制与移动。2018年,波音公司 J·W·格拉特费尔特等也提出了自动部署旅客登机桥的系统和方法^[10],使用传感器与控制器相互协作达到登机桥自动完成对接的目的,但该方法着重于控制舱门与登机桥的距离,不能全局精确定位。2019年,李剑思等提出一种登机桥停靠方法^[11],通过构建登机桥本地坐标系和地面坐标系,利用登机桥前端的双目摄像机进行外部参数标定,识别、跟踪舱门并计算出舱门下方两个角点与连线中点的位置,实现登机桥的自动停靠。

基于计算机视觉的客机舱门识别与定位系统的处理对象是客机与登机桥对接过程的视频,用于拍摄的摄像机安装在登机桥上。对获取的视频进行分析,由于登机桥运动时晃动明显,导致目标图像发生模糊,对接过程中由于摄像头视角变化,视频中的舱门发生畸变,并非规则的矩形;登机桥和客机舱门对接处于室外环境,而且系统需要保证能够全天候工作,所以系统需要克服日间舱门上由于遮挡产生的阴影与夜间的偏暗画面带来的识别困难;同时客机舱门并非完全相同,不同机型与所属航空公司有不同的涂装;检测模型需要有较高的检测速度来满足实时检测的需求。

针对上述情况,本文对目标检测算法、深度学习理论进行研究,对 SSD 模型进行深入地学习,利用迁移学习在深度学习上的应用实现对机场实地拍摄的舱门图像进行识别与定位的关键任务,完成舱门位置的解算。

1 轻量级卷积神经网络

随着 CNN 在图像识别领域的广泛应用,深度神经网络将计算机视觉任务的性能大大提高,对于网络结构而言,目前总体的趋势为了构建具有更高准确性的网络而建立更深、更复杂的网络结构。但是复杂的高维度神经网络在尺度和速度上很难适应普通设备的运算能力。而 MobileNet^[7]提出了一个高效的轻型网络架构,基于深度可分级卷积 (Depthwise Separable Convolution) 构建了一种轻量化的卷积神经网络。通过引入两个超参数构建体积小、延迟低的模型,可有效地在延迟和准确率之间折中。这些超参数允许依据约束条件选择合适大小的模型。

1.1 深度可分离卷积

MobileNet 中的核心部分是用于替代标准卷积的深度可分离卷积,通过深度可分离卷积提取输入特征。方法的基本原理是将标准卷积分解为深度卷积 (depthwise convolution) 和逐点卷积 (pointwise convolution),大幅降低参数数量和计算量,减小模型架构复杂度和尺度。卷积的分解过程如图 1 所示。

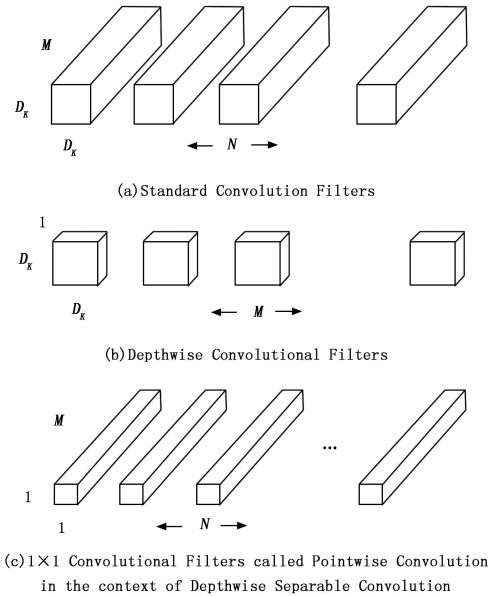


图 1 深度可分离卷积原理示意图

其中:输入的特征映射 F 尺寸为 (D_F, D_F, M) ,采用的标准卷积 K 为 (D_K, D_K, M, N) ,输出的特征映射 G 的尺寸为 (D_G, D_G, N) 。

标准卷积的计算公式为:

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

设定输入的通道 (channels) 数目为 M ,输出的通道数目为 N 。对应的计算量为 D_K, D_K, M, N, D_F, D_F 。

标准卷积 (D_K, D_K, M, N) 可以被拆分为深度卷积和逐点卷积,其中深度卷积负责滤波,卷积尺寸为 $(D_K, D_K, 1, M)$,输出大小为 (D_G, D_G, M) ;逐点卷积负责进行通道的,尺寸为 $(1, 1, M, N)$,得到输出为 (D_G, D_G, N) 。

深度卷积的卷积公式为:

$$\hat{G}_{k,l,n} = \sum_{i,j} \hat{K}_{i,j,m} \cdot F_{k+i-1,l+j-1,m} \quad (2)$$

其中: \hat{K} 是深度卷积,卷积核为 $(D_K, D_K, 1, M)$,其中 m_m 个卷积核作用在 F 中第 m_m 个通道上,产生上第 m_m 个通道输出。

深度卷积和逐点卷积的计算量为 $D_K, D_K, M, N, D_F, D_F + M, N, D_F, D_F$,与标准卷积相比较减少了:

$$\frac{D_K \cdot D_K \cdot M \cdot D_F \cdot D_F + M \cdot N \cdot D_F \cdot D_F}{D_K \cdot D_K \cdot M \cdot N \cdot D_F \cdot D_F} = \frac{1}{N} + \frac{1}{D_K^2} \quad (3)$$

一般情况下, N 比较大,而如果采用 3×3 卷积核,对比标准卷积,深度可分离卷积将降低 $8 \sim 9$ 倍的计算量,参数量也减少了,而只有很小的准确率上的损失。

1.2 网络结构与超参数

标准卷积与 MobileNet 使用的深度可分离卷积的结构对比如图 2 所示。

深度可分离卷积作为 MobileNet 的基本组件,在实际




图 2 深度可分离卷积网络结构示意图

应用中在其后加入批标准化层 (batchnorm, BN), 并使用 ReLU 激活函数。分析整个网络与参数和计算量的分布可知, MobileNet 共有 28 层 (不包含平均池化与 softmax 层), 其中利用步长为 2 的深度卷积进行下采样, 而非采用池化层。计算量和参数基本大部分集中在 1×1 卷积上, 除此之外全连接层占用较多参数。值得关注的是, 深度可分离卷积中引入更多的 ReLU 函数, 增加了模型的非线性变化, 增强了模型的泛化能力。

MobileNet 还提供两个超参数用于模型的轻量化: 宽度乘数 α (width multiplier) 与分辨率乘数 ρ (resolution multiplier)。

(1) 宽度乘数 α 使得输入通道 M 更新为 αM , 输出通道更新为 αN , 则深度卷积和逐点卷积的计算量为 $D_K \cdot D_K \cdot \alpha M \cdot D_F \cdot D_F + \alpha M \cdot \alpha N \cdot D_F \cdot D_F$, 通常设 $\alpha \in (0, 1]$ 。计算量减少了:

$$\frac{D_K \cdot D_K \cdot \alpha M \cdot D_F \cdot D_F + \alpha M \cdot \alpha N \cdot D_F \cdot D_F}{D_K \cdot D_K \cdot M \cdot N \cdot D_F \cdot D_F} = \frac{\alpha}{N} + \frac{\alpha}{D_K^2} \quad (4)$$

宽度乘数将计算量降低了约 α^2 倍, 其参数量也会下降, 能方便地控制模型大小。

(2) 分辨率乘数 ρ 的作用是控制输入的分辨率。

深度卷积和逐点卷积的计算量为 $D_K \cdot D_K \cdot \alpha M \cdot \rho D_F + \rho D_F + \alpha M \cdot \alpha N \cdot \rho D_F \cdot \rho D_F$, 通常设 $\rho \in (0, 1]$ 。通常设置输入分辨率为 224, 192, 160 和 128。计算量减少了:

$$\frac{D_K \cdot D_K \cdot \alpha M \cdot \rho D_F \cdot \rho D_F + \alpha M \cdot \alpha N \cdot \rho D_F \cdot \rho D_F}{D_K \cdot D_K \cdot M \cdot N \cdot D_F \cdot D_F} = \frac{\alpha \rho}{N} + \frac{\alpha^2 \rho^2}{D_K^2} \quad (5)$$

分辨率乘数将计算量降低了约 α^2 倍, 但不改变参数数量。参数的引入对 MobileNet 的性能有一定影响, 其提出是为了能在准确度与计算量和模型大小之间做出折中。

2 客机舱门的检测模型构建

对于目标检测与识别, 国际上有多种不同场景的公开数据集。本文利用在大型数据集上训练后的模型, 即预训练模型, 进行对本地目标数据集的迁移学习。本文选用 MS COCO 数据集上预训练得到的 MobileNet-SSD 模型作为预训练模型。

2.1 MS COCO 数据集

COCO (Common Objects in Context) 数据集由微软等

企业赞助, 是大规模的对象检测、分割和描述数据集。COCO 包含 91 个物品类别, 150 万个目标实例, 80 个目标类别, 进行了目标分割、上下文识别、超像素物体分割, 包含 33 万张图像, 已标记的图像大于 20 万张, 每张图像有 5 条图像描述, 图像中含有标记有关键点的 25 万人。COCO 在 2017 年更新的数据集中, 分配了 11.8 万张训练图片, 5 千张测试图片。

COCO 数据集的标注以 JSON 格式存储, 对数据信息的格式和数据类型有明确的标准。类似于 PASCAL VOC 数据集, COCO 数据集的标注文件包含文件 ID, 种类 ID, 分割和区域信息、边界框信息等。

2.2 基于 MobileNet 网络的 SSD 舱门检测模型构建

2016 年 Liu 等人提出了 SSD 算法^[13], 该算法结合了 YOLO 的回归思想以及 Faster R-CNN 的 anchor 机制, 使得检测速度和精度均得到了保证^[14]。

将 SSD 算法的主干网络 VGG-16 替换为 MobileNet-v1 就得到了 MobileNet-SSD 模型, 在 COCO 数据集上进行训练, 提取图像特征。对习得的特征提取参数进行冻结, 即冻结网络前端的层, 保留网络提取图像特征的能力, 对最后的卷积层 (SSD 算法把 VGG 的 FC6、FC7 全连接层替换为卷积层) 进行分类训练, 得到期望的舱门检测模型。

SSD 通过对主干网络后的 5 个卷积层的特征图输出用大小为 3×3 的卷积核进行卷积, 计算分类与回归的置信度。

MobileNet-SSD 的损失函数由分类和回归两部分组成:

$$L(x, c, l, g) = \frac{1}{N} (L_{conf}(x, c) + \alpha L_{loc}(x, l, g)) \quad (6)$$

式中, N 代表选取的预设框数量, L_{loc} 表示定位的偏移量损失:

$$L_{loc}(x, l, g) = \sum_{i \in Pos} \sum_{m \in \{cx, cy, w, h\}} x_{ij}^k smooth_{L1}(l_i^m - g_j^m) \quad (7)$$

where $smooth_{L1}(x) = \begin{cases} 0.5x^2 & \text{if } |x| < 1 \\ |x| - 0.5 & \text{otherwise} \end{cases}$

其中: l_i^m, g_j^m 分别代表 m 类别之中的第 i 个预测框、第 j 个真值框。 x_{ij}^k 指的是第 i 个预测框与第 j 个真值框对于类别 k 是否匹配, 匹配时值取 1, 否则取 0。边界框的中心点坐标为 (cx, cy) , 边界框的宽为 w , 高为 h 。

损失函数中的另一部分 L_{conf} 为分类损失, 定义为正例损失与负例损失:

$$L_{conf}(x, c) = - \sum_{i \in Pos} x_{ij}^p \log(\hat{c}_i^p) \quad \text{where } \hat{c}_i^N = \frac{\exp c_i^0}{\sum_n \exp c_i^p} \quad (8)$$

其中第一项中预测框 i 与真值框 j 关于类别 p 匹配, p 预测的概率越高, 损失越小。第二项中表示预测框内并无目标, 测预测为背景的概率越高, 损失越小。同时, 概率 \hat{c}_i^p 通过 softmax 产生。

3 基于 MobileNet-SSD 模型的舱门识别与定位

3.1 网络参数初始化

在开启模型训练之前, 首先要创建标签 (Label) 类别文件, 其次要对管道配置文件自定义, 重要参数见表 1。

其中 `batchsize` 与 `learning_rate` 两个参数需要动态地调节, 通常 `batchsize` 减半时, `learning_rate` 需要降低一个数量级。而 `batchsize` 的大小与实验设备的 GPU 显存密切相关, 由于本实验平台 GPU 显存仅为 2GB, 经多次尝试, 可以进行训练的最大 `batchsize` 为 8, 而更大的 `batchsize` 能更全面地拟合图像特征。若初始学习率过大, 则很可能导致梯度爆炸, 出现训练 Loss 为 Nan 的错误, 导致模型发散, 训练失败。

表 1 模型配置部分参数表

参数	描述	设定值
<code>num_classes</code>	目标种类的数量	1
<code>iou_threshold</code>	判断是否检测到目标	0.6
<code>score_threshold</code>	判断边界框是否需要舍弃	1e-8
<code>batchsize</code>	每次从 TFrecord 中读取图像数量	8
<code>initial_learning_rate</code>	初始学习率	0.00001
<code>momentum_optimizer_value</code>	学习中的动量参数	0.9
<code>Decay_factor</code>	学习率衰减因子	0.95
<code>fine_tune_checkpoint</code>	微调的检查点文件路径	"/model.ckpt"
<code>num_steps</code>	模型迭代步数	200000
<code>num_examples</code>	评估时参与的样本数量	100
<code>metrics_set</code>	评估标准设置	"coco_detection_metrics"

3.2 检测性能评估与分析

使用上述的配置文件对所设计的模型进行 50 000 步迭代后, MobileNet-SSD 模型对视频图像中的舱门识别已经有比较好的效果, 效果如图 3 所示。

由图 3 可知, 构建的 MobileNet-SSD 微调模型准确率高, 漏检率低, 对光照、姿态、模糊、阴影等变化具有较好的鲁棒性, 对不同样式的舱门也有着较好的普适性。

1) 对模型在测试集上进行评估。

IOU 即交并比, 指的是预测框与真值框的重叠部分与两者并集做除法, mAP (Mean average precision) 为均值平均精度, AR (Average recall) 为平均召回值, `classification loss` 即分类损失, `localization loss` 即定位损失, `total loss` 为模型的总损失。

从图 4~6 中训练过程的 loss 图像可以看出, 训练过程中 20 000 step 前 loss 的平均水平下降速度较快, 随后 loss




图 3 不同环境下的舱门识别结果

保持在 2.6 左右, 跳动幅度在 1 左右。在 30 000 step 时 loss 的平均水平已经趋近稳定。证明该实验选取了合适的学习参数使整条 loss 曲线平稳下降。

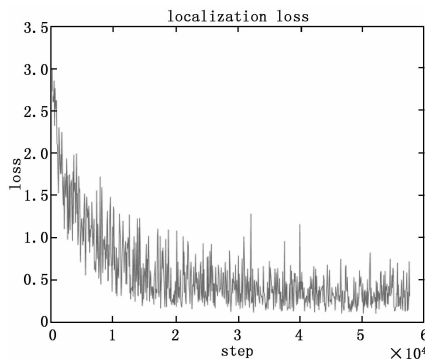


图 4 训练集定位损失




图 5 训练集分类损失

同时图像中 loss 曲线虽然整体下降, 但曲线的“宽度”较大, 在训练后期不利于模型的拟合, 准确度难以进一步提高。说明相邻两次训练中使用样本的方差太大, 需要增




图 6 训练集总损失

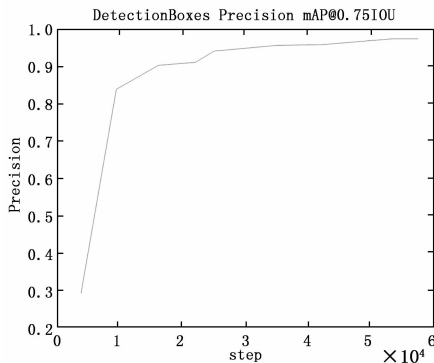


图 9 测试集平均准确度 (IOU=0.75)

大 batchsize, 增加样本量, 来不断训练和完善模型。

从图 7~9 的测试集准确度图像可以看出, 由于采用预训练模型提供的特征提取器, 训练过程中模型准确率在 10 000 step 前后已经有很大提升, 达到 0.6 mAP, 最终稳定在 0.849 mAP。如果放宽预测框与实际标注框的重合比例, 当 IOU 取 0.5 时, 在 50 000 step 后 mAP 到达了 0.99 的水平, 即使 IOU 取 0.75 时, 在 50 000 step 后 mAP 也到达了 0.97 的水平。说明该模型对舱门的检测能力很强, 后通过对比训练集和测试集的数据, 也证明模型没有发生过拟合。

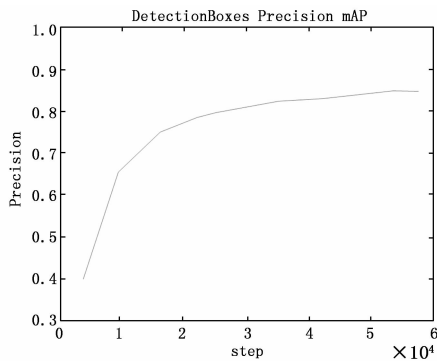


图 7 测试集平均准确度

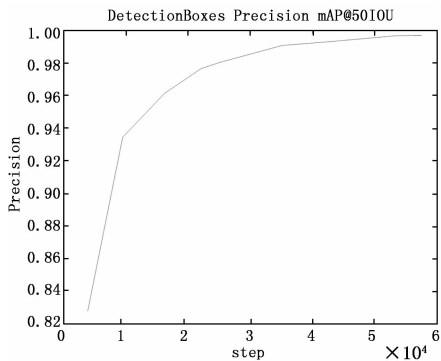


图 8 测试集平均准确度 (IOU=0.5)

从图 10 和图 11 的模型训练集与测试集的表现看出, 模型训练充分, loss 函数收敛速度较快, 识别准确率高, 未见过拟合, 训练集与测试集数据符合预期结果。

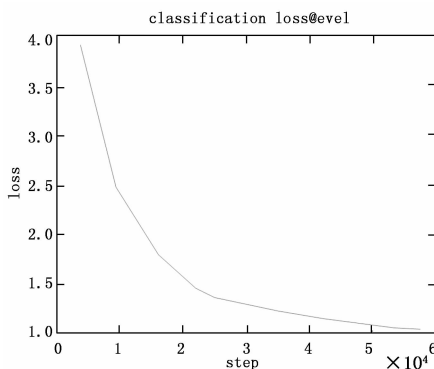


图 10 测试集分类损失

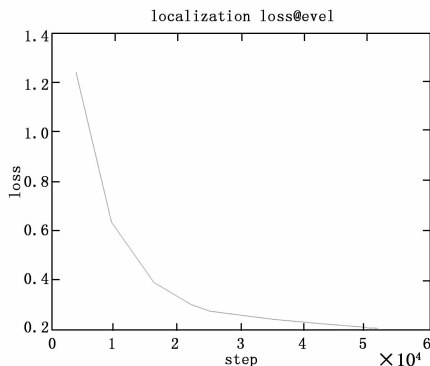


图 11 测试集定位损失

2) 识别的效率分析。

使用 100 张分辨率为 1 920×1 080 的图像进行测试, 前 10 张模型推断用时 (秒) 为: 5.566 57, 0.068 96, 0.068 95, 0.068 95, 0.070 95, 0.069 95, 0.070 95, 0.070 95, 0.072 97, 0.069 96。

由于第一张图像的计时包含了模型初始化、创建会话 (session) 等操作, 耗时较长且不能代表模型推断的速度, 所以排除该数据, 对剩余 99 条计时数据计算平均值, 得到结果为: 0.071 36 (秒)。

本模型得到平均检测耗时约为 0.072 秒每帧。从摄像机获取的实地检测视频的最高帧率为 12 帧每秒, 检测耗时需要低于 0.083 秒每帧即可完成实时检测任务。由此可知,

本方法平均检测耗时低于需求耗时, 能够完成实时舱门识别与定位。

相比 Github 中 TensorFlow Object Detection 子页面 detection_model_zoo.md 提供的数据显示, MobileNet-SSD 在 MS COCO 数据集上的预训练模型的推断速度平均为 30 毫秒。本模型与其的差距在于两个方面: 1) 使用的图片分辨率不同, 本实验的测试数据是分辨率为 $1\ 920 \times 1\ 080$ 的图像, 图像尺寸越大, 检测耗时越高; 2) 本地模型相比预训练模型, 没有对硬件资源进行充分利用。

3.3 舱门位置信息的输出与交互

由模型获得检测结果后, 提取边界框 (bounding box) 的坐标数据, 计算出中心点坐标并利用 OpenCV 库中的函数进行标记。

在进行舱门检测前, 需要获取舱门对接后的图像, 以确定舱门移动终点的位置坐标。利用终点坐标与边界框中心点坐标进行比较, 判断出当前舱门相较于终点还需要移动的方向, 为下一步登机桥的移动做出指导。同时将相关信息打印在图像上, 使得输出更加直观。

输出的视频截图展示如图 12 和图 13, 两图由上至下分别为匹配中、需要向左、向上移动、 x 轴坐标、完成匹配对接成功。输出框的中心红点即为对舱门中心的检测, 图片的左上角给出了该预测中心点的坐标信息, 同时也给出了当前情况下的动作要求, 如前进、左转、对接完成等信息。




图 12 输出的视频截图 (对接中)




图 13 输出的视频截图 (对接完成)

4 结束语

本文首先对基于计算机视觉的客机舱门识别与定位系统的要求进行分析, 综述了舱门识别对接的研究现状, 后对 MobileNet 的结构与特点进行介绍, 根据任务需求构建基于 MobileNet 与 SSD 的舱门检测网络模型, 对模型的损失函数进行分析, 实现了基于 MobileNet-SSD 的舱门检测模型。并对 MobileNet-SSD 模型各个环节进行详细阐述, 对开发环境的选择与配置、数据集的预处理、模型训练的参数配置与输出结果进行设计与分析, 展示了训练后的模型的性能和含有对接指导信息的输出图像结果。从实验的结构中分析可以看出, 本文设计的 MobileNet-SSD 模型对舱门的识别有着很好的识别效果, 而且在不同的环境、角度、距离、舱门类型等干扰下仍然有很强的鲁棒性。该实验对客机舱门自动对接的实现具有十分重要的工程意义。

参考文献:

- [1] 毛文清. 解析机场登机桥 [J]. 建筑创作, 2012 (6): 129-133.
- [2] Helen N. Boarding Basics [J]. Passenger Terminal World, 2012, 2012 (Suppl.): 94-95.
- [3] Hazel K. Legacy of Innovation [J]. Passenger Terminal World, 2015, 2015 (Suppl.): 126-127.
- [4] Paulina M. Still Nifty at Fifty [J]. Passenger Terminal World, 2009, 2009 (3): 87-87.
- [5] 黄健明. 新一代智能型旅客登机桥研发 [D]. 广州: 华南理工大学, 2018.
- [6] 德温·C·斯潘塞, 奥哈德·I·昂纳. 自动与飞机停靠在一起的旅客登机桥或类似装置的成像系统 [P]. CN1639003, 2005-07-13
- [7] 邓 览. 基于计算机视觉的登机桥全自动接机系统设计 [J]. 科技创新导报, 2012 (13): 43-46.
- [8] 马科斯·佩雷斯·佩雷斯. 用于将乘客登机桥定位在飞机上的方法 [P]. 中国专利: CN201780030988.8, 2017-5-15.
- [9] Tan Hong Soon, Toh Chee Hwee, Tan Han Leong. Automatic passenger boarding bridge docking system [P]. US10392130, 2019-08-27.
- [10] W·格拉特费尔特, B·D·劳克林. 用于自动部署旅客登机桥的系统和方法 [P]. 中国专利: CN109110147A, 2019-01-01.
- [11] 李剑思, 林姝含, 郑文涛. 一种登机桥停靠方法 [P]. 中国专利: CN110641721A, 2020-01-03.
- [12] Howard A G, Zhu M, Chen B, et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications [J]. arXiv preprint arXiv: 1704. 04861, 2017.
- [13] Liu W, Anguelov D, Erhan D, et al. SSD: Single Shot Multi Box Detector [J]. 2015.
- [14] 李 丹. 基于深度学习的目标检测综述 [J]. 科技经济导刊, 2019, 27 (13): 7-8.