

DOI: 10. 13382/j. jemi. B2003051

面向铁路货车车号定位的 Faster R-CNN 卷积神经网络*

张晓丽 董 昱

(兰州交通大学 自动化与电气工程学院 兰州 730070)

摘 要:为了解决传统算法对于铁路货运列车车号识别准确率不高问题,提出了一种面向铁路货车车号定位的 Faster R-CNN 神经网络。通过调整特征提取网络的相关尺寸参数及连接方式增强了最后一层卷积特征图的细节特征。并采用 *k-means++* 聚类算法求取车号区域长宽比改进 anchor 尺寸设计,使目标检测框与实际车号区域更加贴合。实验过程中,采用了数据增广、*dropout* 方法提升网络的鲁棒性。结果显示,改进 Faster R-CNN 网络在铁路货车车号定位精度达到了 93. 15%,召回率 90. 76%,综合 *F1* 指标 91. 94%,也说明该方法能够对铁路货车车号准确定位,并为车号识别过程提供可靠的数据支持。

关键词:货车车号定位;Faster R-CNN;卷积神经网络;特征增强

中图分类号: TP391. 41 **文献标识码:** A **国家标准学科分类代码:** 580. 3030

Faster R-CNN convolutional neural network for the location of freight train number

Zhang Xiaoli Dong Yu

(College of Automation and Electrical Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China)

Abstract:In order to solve the problem of low accuracy of traditional algorithm for train number identification of railway freight trains, Faster R-CNN neural network for train number location of railway freight trains is proposed. The detailed features of the final convolution feature map are enhanced by adjusting the relevant size parameters and connection mode of the feature extraction network. The *k-means++* clustering algorithm is used to calculate the length width ratio of the train number area. The improved anchor size design makes the target detection frame more suitable for the actual train number area. In the experiment, data augmentation and dropout are used to improve the robustness of the network. The results show that the improved Faster R-CNN network has achieved 93. 15% accuracy in the location of railway freight train number, 90. 76% recall rate and 91. 94% comprehensive *F1* index. It also shows that this method can accurately locate the railway freight train number and provide reliable data support for the identification process.

Keywords:train number location; Faster R-CNN; convolutional neural network; feature enhancement

0 引 言

编组站作为铁路网上重要的车流集散地和交通枢纽,设在车流量大并且较为集中的地点,具备两条溜放线的编组站日均解编量可达 3 000~5 000 辆^[1],承担了巨大的工作量,降低人的劳动强度、提高编组站的运行效率已经是一个亟待解决的问题,货运列车的信息化管理已经是势在必行了。自 1999 年开建的铁路车号自动识别系统(ATIS)工程仅在编组站进出口位置设置车号的自

动识别装置,对于编组站内部车辆情况信息仍是空白。目前,站内设置计轴器通过计算经过车辆轮轴数目来间接判断车辆位置,要获取车辆的车号信息必须与相关作业计划结合,过程繁琐,很容易出现严重失误。经过多方研究,本文提出一种应用在编组站的货车车号识别方法,一方面可以实现车辆的作业过程的闭环控制,另一方面可以实现在相对较低成本下,可提供比计轴器更多功能,如计算车辆节数、测速、识别车号等,车辆的运行数据清晰明了,实现信息一次性获取。

近年来,科研工作者对货车车号的识别进行了许多



深入的研究,主要有基于微波射频调制技术和基于图像处理技术的车号识别方法。基于射频识别技术的车号自动识别系统是通过读取安装在车厢底部的电子标签信息来获取货车车号。但货车运行条件恶劣,对电子标签的维护力度不够、轨道不够平整、受列车运行速度影响大、造价高等原因,很容易发生漏号识别^[2]。基于图像处理技术的车号识别需要在相应位置设置图像拍摄装置,室内设置主机进行处理识别,操作简单,易于维护,且受列车运行因素干扰小。因此,本文选择基于图像处理的方法进行车号自动识别。

识别过程一般分为车号区域定位和车号识别两步。车号区域的定位结果作为车号准确识别的基础和前提,其准确性在很大程度上会影响到整个车号识别的结果。所以,本文以货车车号定位作为主要研究内容。目前常用定位方法包括基于边缘检测、基于笔画宽度、基于数学形态学等定位方法。基于边缘检测的方法^[3-4]一般需要和形态学方法、投影法等算法相结合实现车号定位,但此方法受光照影响大,而且货车车身一般会有许多栅栏,边缘检测会检测出大量多余边缘点,需要丰富经验来区别车号区域和伪车号区域;基于笔画宽度变换的方法^[5-7]是在 Canny 边缘检测算子对图像进行边缘检测后开始计算的,这种算法计算量大,时间开销大,而且货车车身还漆刷有载重、换长等文本噪声,容易对车号区域定位产生干扰。

铁路货车车身同时漆刷有大车号和小车号,除了字体大小的区别,其内容完全一致。铁路货车运行条件恶劣,恶劣的运行环境及反复性的装货、卸货往往会造成车号字符颜色淡化,如果实现大、小货车车号的同时检测,车号内容可以相互补充,进一步提高识别的准确率。但以上的车号定位方法研究当中,绝大多数算法对图片的质量较高,而且经试验发现,因为车号区域占比较小,传统算法仅能检测出大车号目标区域。

近年来,随着众多研究者们对深度学习的深入研究,基于深度学习的图像处理方法已经在文本检测^[8-9]、农业植被检测^[10-11]、车辆检测^[12]等领域当中都取得了令人满意的结果。目前,应用较广泛的货车车号检测算法多是以文本检测为基础的,自 Faster R-CNN 神经网络被提出,文本检测领域有了突破性的进展,也为货车车号定位打开了一扇大门。它的一系列变体在目标检测领域中表现突出,尤其是小目标检测领域^[13],为本课题的研究提供了基础算法支持。因此,本文根据文献^[14]思路建立传统模型,针对货车车号特征,调节卷积特征提取网络的相关参数,融合浅层特征和深层特征对最后一层特征图进行特征加强,并采用 k-means++ 算法对网络 anchor 尺寸进一步优化,为验证本文提出改进方法的有效性,在自收集铁路货车数据集

上做了相关实验,实验结果表明,本文提出方法可以准确定位出铁路货车车号区域。

1 基于 Faster R-CNN 车号区域定位

1.1 Faster R-CNN 简介

Faster R-CNN 目标检测模型是在 R-CNN^[15]、Fast R-CNN^[16]的基础上改进,生成的一种优化目标检测模型。Faster R-CNN 网络结构如图 1 所示,网络分为特征提取子网络、RPN 子网络和分类回归子网络 3 部分。基于 Faster R-CNN 的铁路货车车号区域定位步骤如下。

1) 将图片首先进入特征提取网络,得到表示高层语义信息的特征图。

2) RPN 网络根据提取到的卷积特征图,在特征图每一个像素点处 9 种覆盖参考建议框(又称 anchors),并通过 anchor 映射回原图,找到候选框位置,判断 anchor 属于前景还是背景。如图 1 红色框标注部分。

3) 分类及回归子网综合特征图和候选框信息,判定前景所属类别,即大车号区域、小车号区域或伪车号区,并生成最终检测框的精确位置。

1.2 特征提取子网络

特征提取网络作为 Faster R-CNN 的基础,用于提取输入图片的语义信息。特征提取的效果会影响到网络后续的结果,针对货车车号区域的定位,选择一个合适的基层特征提取网络表现的尤为重要。常见的特征提取网络有 ZF^[17]、VGG16、ResNet^[18] 3 种类型。本节设置实验对以上 3 种网络进行测试,测试结果如表 1 所示。

实验结果表明,针对货车大车号检测,ZF 网络的检测结果没有其他两种方法好,而对于小目标车号的检测问题,ZF 网络展示出了优越的性能,所以本文选择 ZF 网络作为特征提取基础网络,结合另外两种网络特点进行改进。传统 ZF 网络结构如图 2 所示。

1.3 RPN 子网络

RPN 网络用于提取目标区域建议框。首先,利用 3×3 滑窗进一步提取特征得到其特征图,然后将此特征图分别送入分类和回归层,其本质是两个并行的全连接层。以输入特征图的每个位置为中心,都铺设 3 种尺度 {128, 256, 512} 和 3 种比例 {1:1, 1:2, 2:1} 的参考建议框(本文称为 anchors)用来检测不同尺寸的目标物体,其结构如图 3 所示。

将每一个 anchor 映射回原图,对每一个原图对应的 anchor 进行前景置信度的计算,结合非极大抑制思想,以交并比(intersection over union, IOU)作为指标,即模型预测候选框和任意一个标记候选框的交叠率,计算方法如式(1)。




图 1 Faster R-CNN 网络结构
Fig. 1 Faster R-CNN network structure

表 1 3 种网络定位准确率对比表

Table 1 Comparison table of three kinds of network positioning accuracy

网络	大车号准确率/%	小车号准确率/%	时间/s
ZF	79.64	40.26	0.014 3
ResNet	83.26	17.36	0.053 7
VGG	82.49	19.38	0.041 6




图 2 传统 ZF 网络结构(不含全连接层)
Fig. 2 Traditional ZF network structure (excluding fully connected layers)




图 3 RPN 网络结构
Fig. 3 RPN network structure

$$IOU = \frac{S_{\text{anchorBox}} \cap S_{\text{groundTruth}}}{S_{\text{anchorBox}} \cup S_{\text{groundTruth}}} \quad (1)$$

式中: $S_{\text{anchorBox}}$ 表示预测的候选框; $S_{\text{groundTruth}}$ 表示标记候选框。

网络最终选取前 300 个 anchors 作为 RPN 子网输出结果,选取 anchors 的规则如下^[19]。

规则 1,若 anchor 对应的候选框和某一标记框的交叠率最大,则标记为正样本。

规则 2,若 anchor 对应的候选框和某一标记候选框的指标 $IOU>0.7$,则标记为正样本。

规则 3,若 anchor 对应候选框和某一标记候选框的指标 $IOU<0.3$,则标记为负样本。

本文将标记为正样本的 anchors 认为有可能包含前景物体的候选框,即目标物体,标记为负样本的认为所包含内容属于背景,即非目标物体。将标记为正样本的 anchors 根据 IOU 指标进行排序,由高到低进行排序,选取前 300 个 anchors 作为 RPN 输出结果。回归层计算 anchors 相对标记候选框的位置偏移量,用 $(\Delta x, \Delta y, \Delta w, \Delta h)$ 分别表示候选框左上角坐标 (x, y) 、矩形框宽度 w 及高度 h 的偏移量值,根据偏移量值进行区域边框位置回归。位置回归计算公式如下:

$$\begin{cases} t_x = (x - x_a) / w_a, & t_y = (y - y_a) / h_a \\ t_w = \log(w / w_a), & t_h = \log(h / h_a) \\ t_x^* = (x^* - x_a) / w_a, & t_y^* = (y^* - y_a) / h_a \\ t_w^* = \log(w^* / w_a), & t_h^* = \log(h^* / h_a) \end{cases} \quad (2)$$

式中: x, y, w, h 表示预测边框的中心坐标及其宽和高;变量 x, x_a, x^* 分别表示预测边框、anchor、真实区域边框的 x 坐标(y, w, h 同样适用)。

2 Faster R-CNN 网络的分析及改进

Faster R-CNN 在通用目标检测领域表现优异,但是对小目标物体的检测效果不太理想。因此,本文结合货车小车号区域定位需求,对 Faster R-CNN 网络加以改进,提高 Faster R-CNN 网络对车号区域定位的准确率。

2.1 特征提取网络的分析与改进

传统 ZF 网络采用的卷积核尺寸较大,具有较大感受野,其特征图相对分辨率较小,这对于大尺度目标的检测是有效的,但对于小目标货车车号区域检测效果很不理想。鉴于以上分析,本文针对传统 ZF 特征提取网络做了一下改进。




图 4 改进后的特征提取网络

Fig. 4 Improved feature extraction network

将第 3 卷积层和第 5 卷积层进行特征融合得到浅层特征图 C1。特征融合一般有元素求和或计算点积两种方式,卷积神经网络得到特征图相当于是通道数深度的二维矩阵,矩阵元素求和或计算点积要求矩阵维度相同。由于第 3 层和第 5 层特征图通道数不同,故将第 3 层后叠加一层核尺寸为 1×1 的 256 通道卷积层,将原来 96 通道的特征图升维成 256 通道,和第 5 卷积层进行特征融合。得到浅层特征 C1 与第 7 卷积层特征图输出的深层次特征进行融合,最后与第 8 卷积层特征融合输出最终结果。

2.2 基于 RPN 网络分析与改进

现有 Faster R-CNN 网络并没有涉及到货车车号识别的相关应用,但 RPN 子网最关键部分—anchor 的设计比例具有一般性。从现有采集图像可以看出,车号区域的长度、宽度会受到货车车身构造的影响,为了提高 Faster R-CNN 网络的收敛速度和准确率,将货车车号的大小与 RPN 网络的 anchor 设计结合。根据铁道车辆标记一般规则和货车车号编码规则两则标准可以计算出,单行货车车号区域的长宽比例接近 7 : 1,双行货车车号区域的长宽比例接近 4 : 1,为了确切反映出货车车号区域的大小尺寸,本文沿用文献[20]思路,选定 3 种具有代表的长宽比优化传统网络 anchor 比例设计。实验结果如图 5 所示。

1) 卷积核的改进

将 ZF 中将卷积核尺寸原 7×7 的卷积核用 3 层 3×3 卷积核来代替,即原 conv1 改进为 conv1_1、conv1_2 及 conv1_3。原 5×5 的卷积核用两层 3×3 卷积核来代替,即原 conv2 改进为 conv2_1 及 conv2_2。虽然网络层数由原来 5 层变为 8 层,但减少了 71.287% 的参数量,网络规模更小。

2) 基于级联的特征融合

Faster R-CNN 网络中仅将特征提取网络的最后一层卷积特征图作为后续操作的输入,但最后一层卷积特征图中的每个点都融合了大量的周围信息,其特征图相对分辨率较小,具有很强的语义信息。货车车号区域在整张图片区域中所占的比例较小,其所包含细节信息对于检测小目标是不够的,故本文选择一种基于级联的特征融合策略,增强图像深层特征,级联结构如图 4 所示。




图 5 k-means++ 获取车号区域最优比结果

Fig. 5 The k-means ++ algorithm is used to obtain the optimal ratio result of rehicue number region



本文实验利用了 289 组样本点,通过实验,选定 $k=3$,从实验结果来看,计算出可以反映铁路货车车号候选框大小的长宽比为 $\{7.014\ 5, 4.835, 2.000\ 5\}$,取整后的长宽比是 $\{7, 5, 2\}$ 。




图 6 RPN 子网 anchor 优化对比

Fig. 6 Anchor optimization comparison for the RPN

如图 6 所示,图中白色框表示 anchor 位置,图 6(a) 为传统 anchors 覆盖车号区域的结果,可以看出边界框精度较低。图 6(b) 为优化 anchor 的长宽比例的覆盖结果,可以看出改进后的 anchors 候选框与车号区域,尤其是小火车号区域边界框更为贴切。

2.3 分类网络的输出改进

本文将大车号区域、小车号区域同时作为目标物定位,因此,本文将 Faster R-CNN 最后分类结果可归为 3 类,即大车号区域、小车号区域与伪车号区域。

2.4 Faster R-CNN 网络的训练策略

本文改进后的 Faster R-CNN 网络结构相比传统网络结果差异较大,不能在预先训练好的 Faster R-CNN 结构上微调。因此,文本选择 adadelta 算法训练 Faster R-CNN 网络,网络的训练步骤如下。

1) 预先训练特征提取网络 ZF,生成特征图。

2) 利用初始化好的特征提取网络训练 RPN,生成感兴趣区域(region of interest, ROI)。

3) 针对步骤 2) 得到的 ROI,利用预训练好的特征提取网络进行回归和分类训练。

4) 利用步骤 3) 得到的网络训练 RPN,只调整 RPN 特有参数,并生成 ROI。

5) 利用生成的 ROI 训练网络进行分类与回归,保持共享的卷积层参数固定。

训练目标函数如下:

$$L_{\text{oss}}(\{p_i\}, \{t_i\}) = \frac{1}{N_{\text{cls}}} \sum_i L_{\text{cls}}(p_i, p_i^*) + \lambda \frac{1}{N_{\text{reg}}} \sum_i p_i^* L_{\text{reg}}(t_i, t_i^*) \quad (3)$$

式中: i 表示一个批次中第 i 个 anchor, p_i 表示第 i 个 anchor 是前景的概率,当第 i 个 anchor 为前景时, p_i^* 为 1,反之为 0; t_i 表示预测的 bounding box 的坐标, t_i^* 为 ground truth 的坐标。 L_{cls} 是分类损失函数, L_{reg} 是回归损失函数,其中 p_i^* L_{reg} 表示回归只对正样本进行损失计算。

式(3)中 L_{cls} 定义为:

$$L_{\text{cls}} = -\log(p_i p_i^* + (1 - p_i^*)(1 - p_i)) \quad (4)$$

L_{reg} 定义为:

$$L_{\text{reg}}(t_i, t_i^*) = \sum_i \text{smooth}_{\text{L1}}(t_i - t_i^*) \quad (5)$$

其中, $\text{smooth}_{\text{L1}}(t_i - t_i^*)$ 定义为:

$$\text{smooth}_{\text{L1}}(t_i - t_i^*) = \begin{cases} 0.5(t_i - t_i^*)^2, & |t_i - t_i^*| < 1 \\ |t_i - t_i^*| - 0.5, & |t_i - t_i^*| \geq 1 \end{cases} \quad (6)$$

3 实验结果分析

本文实验环境及硬件条件:3.00 GHz CPU,12 GB 内存,NVIDIA Geforce 920 M, 64 位操作系统;软件环境为 Windows10,框架是 TensorFlow,开发语言是 Python,并搭有 CUDA9.0 和 CUDNN7.1 并行处理开发软件。实验中,数据集是主要从某编组站收集的货车运行图像数据,总共 12 625 张图片,包含各种自然场景下的图片,如光线昏暗、倾斜、模糊、有污渍等情况下的货车图片。经过调整对比度、旋转等变换后,共得到 22 263 张图片,其中训练集包括 20 000 张图片,测试集有 2 263 张货车图片。数据增广部分示例如图 7 所示。




图 7 图像数据增广结果

Fig. 7 Image data augmentation

3.1 实验设计

为了验证对 Faster R-CNN 的改进方法对车号定位结果的有效性,进行如下实验。

实验 1,传统 Faster R-CNN 网络结合分类与回归输出层的改进。

实验 2,传统 Faster R-CNN 网络结合分类与回归输出层的改进、RPN 子网的改进。

实验 3,传统 Faster R-CNN 网络结合分类与回归输出层的改进、特征提取网络卷积核改进。

实验 4,传统 Faster R-CNN 网络结合分类与回归输出层的改进、特征融合的改进。

实验 5,传统的 Faster R-CNN 网络结合实验 1~4 改进。

在对以上 5 组实验网络分别进行训练,为了便于比较算法改进的有效性,本文主要参考了汽车车牌检测、文本检测、行人检测及农业草本植物检测等比较通用的评价标准,选用召回率(Rec)和准确率(Acc)作为本文方法的评价指标,其计算方法如下:

$$Rec = \frac{\text{正确定位的车号个数}}{\text{测试集中车号个数总和}} \quad (7)$$

$$Acc = \frac{\text{定位正确的车号个数}}{\text{算法判定为车号的个数}} \quad (8)$$

召回率表示判定为车号区域且判定正确的车号个数占测试集图片总数的比率。准确率表示算法判定为车号且判定正确的车号个数占判定为车号区域的比率。一般来说,准确率的提升往往伴随着召回率的下降。因此,本文使用 F1 评估值综合衡量指标,对算法进行更全面的评价。其计算方法如下:

$$F1 = \frac{2 \times Acc \times Rec}{Acc + Rec} \quad (9)$$

3.2 结果分析

利用自收集货车图像数据集来训练改进后 Faster R-CNN 网络,本文对 Faster R-CNN 网络共做了 4 项改进,为了验证每条改进的有效性,对实验 1~5 作对比。针对大、小车号的定位比较结果,如表 2、3 所示。

表 2 改进 Faster R-CNN 对大车号定位实验结果
Table 2 Improved Faster R-CNN for large freight train number positioning experiment results

方法	图像数	评价指标		
		Acc	Rec	F1
1	2 263	0.851 2	0.900 3	0.875
2	2 263	0.875 6	0.872 1	0.874
3	2 263	0.886 7	0.885 2	0.886
4	2 263	0.863 6	0.898 4	0.881
5	2 263	0.922 5	0.860 7	0.891

表 3 改进 Faster R-CNN 对小车号定位实验结果
Table 3 Improved Faster R-CNN for small freight train number positioning experiment results

方法	图像数	评价指标		
		Acc	Rec	F1
1	1 852	0.468 5	0.314 6	0.376
2	1 852	0.723 7	0.679 1	0.701
3	1 852	0.798 0	0.576 2	0.669
4	1 852	0.786 4	0.635 2	0.702 8
5	1 852	0.906 7	0.648 1	0.756

可以看出,实验 2~4 对大、小车号的定位精度均优于实验 1,说明针对 Faster R-CNN 的 4 项改进对货车车号定位精度上都有所提高。实验 5 是综合实验 1~4 改进得出的新型网络,从表 2、3 可以看出,对大车号的定位精度提升了 7.13%,小车号定位精度提升到 90.67%,大车号召回率有所下降,总体上大车号 F1 值提升了 1.54%,小车号定位 F1 值提升到 75.6%。

另外,为了提高网络的泛化能力,防止过拟合,本文选择在训练阶段采用 dropout 的方法提高网络的泛化能力,避免网络出现过拟合。训练过程中,通常随机初始化 dropout 值为 0.5,即随机选择网络中一半的神经元参与网络运算^[21]。dropout 对检测精度的影响一般会受到图片数据量和训练迭代次数的影响。所以,在本次实验中,选取间隔为 0.05 的 dropout 值分别训练改进的 Faster R-CNN,通过设置最优的 dropout 来寻找网络的最高精度值。本文以 0.5 为中心,向下选择 dropout=0.45,向上选择 dropout=0.55,0.6,0.65,0.7 分别进行试验,实验结果如表 4 所示。

表 4 不同 dropout 值对网络精度的影响
Table 4 Influence of different dropout values on network accuracy

指标	不同 dropout 值网络精度					
	0.45	0.5	0.55	0.6	0.65	0.7
Acc	0.910 4	0.917 6	0.931 5	0.926 3	0.932 6	0.926 3
Rec	0.877 2	0.890 6	0.907 6	0.892 5	0.891 1	0.900 2
F1	0.893 5	0.903 9	0.919 4	0.909 1	0.911 4	0.913 1

可以看出,改进 Faster R-CNN 网络的检测精度达到了 92.25%,召回率达到了 86.07%,综合 F1 指标达到了 89.05%。由表 4 可知,当网络 dropout 值设置为 0.55 时,网络取得了最佳的定位效果,精度为 93.15%,召回率为 90.76%,综合 F1 指标为 91.94%。

使用训练好的网络进行在测试集中进行实验,识别部分结果如图 8 所示。图 8(a)、(c)、(e)、(g)、(i)是利用传统 Faster R-CNN 网络^[14]对测试集展示的部分结果,图 8(b)、(d)、(f)、(h)、(j)是改进后的 Faster R-CNN 网

络的定位结果,虚线框表示定位正确的候选框,实线框表示定位失败的候选框,由图 8 可以看出,相比传统算法,本文算法的候选框与车号区域更加贴切,对小车号的定位准确率也有明显提升。




图 8 算法定位效果对比

Fig. 8 Comparison of algorithm positioning effects

在大多数情况下,本文算法均可以准确定位出货车车号区域,但是在某些情况下,也可能给出错误的检测结果。主要原因是货车运行条件复杂,部分车号标识由于字迹污染或模糊等原因导致能见度较低,在标注的时候也不能看清具体字符,因而并没有进行标注。然而,残存的货车标识往往表现出较强的车号标识特征,因而误被检测为铁路货车车号区域,如图 8(a)、(b)。

另外,本文还将改进 Faster R-CNN 方法与基于边缘检测算法^[3]、基于笔画宽度算法^[5]及基于 Faster R-CNN 算法^[14]进行对比,图 9 所示为 3 种算法在相同情况下的定位效果,可以看出,在一般情况下,3 种算法均可以正确定位出车号区域,但在车号模糊情况下,文献[3]算法未能完整定位出车号区域,且无法检测出小车号区域。文献[5]的检测结果中出现了许多错误的文本区域,文献[14]的方法可以正确定位出大车号区域,但无法正确定位出小车号区域,而本文算法可以正确定位出大、小车号区域,且定位效果更优于其他算法结果。




图 9 算法定位效果对比

Fig. 9 Comparison of algorithm positioning effects

4 结 论

本文针对现有算法无法正确定位小车号区域问题,结合铁路货车大、小车号区域占据比例小的特征,对 Faster R-CNN 的特征提取网络卷积核及连接方式进行改进。铁路货车车号的位置易受到车身结构的影响,车号区域比例容易发生变化,本文采用 k-means++ 算法计算出 3 种合适的车号长宽比,优化 anchor 设计,实验结果表明,优化后的建议候选框与铁路货车车号区域更为贴切。对每一组改进方法都设计了一组实验,实验结果证明了每组改进方法对提升车号区域的定位准确率的有效性。为提高网络的泛化能力,设计参数 dropout,结果表明,dropout=0.55 时,网络取得最佳的定位效果。

参考文献

[1] 施卫忠. 我国编组站自动化技术现状与发展[J]. 铁道通信信号,2018,54(3):1-5.
SHI W ZH. Present situation and development of marshalling station automation technology in China[J]. Railway Communication Signal,2018,54(3):1-5.
[2] 王震. 车号自动识别系统常见故障及处理[J]. 铁道技术监督,2011,39(2):25-28.



- WANG ZH. Common faults and treatment of train number automatic identification system [J]. Railway Technical Supervision, 2011, 39(2): 25-28.
- [3] 王俊晓. 基于 LabVIEW 的货车车号识别技术研究[D]. 石家庄: 石家庄铁道大学, 2015.
- WANG J X. Research on freight train number recognition technology based on LabVIEW [D]. Shijiazhuang: Shijiazhuang Railway University, 2015.
- [4] 廖健. 基于深度卷积神经网络的货车车号识别研究[J]. 交通运输工程与信息学报, 2016, 14(4): 64-69.
- LIAO J. Research on identification of freight train number based on deep convolution neural network [J]. Journal of Transportation Engineering and Information, 2016, 14(4): 64-69.
- [5] EPSHTEIN B, OFEK E, WEXLER Y. Detecting text in natural scenes with stroke width transform [C]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2010: 2963-2970.
- [6] 王欣蔚. 基于深度学习的 TEDS 系统车号识别算法研究[D]. 北京: 北方工业大学, 2016.
- WANG X W. Research on vehicle number recognition algorithm of TEDS system based on deep learning [D]. Beijing: North University of Technology, 2016.
- [7] 杨吉. 基于图像处理的高速列车车号识别算法研究[D]. 成都: 西南交通大学, 2012.
- YANG J. Research on recognition algorithm of high speed train number based on image processing [D]. Chengdu: Southwest Jiaotong University, 2012.
- [8] 方清. 基于深度学习的自然场景文本检测与识别[D]. 成都: 电子科技大学, 2018.
- FANG Q. Text detection and recognition of natural scene based on deep learning [D]. Chengdu: University of Electronic Science and Technology, 2018.
- [9] 刘正琼, 丁力, 凌琳, 等. 基于字符编码与卷积神经网络的汉字识别 [J]. 电子测量与仪器学报, 2020, 34(2): 143-149.
- LIU ZH Q, DING L, LIN L, et al. Chinese character recognition based on character coding and convolutional neural network [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(2): 143-149.
- [10] 孙哲, 张春龙, 葛鲁镇, 等. 基于 Faster R-CNN 的田间西兰花幼苗图像检测方法 [J]. 农业机械学报, 2019, 50(7): 216-221.
- SUN ZH, ZHANG CH L, GE L ZH, et al. Image inspection method of broccoli seedling in field based on Faster R-CNN [J]. Journal of agricultural machinery, 2019, 50(7): 216-221.
- [11] 张乐, 金秀, 傅雷扬, 等. 基于 Faster R-CNN 深度网络的油菜田间杂草识别方法 [J]. 激光与光电子学进展, 2020, 57(2): 304-312.
- ZHANG L, JING X, FU L Y, et al. Weed identification in rape field based on Faster R-CNN depth network [J]. Progress in laser and Optoelectronics, 2020, 57(2): 304-312.
- [12] 袁功霖, 侯静, 尹奎英. 基于迁移学习与图像增强的夜间航拍车辆识别方法 [J]. 计算机辅助设计与图形学学报, 2019, 31(3): 467-473.
- YUAN G L, HOU J, YIN K Y. Night aerial vehicle recognition method based on transfer learning and image enhancement [J]. Journal of Computer Aided Design and Graphics, 2019, 31(3): 467-473.
- [13] 陈泽, 叶学义, 钱丁炜, 等. 基于改进的 Faster R-CNN 小尺度行人检测 [J/OL]. 计算机工程: 1-8 [2020-05-21], <https://doi.org/10.19678/j.issn.1000-3428.0055817>.
- ZHEN Z, YE X Y, QIAN D W, et al. Small scale pedestrian detection based on improved Faster R-CNN [J/OL]. Computer Engineering: 1-8 [2020-05-21], <https://doi.org/10.19678/j.issn.1000-3428.0055817>.
- [14] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2015, 39(6): 1137-1149.
- [15] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich semantic segmentation [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580-587.
- [16] GIRSHICK R. Fast R-CNN [C]. IEEE Conference, 2015, DOI: 10.1109/ICCV.2015.169.
- [17] ZEILER M D, FERGUS R. Visualizing and understanding convolutional networks [C]. European Conference on Computer Vision, Springer International Publishing, 2013, DOI: 10.1007/978-3-319-10590-1-53.
- [18] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]. IEEE Conference on Computer Vision & Pattern Recognition, IEEE Computer Society, 2016: 770-778.
- [19] 吴晓凤, 张江鑫, 徐欣晨. 基于 Faster R-CNN 的手势识别算法 [J]. 计算机辅助设计与图形学学报, 2018, 30(3): 468-476.
- WU X F, ZHANG J X, XU X CH. Gesture recognition algorithm based on Faster R-CNN [J]. Journal of Computer Aided Design and Graphics, 2018, 30(3): 468-476.
- [20] 李祥鹏, 闵卫东, 韩清, 等. 基于深度学习的车牌定位和识别方法 [J]. 计算机辅助设计与图形学学报, 2019, 31(6): 979-987.
- LI X P, MIN W D, HAN Q, et al. License plate

location and recognition method based on deep learning[J]. Journal of Computer Aided Design and Graphics, 2019, 31(6):979-987.

[21] SRIVASTAVA N, HINTON G, K RIZHEVSKY A, et al. Dropout: A simple way to prevent neural networks from overfitting [J]. Journal of Machine Learning Research, 2014, 15(1):1929-1958.

作者简介



张晓丽,2018 年于兰州交通大学获得学士学位,现为兰州交通大学硕士研究生,主要研究方向为交通运输自动化、图像处理及铁路信号。

E-mail:bbnxkl11111@ 163. com

Zhang Xiaoli received her B. Sc. degree from Lanzhou Jiaotong University in 2018. Now she is a M. Sc. candidate at Lanzhou Jiaotong University. Her main research interests include railway signal, image processing and sensor applications.



董昱,1985 年于兰州交通大学获得学士学位,现为兰州交通大学教授,主要研究方向为轨道交通运输自动化。

E-mail:1761853586@ qq. com

Dong Yu received his B. Sc. degree from Lanzhou Jiaotong University in 1985. Now he is a professor at Lanzhou Jiaotong University. His main research direction is rail transit transportation automation.