

基于改进 Mask-RCNN 算法的车位检测研究^{*}

党顺峰¹,熊锐¹,李继辉²,陈灿奇¹,陈振威¹,吴鑫¹

(1 广东工业大学机电工程学院,广州 510006;

2 中国科学院长春光学精密机械与物理研究所,长春 130033)

摘要: 车位检测是自动泊车至关重要的环节,在复杂情况下,为同时实现自动泊车视觉系统对车位识别和车位状态分类,提出一种基于改进掩模区域卷积神经网络(Mask Region Convolutional Neural Network, Mask-RCNN)算法的 C-Mask-RCNN 车位检测算法。C-Mask-RCNN 车位检测算法通过在 Mask-RCNN 算法的 ResNet50 特征提取网络中增加卷积块注意力模块(Convolutional Block Attention Module, CBAM),使模型更加关注车位相关的语义信息。利用 C-Mask-RCNN 车位检测算法中的区域卷积神经网络(Regions with Convolution Neural Network, RCNN)分支网络进行车位检测,实现 Keypoint 分支进行车位 8 个关键点的预测。实验结果表明,改进后的 C-Mask-RCNN 车位检测算法较 Mask-RCNN 算法在车位类型识别平均精确率上提升 7.4%,在车位状态识别平均精确率上提升 11.1%,并且车位线关键点预测的平均像素误差减少 15.1 px。

关键词: 车位检测;掩模区域卷积神经网络;注意力机制;关键点预测

中图分类号: TP391 **文献标志码:** A **文章编号:** 1671-3133(2021)01-0091-08

DOI: 10.16731/j.cnki.1671-3133.2021.01.016

A research on parking slot detection based on improved Mask-RCNN algorithm

DANG Shunfeng¹, XIONG Rui¹, LI Jihui², CHEN Canqi¹, CHEN Zhenwei¹, WU Xin¹

(1 School of Electromechanical Engineering, Guangdong University of Technology,

Guangzhou 510006, China; 2 Changchun Institute of Optics, Fine Mechanics and Physics,

Chinese Academy of Sciences, Changchun 130033, China)

Abstract: Parking slot detection is a crucial part of automatic parking. In complex situations, in order to achieve automatic parking vision system for parking slot recognition and parking slot status classification. A parking slot detection algorithm of C-Mask-RCNN was proposed based on improved algorithm of Mask Regions Convolutional Neural Network (Mask-RCNN). C-Mask-RCNN adds Convolutional Block Attention Module (CBAM) to ResNet50 feature extraction network of original Mask-RCNN algorithm to make the model pay more attention to the semantic information related to parking slot. The Regions with Convolution Neural Network (RCNN) branch network of C-Mask-RCNN was used to detect parking slot, and the Keypoint branch was used to predict the 8 keypoints of parking slot. The experimental results show that the C-Mask-RCNN algorithm slot-type-detection average accuracy is improved by 7.4%, the slot-status-detection average accuracy is improved by 11.1%, and the average pixel error of keypoints is reduced by 15.1 px.

Keywords: parking slot detection; Mask-RCNN; attention mechanism; keypoint prediction

0 引言

车位检测的准确性是自动泊车系统可靠性的关键,直接影响着自动泊车系统的效率以及泊车安全。

目前,车位检测技术主要基于超声波传感器和视觉传感器。基于超声波进行车位检测也是最早的车位检测技术,超声波传感器的工作原理是通过超声波发射装置向外发出超声波,通过接收器接收到的回波时间

^{*} 国家重点研发计划项目(2017YFB0103300);吉林省科技发展计划资助项目(20200201294JC)

差来测算距离,以此判断出障碍物的位置和距离^[1-2]。超声波检测使用场景有限,只能根据障碍物来判断车位,当车位内存在障碍物时,检测信号容易受到干扰,可能导致车位误判。视觉传感器利用摄像头获取环境状态图片,所获取的图片包括物体的颜色、形状和纹理等信息。目前国内外基于视觉传感器的车位检测研究较多,所涉及的方法有 Radon 矩阵、Hough 变换和 K-Means 算法等。朱旺旺等人^[3]利用改进的 Radon 矩阵对边缘提取后的车位图像进行直线检测,根据角度变化时出现的局部峰值确定直线的方向,实验证明改进后的 Radon 矩阵中的元素值更适用于车位线识别。文献[4]~文献[6]利用 Hough 变换从灰度轮廓图像中提取车位直线信息,并且文献[4]用图像样本的 Haar 特征对车辆样本进行训练,判断所检测车位是否被车辆占用。上述传统算法主要是依赖像素的变化来手工提取车位特征,在停车位存在遮挡、车位线模糊等复杂场景下检测效果较差,且环境光照条件的变化会加大车位线特征提取的难度,使其难以实现车位识别与车位状态判断。

近年来,深度学习在视觉感知中得到广泛应用。相较于传统的手工提取特征算法,深度学习算法可以在图像数据中实现端到端的自主学习,获得特征提取的能力。WU 等人^[7]提出一种基于图像分割的高度融合卷积网络来提取车位线的线性特征信息。SUHR 等人^[8]利用卷积神经网络(Convolutional Neural Network, CNN)来提取车位的全局信息和局部信息,实现对车位的单阶段检测。但是在上述车位检测方法中,根据车位线进行检测时,易在车位线存在遮挡或缺损时出现较大的检测误差。利用图像分割相关方法进行车位检测时,车位边缘区域像素误差较大,且同样难以处理车位遮挡的情况。故本文提出基于改进 Mask-RCNN 算法的关键点检测方式实现车位检测。

本文通过改进 Mask-RCNN 算法的 ResNet50 特征提取网络,对其网络结构、参数进行优化^[9-10],同时引入 CBAM 注意力机制^[11],通过通道注意力模块和空间注意力模块来增强车位强相关特征信息,抑制无关特征信息,提高车位检测的效果,即 C-Mask-RCNN 车位检测算法。通过车辆左、右两侧前置摄像头采集图像构造数据集,完成 C-Mask-RCNN 车位检测算法模型训练,最终得到高精度的车位检测模型。该模型能够高效快速地完成车位分类、车位状态识别与关键点预测,实现车位检测。且车位检测模型能够随着车位信息数据的增加,使检测能力获得增强,模型鲁棒性获

得提高,便于推广至复杂环境下的车位检测。

1 车位检测

1.1 Mask-RCNN 算法

Mask-RCNN 算法主要由特征提取网络、区域建议网络、兴趣区域对齐层和任务分支 4 个部分组成,Mask-RCNN 算法实现流程如图 1 所示,可以有效地完成目标分类、边框回归和关键点预测等任务。

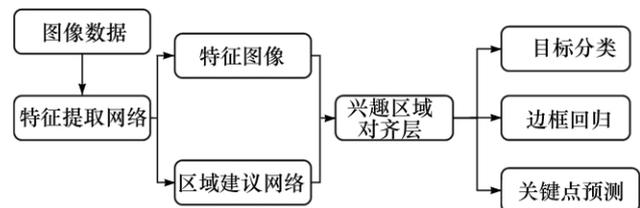


图 1 Mask-RCNN 算法实现流程

Mask-RCNN 算法采用 Resnet50 特征提取网络对特征图像进行卷积操作,并且利用特征金字塔网络(Feature Pyramid Networks, FPN)再对特征图像进行采样^[12],最后将对应的特征图像进行融合,输出不同深度的特征图像,保留更丰富的特征信息,有利于后阶段分类、回归任务的顺利完成。

区域建议网络(Region Proposal Network, RPN)的输入为经过特征提取后的特征图像,在特征图像上生成大量锚框,RPN 首先对锚框进行二元类别判别和边界框预测,再利用非极大抑制(Non-Maximum Suppression, NMS)对候选区域进行筛选,实现候选框数量的缩减和有效目标候选框即兴趣区域(Region of Interest, RoI)的增加,提高了分类、回归任务的完成效率。

兴趣区域对齐层(Region of Interest Align, RoI-Align)可以保证 RoI 尺寸缩放前后的像素依然保持对应关系。经过 RPN 处理后,候选框对应的特征图像来自多个不同的卷积层,导致映射后的 RoI 大小不一样,但是全连接层中的图像输入应为固定值,所以要将各 RoI 放缩成统一尺寸。RoIAlign 取消了对像素的量化操作,通过双线性插值法将特征图像尺寸统一,双线性插值是 2 个变量的插值函数的线性插值扩展,其核心思想是在 2 个方向(X 方向和 Y 方向)分别进行一次线性插值。

双线性插值如图 2 所示。图 2 中,像素值计算函数 $f(x, y)$ 未知,已知 4 个像素点 Q_{11} 、 Q_{12} 、 Q_{21} 和 Q_{22} 在坐标系中对应的坐标分别为 (x_1, y_1) 、 (x_1, y_2) 、 (x_2, y_1) 和 (x_2, y_2) ,同时也已知像素点 Q_{11} 、 Q_{12} 、 Q_{21} 和 Q_{22} 对应的像素值分别为 $f(Q_{11})$ 、 $f(Q_{12})$ 、 $f(Q_{21})$ 和

$f(Q_{22})$ 。通过双线性插值得到像素点 P 的像素值。

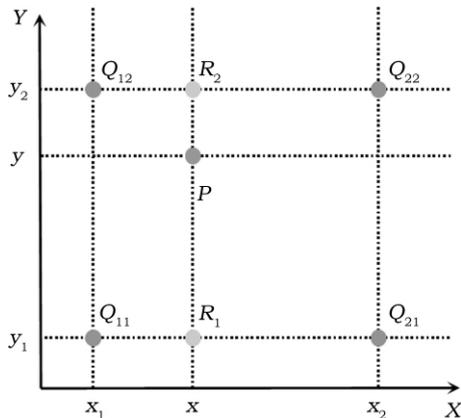


图 2 双线性插值

首先求得像素点 R_1 和像素点 R_2 的像素值。

利用单线性插值法,即:

$$\frac{f(Q_{21}) - f(Q_{11})}{x_2 - x_1} \approx \frac{f(Q_{21}) - f(R_1)}{x_2 - x} \quad (1)$$

将式(1)进行化简,可得 R_1 的像素值 $f(R_1)$ 为:

$$f(R_1) \approx \frac{x_2 - x}{x_2 - x_1} f(Q_{11}) + \frac{x - x_1}{x_2 - x_1} f(Q_{21}) \quad (2)$$

同理,可得 R_2 的像素值 $f(R_2)$ 为:

$$f(R_2) \approx \frac{x_2 - x}{x_2 - x_1} f(Q_{12}) + \frac{x - x_1}{x_2 - x_1} f(Q_{22}) \quad (3)$$

在 R_1 和 R_2 之间双线性插值得到像素点 P 的像素值 $f(P)$,即:

$$f(P) \approx \frac{y_2 - y}{y_2 - y_1} f(R_1) + \frac{y - y_1}{y_2 - y_1} f(R_2) \quad (4)$$

预测分支主要是对处理后的 RoI 完成最后的目标检测、分类和关键点预测。全卷积网络(Fully Convolutional Networks, FCN) 构成的卷积网络是关键点预测任务分支重要的组成部分^[13]。经过 RoIAlign 尺寸统一后的 RoI 作为关键点预测任务分支的输入,利用 FCN 对特征图像进行卷积特征提取、上采样,最后对每个关键点进行像素级预测。在模型训练时同时进行目标分类任务和关键点预测任务,当模型预测时先进行目标分类再进行关键点预测,利用目标分类的结果对关键点预测任务进行计算,可以避免车位关键点和非车位关键点之间的竞争。

将 Mask-RCNN 算法泛化到车位检测和关键点预测任务上,可以实现端到端目标检测。但是 Mask-RCNN 算法进行车位检测和关键点预测时,在特征提取过程中对于整张图片的关注度一致,车位外的复杂

环境易造成检测干扰和计算资源的浪费,导致复杂环境背景下的检测准确率下降、像素误差增大,使得车位线定位紊乱,如图 3 所示。图 3 中,黑色实线为 Mask-RCNN 算法所检测到的车位内边线。根据上述缺陷,本文通过引入注意力机制,能够使得模型更加关注包含车位的区域特征信息,提高模型检测能力。

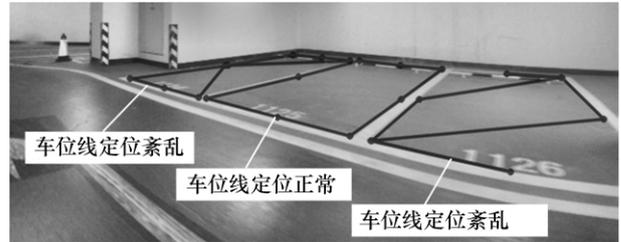


图 3 车位线定位紊乱

1.2 CBAM 结构

CBAM 是一种能对特征图像局部信息聚焦的机制模块。它通过学习的方式在空间和通道上对特征图像进行权重分配,促使计算资源更倾向于重点关注的目标区域,从而加强感兴趣的信息,抑制无用信息。

CBAM 包含 2 个模块,分别为通道注意力模块、空间注意力模块,CBAM 模块划分如图 4 所示。

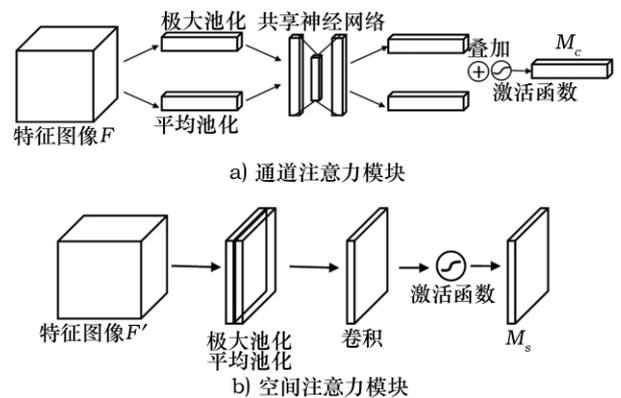


图 4 CBAM 模块划分

通道注意力模块的作用是增大有效通道权重,减少无效通道权重。其实现机制为:首先输入特征图像 F 的像素值,分别进行全局平均池化和极大池化得到 2 个通道描述;再输入至一个 2 层的共享神经网络进行反向传播训练,得到 2 个特征图像;然后,将 2 个特征图像相叠加后输入 Sigmoid 激活函数得到权重系数 M_c ;最后将权重系数 M_c 和特征图像 F 的每个像素值相乘,得到通道注意力模块缩放后的特征图像 F' 。

空间注意力模块可以在空间上对特征图像的不同区域赋予不同的重要度,达到增加兴趣区域,抑制

无用区域的目的。其实现机制为:空间注意力模块以特征图像 F 的像素值作为输入,分别经过极大池化、平均池化得到 2 个空间维度特征图像;再将 2 个特征图像叠加后进行卷积操作;将卷积后的特征图像输入 Sigmoid 激活函数得到权重系数 M_s ;最后将权重系数 M_s 乘以特征图像 F 的像素值,得到缩放后的新特征图像。

2 车位检测模型的改进

本文采用 8 个关键点对车位线内边缘进行定位,同时将车位按照泊车方式分为水平车位和垂直车位,按照占用状态分为占用车位和可泊车位,即 4 种车位类型分别为:水平可泊、水平占用、垂直可泊和垂直占用。C-Mask-RCNN 车位检测算法框架如图 5 所示。

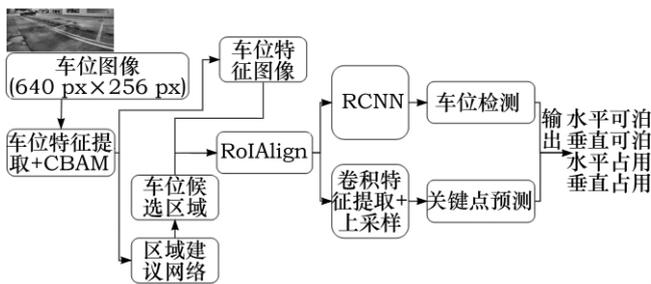


图 5 C-Mask-RCNN 车位检测算法框架

2.1 融合 CBAM 的车位特征提取

Mask-RCNN 特征提取网络为 ResNet50 特征提取网络,在其基础上融入 CBAM,得到新的特征提取网络为 CResNet50 网络。CResNet50 网络能够增强空间维度和通道维度的有效特征,抑制无效信息的流动。借鉴文献 [11] 的方法,本文将 CBAM 作用于 ResNet50 特征提取网络的所有卷积残差块,残差网络+CBAM 示意图如图 6 所示。将上一个残差块输出的特征图像经过卷积后得到特征图像 F 作为注意力模块的输入,经过通道注意力模块处理后得到特征图像 F' ,继续通过空间注意力模块处理得到特征图像 F'' 。

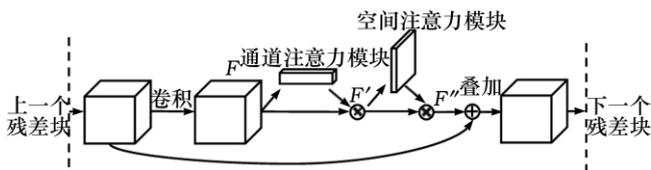


图 6 残差网络+CBAM 示意图

定义通道注意力模块计算函数,其特征权重函数 $M_c(F)$ 为:

$$M_c(F) = \sigma(\text{MLP}(\text{AvgPool}(F))) +$$

$$\text{MLP}(\text{MaxPool}(F)) \quad (5)$$

可得:

$$F' = M_c(F) \otimes F \quad (6)$$

式中: AvgPool() 为平均池化函数; MaxPool() 为极大池化函数; MLP() 为感知机函数; $\sigma()$ 为 Sigmoid 激活函数; \otimes 表示对应元素相乘。

令 $g^{7 \times 7} []$ 为 7×7 的卷积核函数,定义空间注意力模块计算函数,其特征权重函数 $M_s(F')$ 为:

$$M_s(F') = \sigma(g^{7 \times 7} [\text{AvgPool}(F'); \text{MaxPool}(F')]) \quad (7)$$

且:

$$F'' = M_s(F') \otimes F' \quad (8)$$

C-Mask-RCNN 车位检测算法车位特征提取过程如图 7 所示,通过 CResNet50 网络的上卷积网络和池化层对车位进行特征提取和下采样操作,分别输出 C1~C5 层的特征图像,同时采用 FPN 作为特征提取的下层卷积网络。FPN 利用自顶向下的横旁路连接结构,构造了一个单尺度输入,可以自顶向下对高层特征上采样(最邻近上采样法),而横向连接则是将上采样的结果和 CResNet50 网络下采样生成的相同大小的特征图像进行叠加,生成 P2~P5 层车位特征图像。

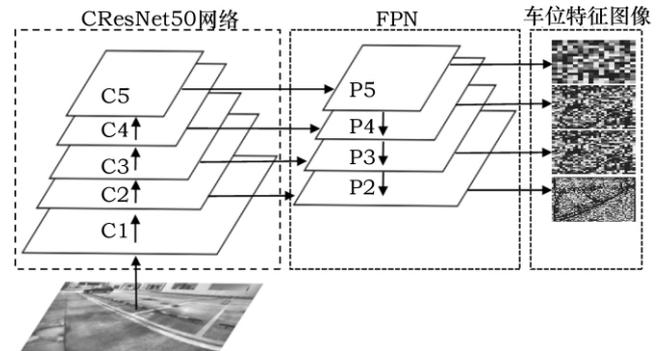


图 7 C-Mask-RCNN 车位检测算法车位特征提取过程

为能够更加直观地展示 CBAM 对特征提取的影响,本文利用 Grad-CAM 方法得到加入 CBAM 前后的热力图,车位特征热力图如图 8 所示。



图 8 车位特征热力图

2.2 车位候选区域生成

车位候选区域生成阶段,将由 CResNet50 网络进行特征提取得到的 P2~P5 层车位特征图像输入

RPN,RPN 工作机制如图 9 所示。用 3×3 滑动窗口在每个特征图像上进行滑动,并且按照 3 组宽高比(1:1、1:2 和 2:1),在原始图像上生成不同尺寸的候选区域。CResNet50 网络对 3×3 滑动窗口产生的 256 维特征图像进行目标分类和边框回归,分类结果为车位、非车位,边框回归后输出 4 个较精准的坐标值,通过这 4 个坐标值可以确定候选区域在原始图像的对应位置。将人工标注的车位框作为真实车位框,计算所有车位候选区域和真实车位框的交并比(Intersection over Union, IoU)大小,并且保留 IoU 阈值大于 0.7 的车位候选区域。通过 NMS 对车位候选区域进一步筛选,最终得到更有可能存在车位的候选区域(预测车位框)。

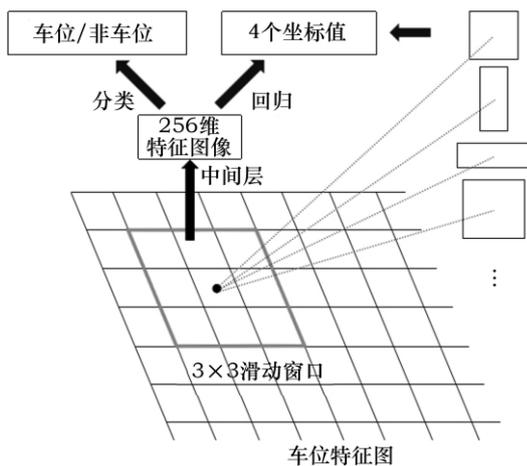


图9 RPN 工作机制

2.3 车位候选区域尺寸统一化处理

在 RPN 计算得到候选区域后,需要获取 RoI 的特征图像。按照每个候选区域的尺寸大小,映射到 FPN 中 P2~P5 层中获取相应的特征图像,映射分配公式为:

$$k = k_0 + \log_2(\sqrt{mn}/244) \quad (9)$$

式中: k_0 为映射常数,取值为 4; m 、 n 分别为 RoI 的宽、高(在输入图像上); k 为 RoI 对应的 FPN 层数。

将候选区域对应每一层特征图像剪裁出 RoI 的特征图像,RoIAlign 通过双线性插值对这些不同尺寸的 RoI 进行尺寸统一化处理。由 RoIAlign 处理后,将分辨率为 7 px×7 px 车位特征图像输入车位检测分支,分辨率为 14 px×14 px 车位特征图像输入关键点预测分支。训练阶段车位检测分支与车位特征图输入关键点预测分支并行执行,测试阶段采用 NMS 减少候选框个数,使得 C-Mask-RCNN 车位检测算法的车位检测效率得到提升。

2.4 车位检测和关键点预测

2.4.1 车位检测

车位检测是由 C-Mask-RCNN 模型中 RCNN 检测分支完成。车位检测与关键点预测的损失函数均为基于 Softmax 函数的交叉熵损失函数 L_{cls} ,即:

$$L_{cls} = - \sum_{j=1}^T y_j \lg z_j \quad (10)$$

其中:

$$z_j = \frac{e^{a_j}}{\sum_{j=1}^T e^{a_j}} \quad \forall j \in \{1, 2, \dots, T\} \quad (11)$$

式中: T 为车位类别数; y_j 为第 j 种车位的车位真实标注值; z_j 为第 j 种车位的车位预测概率值; a_j 为第 j 种车位通过网络前向传播所计算的类别得分。

基于 SmoothL1 函数的车位框回归的损失函数 L_{box} 为:

$$L_{box} = \sum_{i \in \{c, d, w, h\}} \text{SmoothL1}(t_i^u - v_i) \quad (12)$$

其中,SmoothL1 函数为:

$$\text{SmoothL1}(t_i^u - v_i) = \begin{cases} 0.5(t_i^u - v_i)^2 & \text{if } |t_i^u - v_i| < 1 \\ |t_i^u - v_i| - 0.5 & \text{其他} \end{cases} \quad (13)$$

式中: (t_c^u, t_d^u) 为预测车位框的平移变化量; (t_w^u, t_h^u) 为预测车位框的尺寸缩放量; (v_c, v_d) 为真实车位框的平移变化量; (v_w, v_h) 为真实车位框的尺寸缩放量; 下标 c, d 为预测车位框的中心坐标; 下标 w, h 分别为预测车位框的宽、高; 上标 u 为类别索引。

C-Mask-RCNN 模型通过损失函数的值来指导每一层的权重更新,最终达到预期的车位检测效果。

2.4.2 车位关键点预测

车位关键点预测通过关键点分支完成。模型进行关键点预测时,首先将分辨率为 14 px×14 px 的 RoI 输入全连接层,再通过双线性插值、上采样输出 8 个分辨率为 56 px×56 px 的二进制掩码。1 个分辨率为 56 px×56 px 的二进制掩码中只有 1 个像素被标记为前景,且该像素对应车位的 1 个关键点。将模型对每个车位预测的 8 个关键点用黑色实线连接,车位关键点预测效果如图 10 所示。

3 实验分析

3.1 数据集的建立

本文车位关键点检测为多场景检测,为增强 C-Mask-RCNN 车位检测算法的泛化能力,提升模型鲁棒

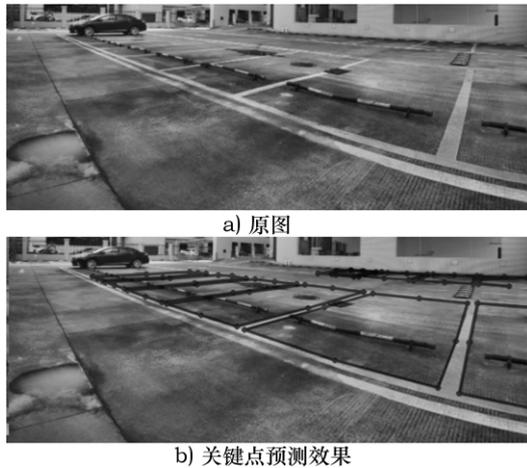


图 10 车位关键点预测效果

性,采集不同场景下停车场车位图片进行模型训练。通过车辆左、右两侧前置摄像头设备共采集约 3 140 张车位图像数据,并利用 OpenCV 模块对图像进行畸变矫正。使用 LabelMe 软件对车位图像进行关键点标注,每个车位用 8 个点标注,同时添加车位属性,标注信息保存在.json 文件里。由于远处车位成像质量差,导致标注误差较大,故距离采集车辆 4 个车位以外的范围不再进行标注,标注样式如图 11 所示。数据集中室内车位图像为 2 530 张,户外车位图像为 610 张,共标注车位 12 105 个。经过随机分配,将其中 2 626 张车位图像作为训练集,314 张车位图像作为验证集,200 张车位图像作为测试集。为减少网络的计算量,加快网络训练速度,将原始图像分辨率从 1 280 px×960 px 缩放到 640 px×256 px。

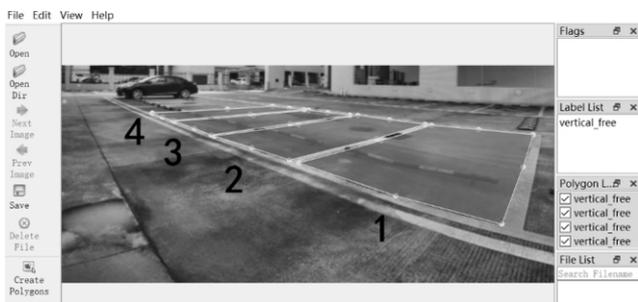


图 11 标注样式

3.2 模型训练

本文实验环境软件系统为 Ubuntu16.04 操作系统,硬件采用 2 块 NVIDIA TITAN X 图形处理器进行加速运算。使用深度学习框架 Pytorch 实现车位检测算法运行。将车位检测模型初始学习率设置为 0.002 5,采用梯度下降法训练,衰减系数为 0.000 2。将车位图像数据转换成 COCO 数据集格式,加载预训

练模型权重开始训练,按照图 12 所示的训练流程,经过 54 000 次迭代,损失值稳定在 2.8 左右,获得车位检测最终模型,训练过程的损失值变化如图 13 所示。

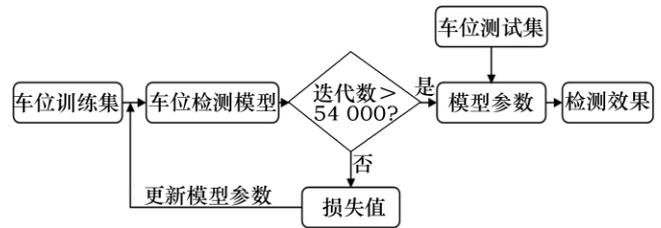


图 12 训练流程

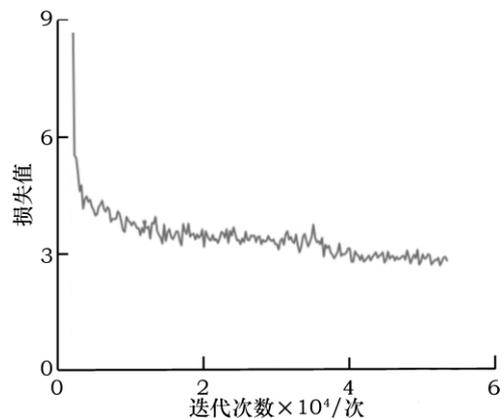


图 13 损失值变化

3.3 实验结果分析

为检验 C-Mask-RCNN 模型(C-Mask-RCNN 车位检测算法模型)对车位检测的可靠性和准确性,进行四部分实验,即:车位类型检测分析、车位状态检测分析、车位关键点预测分析和多场景模型鲁棒性分析。分别用含有注意力机制的 C-Mask-RCNN 模型和原始的 Mask-RCNN 模型(Mask-RCNN 算法模型)对 650 个车位进行检测,所检测的车位包括不同场景(室内和户外)、不同车位类型(水平车位和垂直车位),以及被遮挡的车位。统计出召回率和精确率作为模型评价指标,并进行试验对比分析。

与原始的 Mask-RCNN 模型相比,本文通过加入空间注意力机制和通道注意力机制,并且优化训练参数,使模型能更好地适用于车位检测。表 1 所示为车位类型测试结果,表 2 所示为车位状态测试结果,实验测试结果表明使用本文的车位检测算法在检测车位类型时平均精确率提升 7.4 %,平均召回率提升 3.35 %,检测车位状态时的平均精确率提升 11.1 %,平均召回率提升 5.65 %。

C-Mask-RCNN 模型对车位线内边缘关键点进行预测,并通过求每个车位预测到的 8 个关键点与真实

标注对应的 8 个点的欧氏距离,计算像素误差 σ ,即:

$$\sigma = \frac{1}{N} \sum_{e=1}^N \sum_{p=1}^M \sqrt{(x_e^p - s_e^p)^2 + (y_e^p - t_e^p)^2} \quad (14)$$

式中: N 为检测车位总数, $N=650$; M 为每个车位关键点数量, $M=8$; (x_e^p, y_e^p) 和 (s_e^p, t_e^p) 分别为第 e 个车位的第 p 个关键点的预测像素坐标和真实标注像素坐标。

表 1 车位类型测试结果

车位类型	车位检测模型	精确率/%	召回率/%
水平车位	原始的 Mask-RCNN	77.6	82.1
水平车位	C-Mask-RCNN	84.3	86.7
垂直车位	原始的 Mask-RCNN	83.1	83.0
垂直车位	C-Mask-RCNN	91.2	85.1

表 2 车位状态测试结果

车位状态	车位检测模型	精确率/%	召回率/%
可泊车位	原始的 Mask-RCNN	72.6	81.1
可泊车位	C-Mask-RCNN	83.7	86.2
占用车位	原始的 Mask-RCNN	69.1	79.7
占用车位	C-Mask-RCNN	80.2	85.9

在此实验设备条件下,统计每个车位平均像素误差和检测时间,车位关键点测试结果表 3 所示。

表 3 车位关键点测试结果

车位检测模型	平均像素误差/px	检测时间/ms
原始的 Mask-RCNN	84.3	51
C-Mask-RCNN	69.2	47

原始的 Mask-RCNN 模型和 C-Mask-RCNN 模型在不同背景、不同车位类型和遮挡车位下进行关键点预测,并且依次用线段连接 8 个关键点,关键点预测效果对比如图 14 所示。图 14 中,黑色实线表示可泊车位,黑色虚线表示占用车位。

分析实验结果可知,改进后的 C-Mask-RCNN 车位检测算法对 2 种车位类型和状态的检测效果均有所提高。在室内和户外场景下,车位线关键点预测平均像素误差能达到 ± 70 px,其模型检测每张车位图片平均耗时 47 ms。在车位线被遮挡情况下,传统车位检测方式检测困难较大,通过 C-Mask-RCNN 车位检测算法中深度学习的优势,可以在一定程度上解决这一困难,使得模型具有遮挡车位的检测能力。

4 结语

本文将深度学习与车位检测相结合,能够在多场景下实现车位识别及车位线关键点预测。基于 C-Mask-RCNN 车位检测算法,可以提取深层次的特征,融入注

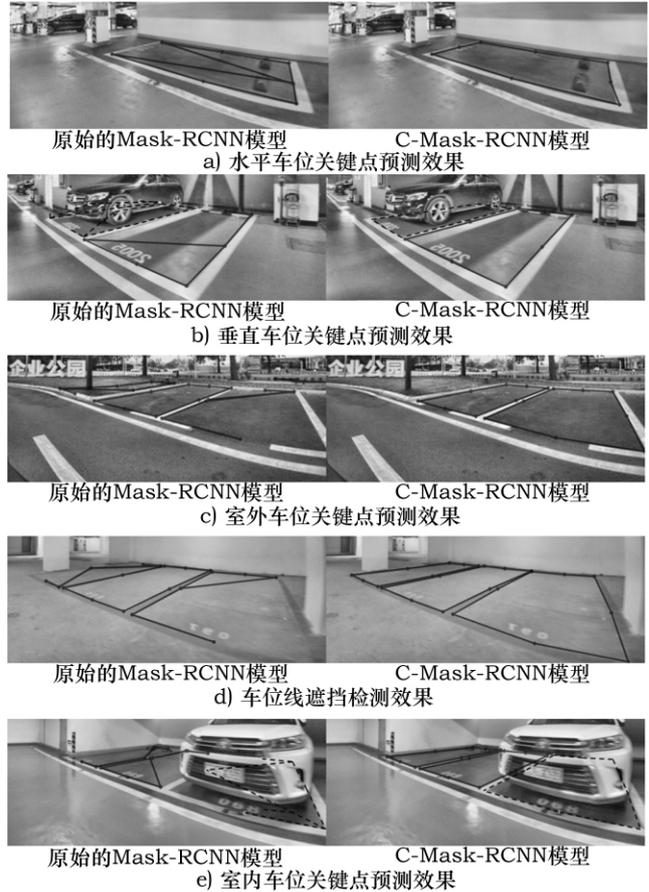


图 14 关键点预测效果对比

意力机制,能够在图像通道和空间上增强车位信息,更能适应不同场景的车位检测。实验结果证明,较 Mask-RCNN 算法车位类型识别平均精确率提升 7.4%,车位状态识别平均精确率提升 11.1%,而且平均每个车位的车位线内边缘定位像素误差在 ± 70 px 以内。在一些车位信息稀少的情况下依然保持较高的车位识别效果。本文研究对车位识别的研究有一定的参考价值。

参考文献:

- [1] 魏振亚,汪明磊.自动泊车的超声波车位探测系统研究[J].农业装备与车辆工程,2013,51(4):26-29,46.
- [2] 付鹏,李嫩,陈庚,等.基于超声波雷达的泊车位类型检测[J].汽车实用技术,2020(7):25-27.
- [3] 朱旺旺,黄宏成,马晋兴.基于图像识别的泊车车位检测算法研究[J].汽车工程,2019,41(7):744-749,756.
- [4] 王景丹,黄园刚,郝宗波,等.基于智能检测车位信息的车辆识别算法[J].计算机科学与应用,2013,3(2):96-101.
- [5] JUNG H G, KIM D S, YOON P J, et al. Parking slot markings recognition for automatic parking assist system [C]// 2006 IEEE Intelligent Vehicles Symposium, Piscataway, (下转第 101 页)

触电阻变化值均小于 20 mΩ, 摩擦力矩均小于 1 N·m, 满足技术要求, 该导电滑环合格。

表 1 接触电阻测试结果

测试环路	接触电阻 最大值/mΩ	接触电阻 最小值/mΩ	变化值/ mΩ	变化值 ≤20 mΩ
1	235	231	4	是
2	225	222	3	是
3	226	224	2	是
4	225	205	10	是
5	223	213	10	是
6	224	215	9	是
7	221	216	5	是

表 2 摩擦力矩测试结果

摩擦力矩 要求值	最大值/ (N·m)	最小值/ (N·m)	平均值/ (N·m)	是否合格
≤1	0.8	0.5	0.65	是

5 结语

本文基于 Labview 虚拟仪器研制了可用于模拟空间环境试验的检测装置, 该装置将导电滑环、驱动电机内置于可模拟热真空环境试验箱内。采用导电滑环全自动数字化测试仪器与上位机软件进行数据传输和处理的系统装置, 模拟导电滑环的转动和传输, 实时检测导电滑环的摩擦力矩和接触电阻指标, 更好地检测和验证了导电滑环在模拟空间环境下的性能

指标, 可在导电滑环用于实际环境条件前, 更加全面地验证导电滑环的工作性能。

参考文献:

- [1] 杨发展, 康鲁迪. 基于 LabVIEW 的中空结构铝合金高速铣削加工噪声试验系统设计 [J]. 制造技术与机床, 2015(7): 129-132.
- [2] 蔡周春, 缪姝妹, 王辉, 等. 基于 Labview 的自动控制原理实验系统的设计 [J]. 工业控制计算机, 2012, 25(4): 39-40.
- [3] 朱小茅, 韩九强, 贾海波. 基于 LabVIEW 的轴承转子实时测控系统研究 [J]. 机电工程, 2001, 18(3): 16-19.
- [4] 杨丹丹, 尹辉俊, 王雨. 基于 LabVIEW 的数据采集系统的应用 [J]. 机械工程与自动化, 2013(4): 11-13.
- [5] 杨莉红. 导电滑环技术的研究 [J]. 科技传播, 2012(6): 45-50.
- [6] 张林, 吴海红, 邓军. 导电滑环摇摆瞬断检测系统设计 [J]. 科技传播, 2012(61): 74-76.
- [7] 周凤余, 李贻斌, 苏学成, 等. 高精度伺服系统位置检测单元的设计 [J]. 电气传动, 2003(3): 33-37.
- [8] 刘海珊, 陈宇晨. 无刷直流电机 PID 控制系统仿真及实验研究 [J]. 系统仿真学报, 2008(21): 5175-5160.

作者简介: 吕斌, 硕士, 工程师, 主要研究方向为旋转传输装置研发, 已发表论文 3 篇。

E-mail: lvbin690346211@126.com

收稿日期: 2020-04-07

(上接第 97 页)

USA: IEEE, 2006: 106-113.

- [6] 黄晨, 刘泽, 罗禹贡, 等. 基于背景光照去除和连通区域的车位检测 [J]. 汽车工程, 2020, 42(1): 47-51, 73.
- [7] WU Y, YANG T, ZHAO J, et al. VH-HFCN based Parking Slot and Lane Markings Segmentation on Panoramic Surround View [C] // 2018 IEEE Intelligent Vehicles Symposium (IV). Piscataway, USA: IEEE, 2018: 1767-1772.
- [8] SUHR J K, JUNG H G. End-to-End Trainable One-Stage Parking Slot Detection Integrating Global and Local Information [J]. Signal Processing Letters, 2020, 4(2): 24-45.
- [9] HE K, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN [C] // Proceedings of the IEEE international conference on computer vision. New York, USA: IEEE, 2017: 2980-2988.
- [10] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // Proceedings of the IEEE conference on computer vision and pattern recognition. New York, USA: IEEE, 2016: 770-778.
- [11] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional

block attention module [C] // Proceedings of the European Conference on Computer Vision (ECCV). Cham, Switzerland: Springer, 2018: 3-19.

- [12] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C] // Proceedings of the IEEE conference on computer vision and pattern recognition. New York, USA: IEEE, 2017: 2117-2125.
- [13] LONG J, SELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [C] // Proceedings of the IEEE conference on computer vision and pattern recognition. Los Alamitos, USA: IEEE, 2015: 3431-3440.

作者简介: 党顺峰, 硕士研究生, 主要研究方向为机器视觉、图像处理。

熊锐, 通信作者, 教授, 硕士研究生导师, 主要研究方向为汽车节能与排放控制、汽车动力总成技术。

E-mail: 907591807@qq.com

收稿日期: 2020-06-08