

基于协作注意力和图神经网络的轻量化车位检测算法*

李琳辉^{1,2} 袁世伟¹ 连静^{1,2} 顾汤鹏¹

(1.大连理工大学,汽车工程学院,大连 116024;2.大连理工大学,工业装备结构分析国家重点实验室,大连 116024)

【摘要】为提高自动泊车过程车位检测的实时性和准确性,提出一种基于协作注意力和图神经网络的轻量化车位检测算法。首先,采用轻量化的网络结构,以改进的 MobileNetV3 作为特征提取网络,通过深度可分离卷积获得车位标记点的位置信息和特征信息,并将二者结合得到标记点的融合特征,然后构建图神经网络结构以增强车位标记点之间的内在联系,并结合协作注意力机制实现对多头注意力的整合,最后,通过公共车位数据集 PS2.0 对所提出的算法进行测试,结果表明,该算法的检测精度优于当前主流算法,平均每帧图像推理时间可缩短至 10.1 ms,具备良好的准确性和实时性。

关键词: 车位检测 协作注意力 图神经网络 轻量化

中图分类号: TP391.41 **文献标识码:** A **DOI:** 10.19620/j.cnki.1000-3703.20221220

Lightweight Parking-Slot Detection Algorithm Based on Collaborative Attention and Graph Neural Network

Li Linhui^{1,2}, Yuan Shiwei¹, Lian Jing^{1,2}, Gu Tangpeng¹

(1. School of Automotive Engineering, Dalian University of Technology, Dalian 116024; 2. State Key Laboratory of Structural Analysis for Industrial Equipment, Dalian University of Technology, Dalian 116024)

【Abstract】In order to improve the real-time and accuracy of parking slot detection in automatic parking, this paper proposed a lightweight parking-slot detection algorithm based on collaborative attention and graph neural network. Firstly, This algorithm used a lightweight network structure and the improved MobileNetV3 as the feature extraction network, obtained the location information and feature information of the parking-slot marker points through depthwise separable convolution, combined them to obtain the fused features of the marker points, then constructed a graph network structure to enhance the internal relationship of the parking-slot marker points, and combined the cooperative attention mechanism to integrate multiple attention. Finally, the algorithm was tested on the public parking-slot dataset PS2.0. The results indicate that the detection accuracy is better than the current mainstream algorithm, the average reasoning speed of each frame of image can reach 10.1 ms, with good accuracy and real-time performance.

Key words: Parking-slot detection, Collaborative attention, Graph neural network, Deep learning

【引用格式】李琳辉,袁世伟,连静,等.基于协作注意力和图神经网络的轻量化车位检测算法[J].汽车技术,2023(11):41-48.

LI L H, YUAN S W, LIAN J, et al. Lightweight Parking-Slot Detection Algorithm Based on Collaborative Attention and Graph Neural Network[J]. Automobile Technology, 2023(11): 41-48.

1 前言

自动泊车作为自动驾驶的基础应用之一,近年来得到了越来越多学者的关注^[1-2]。自动泊车的实现离不开

感知系统的配合,其中,基于车载环视(Around View Monitor,AVM)系统^[3]的停车位检测系统能够利用安装在车身周围的摄像头,通过图像处理算法检测并识别目标车位的标记线,从而提取空停车位,在自动泊车任务

*基金项目:国家自然科学基金资助项目(61976039,52172382);中央高校基本科研业务费专项资金资助项目(DUT22JC09);大连市科技创新基金资助项目(2021JJ12GX015)。

通讯作者:连静(1980—),女,吉林公主岭人,博士,大连理工大学副教授,博士生导师,主要研究方向为智能化汽车主动安全技术、基于深度学习的智能电动汽车控制技术等,lianjing@dlut.edu.cn。

中起到了重要作用。

基于视觉的停车位检测算法主要可以分为传统的车位检测算法和基于深度学习的车位检测算法。传统的车位检测算法可以分为基于线的停车位检测算法^[4-5]和基于标记点的停车位检测算法^[6-7],但对环境变化敏感、鲁棒性差,不适用于复杂的现实环境。

为提高复杂环境下车位识别的准确性,研究人员提出了多种基于深度学习的车位检测算法。Huang等^[8]在基于深度卷积神经网络的停车位检测算法(Deep convolutional neural networks based Parking-Slot detection approach, DeepPS)^[9]的基础上进行优化,使用新的卷积神经网络提取车位标记点的方向、坐标和形状,并利用设计好的几何规则过滤和匹配成对标记点;Wu等^[10]为解决车位检测中先验知识不足的问题,提出了以圆形描述符来回归停车位顶点坐标的方法,并开发了一个两阶段的模型用于检测停车位;Chen等^[11]在图神经网络的使用过程中放弃复杂且不便的后处理环节,以端到端的方式直接对车位进行推理,在公共数据集PS2.0^[9]上得到了优异的结果,然而,由于该算法模型较大,推理速度慢,导致其实时性较差。

基于以上分析,本文综合考虑车位检测实时性和有效性的任务需求,提出一种基于协作注意力与图神经网络的轻量化车位检测算法:使用改进的轻量化神经网络结构,减少模型训练过程的开销,加快模型推理速度;使用协作注意力机制和图神经网络配合的方法,整合多头注意力的冗余信息,并加强车位标记点间的内在联系;

采用端到端的训练方式,不需人工设定规则的复杂后处理过程。最后,将该算法在公共数据集PS2.0上进行训练,并与当前的主流算法进行对比。

2 基于协作注意力和图神经网络的车位检测算法结构

通常,车位可以由4个标记点表示,参考采用定向标记点回归的车位检测(Parking-Slot detection using Directional Marking-Point Regression, DMPR-PS)^[8]方法,本文将车位识别的问题表述为对车位入口线上标记点的检测问题。首先将给定的车位环视图像输入改进的MobileNetV3模型,提取特征图后,利用深度可分离卷积得到车位标记点的位置信息和特征编码信息,并输出标记点的回归损失。其次,利用双线性插值的方法将标记点位置信息与特征信息相结合,输出标记点特征。然后,将得到的标记点特征与经多层感知机变换后的位置信息相结合,构成图神经网络中的节点信息,即融合的标记点特征 V 。本文将图像中的所有车位标记点连接,形成全连通的图,标记点间的连接关系作为图边 E 。根据图节点 V 和图边 E 的关系构建图神经网络 $G=(V,E)$,将其与协作注意力机制相结合,推断标记点间的内在联系。经过协作注意力与图神经网络的处理变换,由车位推理层对输出的标记点特征进行判别,判定其能否形成车位,并输出误差损失,更新算法的参数。

本文算法的总体结构如图1所示。

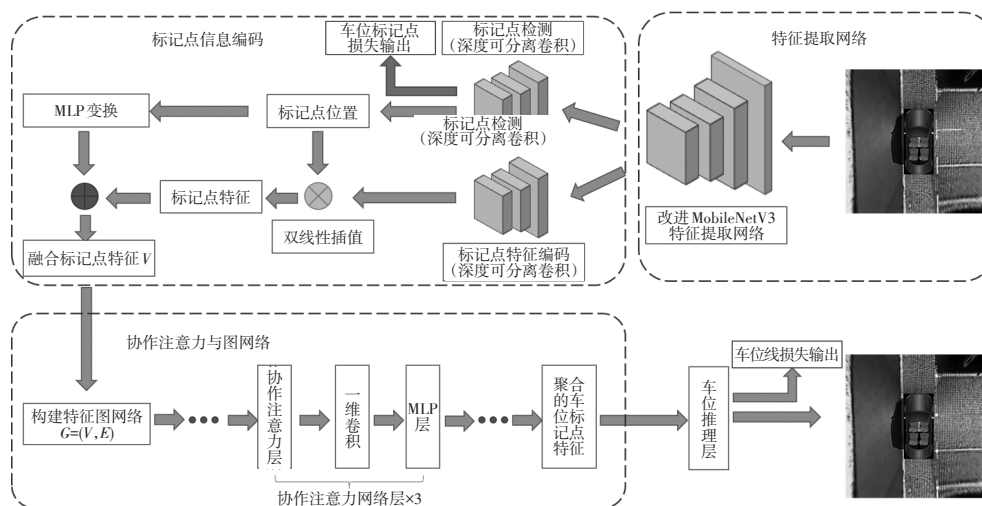


图1 基于协作注意力和图神经网络的车位检测算法总体结构

2.1 特征提取网络

为了减少训练以及实际算法部署的开销,轻量化神经网络的构建尤为重要。本文将协作注意力与图神经网络相结合探究车位标记点的内在关联,增加了算法计

算复杂度,故使用轻量化的神经网络来获取图像特征,以提高算法的推理速度。

本文改进了 MobileNetV3 网络作为特征提取网络,其结构如图2所示,其中 hswish 表示 h-swish 激活函

数。该网络保留 MobileNetV1 的深度可分离卷积、MobileNetV2 的倒残差结构以及挤压和激励(Squeeze-and-Excitation, SE)注意力通道模块,并利用神经结构搜索方法来搜索网络的配置和参数。MobileNetV3^[12]的核心模块为 Bneck 模块,也是构成该网络的基本模块。为提高模型的表达能力,本文将 Bneck 模块中的 SE 注意力通道模块替换为平铺挤压和激励(Tiled Squeeze-and-Excite, TSE)注意力通道模块^[13]。

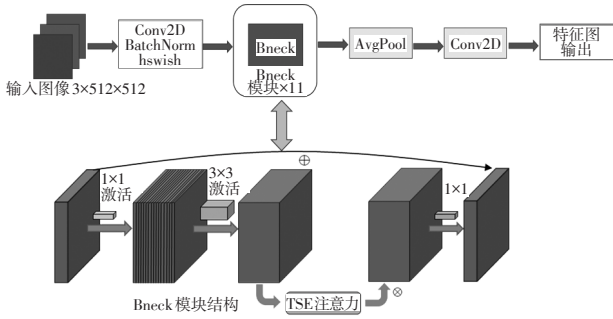


图2 改进的 MobileNetV3 网络结构

TSE 注意力通道模块用平均池化(Average Pooling, AvgPool)层替代了 SE 注意力通道模块的全局平均池化(Global Average Pooling, GAP)层,将输入的张量划分成多个大小相等的非重叠块。此外,TSE 注意力通道模块采用一维卷积层而非 SE 注意力通道模块的全连接(Fully Connected, FC)层,以缩小非重叠块的通道,再通过批归一化(Batch Normalization, BatchNorm)和激活函数线性整流函数(Rectified Linear Unit, ReLU)进行处理,然后使用一维卷积层将非重叠块的通道放大。最后,TSE 注意力通道模块通过最近邻插值(Nearest Neighbor Interpolation, NNI)的方式将通过激活函数 S 型函数(Sigmoid Function)的所有非重叠块拼接在一起,并将其输出尺寸调整为输入张量的尺寸。SE 注意力通道模块与本文使用的 TSE 注意力通道模块的具体结构如图3所示。

TSE 注意力相比于 SE 注意力机制,在挤压过程中使用较小的内核进行共享,从而减小了操作所需要的内存,并在保持精度的同时为终端平台上的深度学习部署提供了优化解决方案。

2.2 标记点信息编码

将特征提取网络得到的特征图分别传递至标记点检测器和标记点编码器,以提取标记点位置信息和特征编码信息。

标记点检测器由深度可分离卷积层构成,输出特征图,用于提取车位标记点的横、纵坐标 x 、 y 以及置信度 c 的信息;检测器同时计算出标记点回归损失用于网络的

迭代计算,从而提高模型的表达能力。标记点编码器同样由深度可分离卷积层构成,输出特征图后,通过双线性插值的方式对检测到的数量为 N 的车位标记点位置进行逐点卷积,得到车位标记点的特征 F 。为增强特征的表达能力,本文参考变换神经网络(Transformer)^[14]位置编码方式,利用多层感知机模型将车位标记点坐标信息 (x, y) 升维,通过相加的方式与特征 F 逐位结合:

$$V_i = F_i + M_{lp}(x_i, y_i) \quad (1)$$

式中, M_{lp} 为多层感知机模型; F_i 为 F 中的第 i 个初始标记点特征; V_i 为获得的第 i 个标记点的融合特征; x_i, y_i 分别为第 i 个标记点的横、纵坐标。

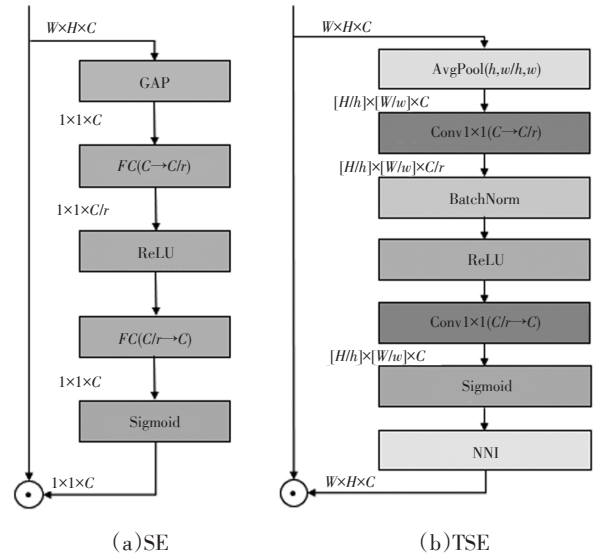


图3 SE 注意力通道模块与本文使用的 TSE 注意力通道模块结构对比

将输出的融合特征 V_i 作为协作注意力与图神经网络的输入,并联合标记点信息和位置信息进行车位推理。

为提高网络的推理速度、减少算法训练以及部署的开销,本文使用深度可分离卷积层^[12]替代标准的二维卷积层,用于提取标记点位置信息和特征编码信息。深度可分离卷积^[12]主要由 2 个部分组成,即深度卷积和逐点卷积。深度可分离卷积相比普通卷积缩减了计算总量,假设输入特征图大小为 $D_f \times D_f \times M$ 、输出特征图大小为 $D_f \times D_f \times O$,卷积核尺寸为 $D_A \times D_A$,其中, D_f 为特征图的宽度和高度, M 为输入通道数量, O 为输出通道数量。

对于标准的二维卷积,其计算量为:

$$C_1 = D_A \times D_A \times M \times D_f \times D_f \times O \quad (2)$$

对于深度可分离卷积,其计算量为:

$$C_2 = D_A \times D_A \times M \times D_f \times D_f + M \times D_f \times D_f \times O \quad (3)$$

深度可分离卷积和标准卷积计算量的比值为:

$$\eta = \frac{C_2}{C_1} = \frac{1}{O} + \frac{1}{D_A^2} \quad (4)$$

由此可见,在同等条件下,相比于标准卷积,深度可分离卷积能够大幅降低计算量,可以有效减少模型的参数数量,加快实时推理的速度。

2.3 协作注意力与图神经网络

根据前文中得到的融合特征 V , 本文构建全连接图神经网络 $G=(V,E)$ 。该图神经网络中的节点 V 表示数量为 N 的车位特征标记点, 图边 E 表示为每个标记点间的连接关系。

为了提高模型的表达能力, 本文用协作注意力^[59]来整合不同头部之间的信息。协作注意力相比于标准的多头注意力^[6], 更关注所有注意力头捕捉的通用信息, 并将这些信息作为共享权重, 从而加强了多个头部间的作用与理解, 并修剪了冗余的参数, 实现了轻量化注意力的功能。

标准的多头注意力机制通过直接拼接的方式整合不同注意力:

$$Q = XW_Q, K = YW_K, V = YW_V$$

$$H^{(i)} = \text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (5)$$

$$\text{MultiHead}(X, Y) = \text{concat}_{i \in [N_h]} [H^{(i)}]W_0$$

式中, Q, K, V 分别为查询向量、键向量和值向量; X, Y 分别为 2 个不同的输入矩阵; W_Q, W_K, W_V 分别为 Q, K, V 的权重矩阵; $H^{(i)}$ 为第 i 个头的注意力表示; Attention 为自注意力机制; softmax 为归一化指数函数, 作为激活函数; N_h 为注意力头的数量; d_k 为每个注意力头中键向量的列空间维度; MultiHead 为多头注意力机制; concat 为拼接函数, 将多个注意力头部的计算结果在最后一个维度上进行拼接; W_0 为输出的权重参数矩阵。

定义 $D_k = N_h d_k$ 为键向量的列空间总维度。引入传统的注意力机制可以提高检测的准确性和模型的表达能力, 然而这些注意力头部之间捕捉的信息存在冗余, 头部与头部间的通用信息较多。

观察到注意力头部的键和查询学习冗余预测后, 利用混合向量 $m \in \mathbf{R}^{D_k}$ 提取每个注意力头部的独有信息, 其中 D_k 为整合所有的注意力头后输出的映射矩阵列维度, 向量 m 通过与模型共同学习后得到。将其带入传统的多头注意力计算中, 可以得到协作多头注意力, 定义如下:

$$H^{(i)} = \text{Attention}(X\bar{W}_Q \text{diag}(m_i), Y\bar{W}_K, YW_V^{(i)})$$

$$\text{CollabHead}(X, Y) = \text{concat}_{i \in [N_h]} [H^{(i)}]W_0 \quad (6)$$

式中, \bar{W}_Q, \bar{W}_K 分别为查询向量、键向量的共享权重矩阵; $W_V^{(i)}$ 为第 i 个注意力头的值相量的权重矩阵; CollabHead 为协作注意力机制。

其中, \bar{W}_Q, \bar{W}_K 被所有注意力头部共同学习, 用于捕捉所有注意力头间的通用信息, 而 m 则帮助捕捉各头部的单独信息, 这种注意力的整合算法作用是: 增加头部注意力的自适应表达性, 头部注意力可以根据注意力模式的复杂程度相应增加或减少维度; 使得参数的计算更加高效, 所有注意力头共享学习 \bar{W}_Q 和 \bar{W}_K , 所以每轮训练只需计算 1 次。

根据上述分析, 可以推理出标准的多头注意力机制在计算注意力评分时, 其混合矩阵 M 的每列对应不同的头部, 因此本文设计了对应的混合矩阵 \bar{M} 用以捕捉所有头部的通用信息, 并对其进行压缩。图 4 所示为标准多头注意力与本文使用的协作多头注意力的对比示意。

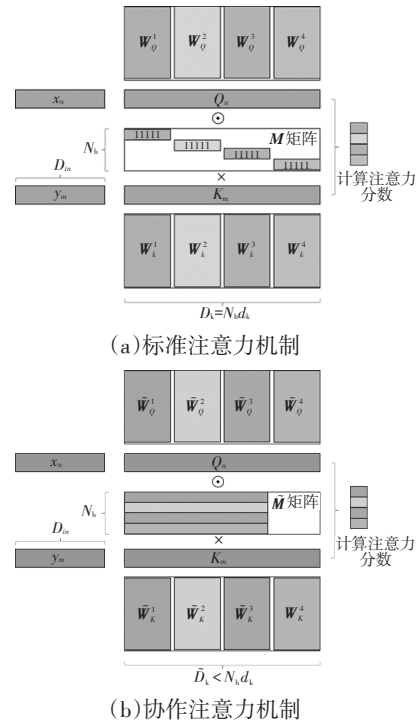


图4 标准注意力机制与本文采用的协作注意力机制

本文构建的图神经网络由 3 层组成, 首先, 协作注意力将所有节点组成的边的特征信息聚合, 然后迭代更新模型, 第 $(l+1)$ 层的第 i 个节点的图节点特征可以表示为:

$$n_i^{l+1} = n_i^l + M_{lp} \left(\left[n_i^l \parallel \text{Collab}(m_{E_i \rightarrow i}^l) \right] \right) \quad (7)$$

式中, $[\parallel \text{Collab}]$ 表示由协作注意力对所有头部特征点信息进行聚合; $m_{E_i \rightarrow i}^l$ 为图节点 i 根据图网络中的一阶邻居节点 E 所聚合的特征信息。

根据协作注意力和图神经网络得到的节点特征,利用车位推理层判断车位标记点对是否形成完整车位。车位推理层将不同的车位标记点进行连接,并计算其形成入口线的概率,如图5所示,车位推理层由一维卷积(Conv1d)层、随机失活(Dropout)层和Sigmoid激活层组成,其中Dropout层仅在训练时使用。




图5 车位推理层结构

最后,协作注意力图神经网络输出 $N \times N \times 5$ 的矩阵,其中 $N \times N$ 表示形成的车位标记点对数,5包括 x_1, x_2, y_1, y_2, p ,其中 (x_1, y_1) 和 (x_2, y_2) 为车位标记点位置坐标, p 为车位标记点形成入口线的概率。

2.4 损失函数

参考注意力图神经网络车位检测(attentional Graph neural network for Parking-slot detection, Gcn-Parking)算法^[11],为端到端地训练整个神经网络,本文损失函数的计算方法为:

$$l_s = \alpha_1 l_{\text{point}} + \alpha_2 l_{\text{sline}} \quad (8)$$

式中, l_{point} 为标记点回归损失; l_{sline} 为入口线分类损失; α_1 、 α_2 分别为 l_{point} 、 l_{sline} 的系数。

考虑到标记点检测的准确性直接影响车位的划分,本文利用图神经网络来探究标记点的内在联系,取 $\alpha_1=100$ 、 $\alpha_2=1$,此时检测效果最优。

标记点回归损失 l_{point} 是车位标记点预测与真值间的平方差之和,标记点检测器的输出层被划分为 $S \times S$ 大小单元的网格,故其计算过程为:

$$l_{\text{sc}} = \frac{1}{S^2} \sum_{i=1}^{S^2} (c_i - \hat{c}_i)^2$$

$$l_{\text{sxy}} = \frac{1}{S^2} \sum_{i=1}^{S^2} \mathbf{1}_i [(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2] \quad (9)$$

$$l_{\text{spoint}} = l_{\text{sc}} + l_{\text{sxy}}$$

式中, l_{sc} 为置信度的回归损失; l_{sxy} 为标记点坐标的回归损失; c_i 为标记点预测的置信度; (x_i, y_i) 为标记点投影的坐标; \hat{c}_i 、 (\hat{x}_i, \hat{y}_i) 分别为标记点预测的置信度和标记点投影的坐标对应的真值; $\mathbf{1}_i$ 为对标记点投影坐标的判断值,当投影坐标为真值时,取值为1,否则为0。

入口线分类损失 l_{sline} 的计算公式为:

$$l_{\text{sline}} = \frac{1}{N^2} \left(- \sum_{i=1}^N \sum_{j=1}^N \hat{l}_{ij} \log l_{ij} \right) \quad (10)$$

式中, l_{ij} 为第 i 个和第 j 个标记点形成车位入口线的预测概率; \hat{l}_{ij} 为 l_{ij} 对应的真值。

3 试验结果与分析

3.1 数据集与试验环境

本文在PS2.0^[9]的公共环视图像数据集上评估所提出的停车位检测算法。PS2.0数据集由9 827帧训练图像和2 338帧测试图像组成,分别包含9 476个停车位和2 168个停车位。根据DMPR-PS^[9]方法,选择7 780帧图像构成训练集、2 290帧图像作为测试图像。PS2.0数据集中的图像采集自不同环境条件下的典型室内外场景,分辨率为600像素 \times 600像素,对应10 m \times 10 m的现实地面区域。

本文在Ubuntu18.04操作系统、GeForce RTX 3060显卡,Pytorch 10.0框架环境下进行试验。训练批量大小为16,训练次数为200轮。本文训练时选用的学习率为0.003,权重衰减率为0.01,优化器为Adam_OneCycle,图6所示为PS2.0数据集下检验后的可视化图片。




图6 PS2.0数据集下检验后的可视化图片

3.2 试验指标设置

本文对算法进行了综合评估,包括推理效率和检测有效性。推理效率指标包括每幅图片推理时间和模型

大小,检测有效性指标包括精确率、召回率和微观F1(Micro-F1),其中Micro-F1为本文引入的参数,同时兼顾了分类模型的精确率和召回率,最大值为1,最小为

0。

精确率 P 为正确预测的正样本数量与预测为正样本的全部样本数量的比值,召回率 R 为正确预测的正样本数量与所有正样本数量的比值:

$$P = T_p / (T_p + F_p) \quad (11)$$

$$R = T_p / (T_p + F_n) \quad (12)$$

式中, T_p 为预测为正的样本数量; F_p 为预测为正的负样本数量; F_n 为预测为负的正样本数量。

对于本文的二分类问题, Micro-F1 的计算方法为:

$$F_M = 2RP / (R + P) \quad (13)$$

3.3 试验结果

使用 PS2.0 中的测试集对本文的车位检测算法进行测试,并与当前车位检测的主流算法进行比较,结果如表 1 所示。

表 1 PS2.0 数据集下的有效性对比结果 %

| 算法 | 精确率 | 召回率 | Micro-F1 |
|-----------------------------|-------|-------|----------|
| 文献[5]算法 | 98.29 | 58.33 | 78.31 |
| 文献[16]算法 | 98.45 | 61.37 | 75.61 |
| PSD_L ^[7] | 98.44 | 86.96 | 92.34 |
| DeepPS ^[9] | 98.99 | 99.13 | 99.06 |
| DMPR-PS ^[8] | 99.42 | 99.37 | 99.39 |
| PSDet ^[10] | 98.35 | 99.60 | 98.97 |
| VPS-Net ^[17] | 99.63 | 99.31 | 99.47 |
| 文献[18]算法 | 99.40 | 92.94 | 96.06 |
| SPFCN ^[19] | 98.01 | 97.31 | 97.66 |
| Gcn-Parking ^[11] | 99.56 | 99.42 | 99.49 |
| 本文算法 | 99.75 | 99.50 | 99.62 |

从表 1 中可以看出,本文提出的车位检测算法在召回率和 Micro-F1 指标上优于当前的主流算法,这表明利用协作注意力和图神经网络的结构可以在复杂环境下学习并提取图像中车位的更多特征。其中:前 3 种算法为利用图像特征检测车位的传统算法,其准确度和召回率均低于基于深度学习的算法; DeepPS、DMPR-PS、基于深度学习的空车位检测方法 (Vacant Parking Slot detection method based on deep learning, VPS-Net)、车位检测方法 (Parking Slot Detection, PSDet) 为二阶段检测算法;用于实时停车位检测的选择修剪全卷积网络 (Select and Prune the Fully Convolutional Networks for real-time parking slot detection, SPFCN)、文献[18]算法、Gcn-Parking 和本文算法为端到端的单阶段检测算法。本文算法既保留了单阶段神经网络的优点,又省去了复杂的后处理操作,同时提升了检测的有效性。相比于传统算法中精度最高的基于学习的车位检测算

法 (Parking-Slot Detection based on Learning, PSD_L), 本文准确率提高了 1.31 百分点,召回率提高了 12.54 百分点;相比于单阶段算法中精度最高的 Gcn-Parking, 本文精确率提高了 0.19 百分点,召回率提高了 0.08 百分点;相比于二阶段算法中精度最高的 VPS-Net, 本文精确率提高了 0.12 百分点,召回率提高了 0.19 百分点。

考虑到一些算法未提供模型大小与推理速度,选取部分算法进行比较,如表 2 所示,相比于目前优秀的车位检测算法 VPS-Net 和 Gcn-Parking, 本文算法的模型大小分别为前者的 34.2%、后者的 16.63%,每帧图像的运行时间与前者相比缩短了 9.95 ms,与后者相比缩短了 15.2 ms。可见本文算法相比于其他车位检测算法模型具有参数数量少、运行时间短、推理速度快的优点,在实际部署时具有一定的优势。

表 2 PS2.0 数据集下的推理效率对比结果

| 算法 | 模型大小/MB | 运行时间/ms |
|-----------------------------|---------|---------|
| PSD_L ^[7] | 8.38 | 40 |
| DeepPS ^[9] | 255 | 17 |
| DMPR-PS ^[8] | 121.3 | 12 |
| VPS-Net ^[17] | 226 | 20.05 |
| Gcn-Parking ^[11] | 465.4 | 25.3 |
| 本文算法 | 77.4 | 10.1 |

3.4 消融试验

为验证修改后网络的优越性,本文进行了对比试验,在本文算法的总体架构下,将特征提取网络替换为主流的特征提取网络和一些轻量化的特征提取网络模型,用于进行比较。本文试验以模型复杂度、精确率、召回率和 Micro-F1 作为评价指标,其测试结果如表 3 所示。

表 3 不同特征提取网络的性能指标比较

| 网络名称 | 精确率/% | 召回率/% | Micro-F1/% | 模型大小/MB | 运行时间/ms |
|-------------------------------|-------|-------|------------|---------|---------|
| Darknet | 99.50 | 99.48 | 99.49 | 296.7 | 15.6 |
| VGG16 | 99.60 | 99.42 | 99.53 | 263.8 | 27.0 |
| ResNet50 | 99.50 | 99.26 | 99.38 | 214.6 | 17.7 |
| GhostNet ^[20] | 99.63 | 99.51 | 99.57 | 113.2 | 11.7 |
| ShuffleNet V2 ^[21] | 99.34 | 99.18 | 99.26 | 67.4 | 10.3 |
| 本文算法 | 99.75 | 99.50 | 99.62 | 77.4 | 10.1 |

由表 3 可知,本文修改后的骨干网络不仅达到了较高的精确率和召回率,同时模型参数数量少、运行速度快,优于其他方案。

为了研究本算法的各改进部分在整体算法中发挥的作用,利用消融试验对整体算法进行研究。以

MobileNetV3 特征提取网络和图神经网络为基础,逐步加入深度可分离卷积、协作注意力机制,以及TSE注意力机制,对方案优化改进,并在PS2.0数据集上进行检测试验,结果如表4所示。

表4 消融试验结果

| 深度可分离卷积 | 协作注意力 | TSE注意力 | 精确率/% | 召回率/% | Micro-F1/% | 模型大小/MB | 运行时间/ms |
|---------|-------|--------|-------|-------|------------|---------|---------|
| × | × | × | 99.42 | 99.42 | 99.42 | 279 | 12.5 |
| √ | × | × | 99.34 | 99.50 | 99.42 | 77.9 | 10.8 |
| √ | √ | × | 99.50 | 99.67 | 99.58 | 77.4 | 10.1 |
| √ | √ | √ | 99.75 | 99.50 | 99.62 | 77.4 | 10.1 |

当损失函数选取不同的系数时,得到的检测结果如表5所示。

表5 不同损失系数的结果

| α_1 | α_2 | 精确率/% | 召回率/% |
|------------|------------|-------|-------|
| 1 | 1 | 98.45 | 99.26 |
| 50 | 1 | 97.65 | 98.77 |
| 100 | 1 | 99.75 | 99.50 |
| 150 | 1 | 99.42 | 99.09 |

由表4和表5可知,本算法经过消融试验后,通过对算法的不断优化,在实时性方面,每帧图像处理时间为10.1 ms,并将模型大小缩减至77.4 MB,在有效性方面,达到了99.75%的精确率、99.50%的召回率和99.62%的Micro-F1指标,有效地平衡了算法的实时性和准确性。

4 结束语

本文提出了一种基于协作注意力和图神经网络的轻量化车位检测算法,利用协作注意力和图神经网络加深了车位标记点间的内在联系,保证了车位识别的精确率和召回率,同时,针对计算繁琐、模型参数数量多的卷积神经网络算法和图神经网络算法在实车部署上的困难,使用轻量化的网络结构,并对协作注意力和图神经网络算法加以改进,最后,在PS2.0车位数据集上进行了对比试验和消融试验,验证了算法的可行性。结果表明,本文算法优于当前的大部分主流车位检测算法,满足更快、更准确的检测需要,符合时间紧迫的自动泊车任务要求。

参 考 文 献

[1] 孙宏伟,陈慧,宋绍禹.一种基于强化学习的小库位自动平行泊车运动规划方法(英文)[J].汽车技术,2021(9):17-26.
SUN H W, CHEN H, SONG S Y. A Motion Planning Method

Based on Reinforcement Learning for Automatic Parallel Parking in Small Slot[J]. Automobile Technology, 2021(9): 17-26.

- [2] 任秉韬,王浙浙,邓伟文,等.基于混合A*和可变半径RS曲线的自动泊车路径优化方法[J].中国公路学报,2022,35(7):317-327.
REN B T, WANG X X, DENG W W, et al. Path Optimization Algorithm for Automatic Parking Based on Hybrid A* and Reeds-Shepp Curve with Variable Radius [J]. China Journal of Highway and Transport, 2022, 35(7): 317-327.
- [3] SUHR J K, JUNG H G. End-to-End Trainable One-Stage Parking Slot Detection Integrating Global and Local Information[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 23(5): 4570-4582.
- [4] 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.
ZHU W W, HUANG H C, MA J X. A Research on Parking Space Detection Algorithm Based on Image Recognition[J]. Automotive Engineering, 2019, 41(7): 744-749+756.
- [5] WANG C X, ZHANG H R, YANG M, et al. Automatic Parking Based on a Bird's Eye View Vision System[J]. Advances in Mechanical Engineering, 2014, 6.
- [6] SUHR J K, JUNG H G. Sensor Fusion-Based Vacant Parking Slot Detection and Tracking[J]. IEEE Transactions on Intelligent Transportation Systems, 2014, 15(1): 21-36.
- [7] LI L S, ZHANG L, LI X Y, et al. Vision-Based Parking-Slot Detection: A Benchmark and a Learning-Based Approach [C]// 2017 IEEE International Conference on Multimedia and Expo (ICME). Hong Kong, China: IEEE, 2017: 649-654.
- [8] HUANG J H, ZHANG L, SHEN Y, et al. DMPR-PS: A Novel Approach for Parking-Slot Detection Using Directional Marking-Point Regression[C]// 2019 IEEE International Conference on Multimedia and Expo (ICME). Shanghai, China: IEEE, 2019: 212-217.
- [9] ZHANG L, HUANG J H, LI X Y, et al. Vision-Based Parking-Slot Detection: A DCNN-Based Approach and a Large-Scale Benchmark Dataset[J]. IEEE Transactions on Image Processing, 2018, 27(11): 5350-5364.
- [10] WU Z Z, SUN W W, WANG M, et al. PSDet: Efficient and Universal Parking Slot Detection[C]// 2020 IEEE Intelligent Vehicles Symposium (IV). Las Vegas, NV, USA: IEEE, 2020: 290-297.
- [11] MIN C, XU J L, XIAO L, et al. Attentional Graph Neural Network for Parking-Slot Detection[J]. IEEE Robotics and Automation Letters, 2021, 6(2): 3445-3450.
- [12] HOWARD A, SANDLER M, CHU G, et al. Searching for MobileNetV3[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision. Seoul,

- Korea: IEEE, 2019: 1314-1324.
- [13] VOSCO N, SHENKLER A, GROBMAN M. Tiled Squeeze-and-Excite: Channel Attention with Local Spatial Context [C]// Proceedings of the IEEE/CVF International Conference on Computer Vision. Montreal, BC, Canada: IEEE, 2021: 345-353.
- [14] VASWANI A, SHAZEER N, PARMAR N, et al. Attention Is All You Need [C]// Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, California, USA: Curran Associates Inc., 2017: 118-128.
- [15] CORDONNIER J B, LOUKAS A, JAGGI M. Multi-Head Attention: Collaborate Instead of Concatenate [EB/OL]. (2021-05-20) [2023-03-01]. <https://arxiv.org/abs/2006.16362>.
- [16] HAMADA K, HU Z, FAN M, et al. Surround View Based Parking Lot Detection and Tracking [C]// 2015 IEEE Intelligent Vehicles Symposium (IV). Seoul, Korea: IEEE, 2015: 1106-1111.
- [17] LI W, CAO L B, YAN L B, et al. Vacant Parking Slot Detection in the Around View Image Based on Deep Learning [J]. Sensors, 2020, 20(7).
- [18] JIAN D H, LIN C H. Vision-Based Parking Slot Detection Based on End-to-End Semantic Segmentation Training [C]// 2020 IEEE International Conference on Consumer Electronics (ICCE). Seoul, Korea: IEEE, 2020: 1-4.
- [19] YU Z P, GAO Z, CHEN H S, et al. SPFCN: Select and Prune the Fully Convolutional Networks for Real-Time Parking Slot Detection [C]// 2020 IEEE Intelligent Vehicles Symposium (IV). Las Vegas, USA: IEEE, 2020: 445-450.
- [20] HAN K, WANG Y H, TIAN Q, et al. GhostNet: More Features from Cheap Operations [C]// 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA: IEEE, 2020: 1577-1586.
- [21] MA N, ZHANG X, ZHENG H T, et al. ShuffleNet V2: Practical Guidelines for Efficient CNN Architecture Design [C]// Proceedings of the 15th European Conference on Computer Vision (ECCV). Munich, Germany: Springer, 2018: 116-131.

(责任编辑 斛 畔)

修改稿收到日期为2023年3月1日。

《汽车工艺与材料》投稿须知

《汽车工艺与材料》杂志创刊于1986年,是由中国第一汽车集团有限公司主办的国内外公开发行的汽车制造类月刊、中国汽车工程学会会刊,是全面报道汽车先进制造工艺与材料应用的专业性杂志。

《汽车工艺与材料》杂志始终致力于汽车制造新技术的开发(如汽车制造领域中的四大工艺)、新材料的研究应用、轻量化技术、智能制造、绿色制造技术、加工技术、生产装备、检测技术、数字化模拟技术及生产管理等方面的报道。努力为汽车及零部件生产中各门类的决策者及研究开发人员提供更好、更快、更节约成本的汽车行业发展动态信息,为其适应国内与国际激烈的汽车生产市场竞争提供有效的帮助。

《汽车工艺与材料》杂志关注领先的整车及零部件企业和材料、装备等供应商,及时报道汽车行业最新的设计、制造、材料、加工技术、生产装备、检测技术等方面的成功案例。

主要栏目:

AT&M视界、生产现场、材料应用、生产装备、检测技术、数字化园地、行业动态等。

投稿要求:

(1)来稿须具有独创性并与实践相结合,文章字数最好控制在6000字以内。

(2)来稿不能在国内、外公开杂志上发表过,严禁一稿多投,对同时一稿多投者,编辑部将视对本刊声誉、工作上造成的影响程度,采取相应处理措施。

(3)来稿的试验方法、试验数据、试验结论必须准确、可靠。

(4)来稿须包括以下项目:题名、作者姓名、作者单位、中文摘要(200字左右)、参考文献等。来稿采用word文档的格式。

(5)来稿文章格式应符合一般科技论文格式,或参考近期本刊所刊登文章格式。

(6)稿件图片请发清晰原图,图形尺寸应适中,并配上图名和图号,且文中要有相应体现(例如:如图1所示、见图2等)。图中英文需要翻译成中文。

(7)计量单位必须采用(或换算成)中华人民共和国法定计量单位。文章中外文字母大小写、上下角标应书写正确,避免同一符号代表2种及以上物理量的情况出现。

(8)文章必须附有公开发表的参考文献,且在文中应标注文献引用处。参考文献录项目应齐全,包括作者姓名、题名、刊名(或书名,图书应注明出版地与出版社)、出版年、卷、期。

(9)请在来稿时注明作者联系方式(包含手机、办公室电话、E-mail等)。

(10)本刊投稿网址:<http://qcgycj.cbpt.cnki.net>,咨询电话:0431-82028069。

竭诚欢迎汽车行业及相关各界的专家学者积极向本刊投稿。