

文章编号: 1671-251X(2024)S1-0082-06

基于卷积神经网络的矿用安全帽佩戴检测

韩忠利

(国能神东煤炭集团有限责任公司 机电管理部, 陕西 榆林 719315)

摘要:传统的安全帽佩戴检测方式存在浪费人力、环境适应性差等问题,同时,实际应用中的安全帽佩戴检测需结合人体检测来进行,只有检测出戴在头上的安全帽才算符合要求,因此,需要先找出监控图像或画面中煤矿工作人员的人脸位置,再根据人脸的位置识别出人脸上方的安全帽。提出了一种基于卷积神经网络的矿用安全帽佩戴检测模型:基于 Faster R-CNN 网络进行改进,将 VGG16 作为特征提取的主干网络;为了更好地对重叠目标进行检测,使用 Soft NMS 方法代替原本的 NMS 算法对冗余的候选框进行删除,构建了符合煤矿生产需求的安全帽佩戴检测模型。实验结果表明,提出的模型算法在平均检测精度上明显优于其他现有检测算法;在召回率方面,提出的模型算法比 Faster R-CNN 高出 3%,查全效果明显提高;与 Faster R-CNN 算法相比,模型运算速度提升了 23 帧/s。相较其他模型,提出的模型在检测精度、运算速度上均取得良好效果,满足煤矿智能化建设所要求的部署与应用要求。

关键词:安全帽检测;卷积神经网络;Faster R-CNN;煤矿安全;目标检测

中图分类号:TD67 文献标志码:A

Mining safety helmet wearing detection based on convolutional neural network

HAN Zhongli

(Electromechanical Management Department, CHN Energy Shendong Coal Group Co., Ltd.,
Yulin 719315, China)

0 引言

煤矿安全生产过程中,安全帽是生产人员的安全底线。实际生产中,由于安全意识薄弱和监管力度不足等原因,经常有工人未佩戴安全帽进入施工现场,造成很大的安全隐患^[1]。

为了加强对安全帽佩戴的管理,通过人工巡检的方式检查安全帽佩戴情况费时费力,且不能实现长时间监测;使用传感器对安全帽的佩戴情况进行识别和检测,只能在有限范围内发挥作用,在实际应用中效果不好^[2]。如何长期常态有效对人员佩戴安全帽进行识别,成为了重点研究方向,而计算机视觉技术的发展为其实现提供了可能^[3-4]。

贾峻苏等^[5]提出了基于块的局部二值模式直方图,使用支持向量机(Support Vector Machine, SVM)进行训练和检测,但有未得到充分利用的有效图像信息;Park 等^[6]提出基于 HOG(Histogram of Oriented Gradients)特征和 SVM 的安全帽佩戴检测方法,首先在捕获的视频帧中检测人体和安全

帽,再用几何和空间关系检测人体和安全帽之间的匹配,该方法需要满足站立条件才能进行有效检测。上述传统图像识别算法检测泛化能力较差,受到实际煤矿光线、距离、遮挡等的影响,识别能力有限。

随着深度学习研究的深入,卷积神经网络(Convolutional Neural Network, CNN)由于能够在大样本数据的特征进行自动学习、具有较强的泛化能力,因而被广泛应用于计算机视觉、自然语言处理等领域^[7]。区域卷积神经网络(Region-based Convolutional Neural Network, R-CNN)以卷积神经网络、线性回归等为基础,成功在目标检测领域引入了深度学习^[8]。而 Fast R-CNN(Fast Region-based Convolutional Neural Network)是截至目前 R-CNN 系列中最有里程碑意义的算法^[9],也是二阶段网络中最为经典的物体检测算法,可以有效实现特殊环境下的安全帽识别。

在目标检测方面,基于深度学习的检测方法大体上可分为 2 类:基于区域的目标检测和基于回归的目标检测。基于区域的目标检测方法主要有

收稿日期:2024-01-25;责任编辑:王晖。

作者简介:韩忠利(1983—),男,内蒙古西子王旗人,工程师,从事煤矿信息化、自动化、智能化的相关工作,E-mail:40531656@qq.com。

Fast R-CNN、Faster R-CNN^[10] 和 R-FCN^[11], 这类目标检测网络属于两步检测, 检测准确率高但速度慢。基于回归的目标检测方法有 YOLO (You Only Look Once)^[12]、SSD (Single Shot MultiBox Detector)^[13] 等, 这类网络属于一步检测器, 去掉了区域思想, 直接在一个网络中进行回归和分类, 速度快但检测精度较低。徐守坤等^[14]在 Faster R-CNN 的基础上引入在线困难样本挖掘和多层卷积特征融合技术, 提高了检测精度, 并且对有部分遮挡的目标和小尺寸目标有较高敏感度, 环境适应性更好; 李天宇等^[15]基于 YOLOv3 网络, 引入 CPANet 和 Clou 构建了一种高精度的安全帽检测算法 YOLO_CPANet_CIoU, 能够保证在复杂环境下对安全帽佩戴情况做出准确且实时的检测; 张春堂等^[16]设计了基于 SSD-MobileNet 的矿工安全帽检测方法; 李忠飞等^[17]设计了融合坐标注意力与多尺度特征的轻量级安全帽佩戴检测方法, 以 YOLOv4 模型为基础, 提出了一种融合坐标注意力与多尺度的轻量级模型 M-YOLO, 并将其用于安全帽佩戴检测。上述目标检测方法都是对基于回归的目标检测方法做了进一步的改进。

安全帽佩戴检测需结合人体检测来进行, 只有检测出戴在头上的安全帽才算符合要求, 因此, 需要找出监控图像或画面中煤矿工作人员的人脸位置, 再根据人脸的位置识别出人脸上方的安全帽。本文选取了目标检测领域性能良好的 Faster R-CNN 网络并对其进行改造, 构建符合煤矿生产需求的安全帽佩戴检测模型。

1 安全帽佩戴检测模型

安全帽佩戴检测模型如图 1 所示, 使用基础网络为 Faster R-CNN, 特征提取网络的主干网络为 VGG16 (Visual Geometry Group Network)。首先, 通过卷积计算层提取图像的特征图, 该特征图在整个网络中共享; 然后, 由区域候选框网络层 (Region Proposal Network, RPN) 对检测区域进行二分类和位置回归, 产生一系列候选区域; 再利用感兴趣区域池化层 (Region of Interest Pooling, RoI Pooling) 将候选区域池化为固定尺寸; 最后通过全连接层整合前面所提取的信息进行分类和边界框回归。

Faster R-CNN 网络属于两阶段检测算法, 第一阶段先找出图片中待检测目标的锚点矩形框 (对背景、待检测目标进行二分类), 第二阶段对锚点框内待检测目标进行分类。主要包括以下部分: 深度卷积神经网络层、区域候选框网络层、感兴趣区域池化层、分类和回归、非极大值抑制。




图 1 基于 Faster R-CNN 的安全帽佩戴检测模型架构

1.1 深度卷积神经网络层

深度卷积神经网络层由卷积层、激活函数层、池化层组成, 就本文所采用的 VGG16 而言, 该网络由 13 个卷积层、13 个激活函数层和 4 个池化层组成。卷积层的关键是卷积核, 它是一个矩阵, 常用尺寸为 3×3 , 卷积核按照既定步长与输入图像的矩阵进行一定的乘法运算可得到原始图像的特征图。激活函数层使用修正线性单元 (Rectified Linear Unit, ReLU) 激活函数^[18], 相较于非线性函数节省很多计算量, 而且在神经元激活值为负数的情况下, ReLU 函数会输出 0, 这样使网络具有稀疏性, 可以缓解过拟合问题。池化层用于将输入数据的维度进行约减, 同时使下一层的输入更精简, 便于网络更广泛地提取特征, 也可以在一定程度上避免过拟合。在卷积层中:

- 1) 所有的卷积层都是卷积核 = 3, 填充值 = 1, 滑动步伐 = 1;
- 2) 所有的池化层都是卷积核 = 2, 填充值 = 0, 滑动步伐 = 2。

其中, 填充值 = 1 表示在矩阵外围添加一圈 0, 填充值 = 0 即不添 0。每经过卷积层, 特征图的大小不会改变, 只进行卷积提取特征; 每经过 ReLU 层, 特征图的大小也不变, 只将其中为负值的像素点重置为 0; 经过池化层后, 特征图的宽高缩减为原来的一半。因此, 在通过卷积层后, 一个尺寸为 $M \times N$ 的图像会变为尺寸为 $(M/16) \times (N/16)$ 的特征图。该特征图被共享用于后续的区域候选框网络层和全连接层。

1.2 区域候选框网络层

区域候选框网络层以第 1 步中提取的特征图作为输入, 输出为一系列候选区域。它以一定大小的窗口遍历整个特征图, 窗口的中心点作为锚点。区域候选框网络层将所输入的数据映射为 1 个概率值和 4 个坐标值, 概率值表示锚点中有物体的概率, 通过 Softmax 判断锚点框属于前景或者后景, 4 个坐标值用于回归确定物体的位置。最后将二分类和回归的损失统一起来训练区域候选框网络, 得到精确的候选区域。

Faster R-CNN 算法中引入了 RPN^[19]用于检测框的生成,使检测效率得到很大提升。

RPN 的输入是经过卷积层后的特征图,输出是检测候选框图。如图 2 所示,在 RPN 中,分 2 条线对图像进行处理:上面使用 Softmax 函数对锚点分类判定前景和背景,这条线完成的是一个二分类;下面的线通过边界框回归(Bounding Box Regression)对锚点进行微调,以得到精确的生成候选区域;然后,生成候选区域层将 2 条线路综合起来进行目标定位。




图 2 RPN 线路

RPN 中一个非常关键的概念是锚点,锚点就是在图像上预设好的不同大小、不同长宽比的参照框。在 Faster R-CNN 算法中,将每个像素点对应的锚点个数预设为 9,9 个不同的锚点由 3 种尺寸 128×128 , 256×256 , 512×512 和 3 种长宽比 1:1, 1:2, 2:1 组合得到。遍历特征图之后,每一个点都对应 k 个锚点作为初始的检测框,如图 3 所示(k 默认为 9),之后通过边界框回归来修正检测框的位置。




图 3 每个像素点对应 k 个锚点框

边界框回归用于对候选检测框进行微调,使经过微调后的窗口更接近真实情况,实现更准确的定位。图 4 中,绿框代表正确佩戴安全帽的真实情况,红框代表初始的生成候选区域,但即使模型将红框识别为安全帽,也会因为检测框位置和大小不适当,而不能检测出是否佩戴了安全帽,于是本文通过边界框回归将初始生成候选区域(红框)映射到更接近真实框(绿框)的回归框(蓝框)。

最后,生成候选区域层综合二分类得到的含有目标的锚点和边界框回归的变换量,计算出准确的生成候选区域,传递给后续的感兴趣区域池化层。

1.3 RoI Pooling

RoI Pooling 收集输入的特征和候选区域,将这些信息整合后提取候选区域特征图,得到固定大小




图 4 边界框回归

的特征图,再传递给全连接层进行目标类别的判断。

对于传统的卷积神经网络,向训练好的网络输入图像时,其尺寸必须是固定值,VGG16 网络也需要满足这个要求。针对原始图像往往大小不一的情况,通常有 2 种解决方法:一是将图像进行剪切,二是拉伸或缩短图像。但这 2 种方法都不尽如人意,要么导致图像不完整,要么改变了其原本的比例,因此 Faster R-CNN 提出了感兴趣区域池化操作。

RoI 是从图像中找到的候选识别区域^[20],由 RPN 输出的候选框映射到特征图上得到,也即 RoI 是针对原始图像的候选区域,如图 5 所示。而 RoI Pooling 的作用就是将来自输入列表的每个候选区域归一化为固定尺寸的目标识别区域。归一化的实现方式如下:

- 1) 根据输入图像,将候选区域映射到特征图的对应位置;
- 2) 将映射后的区域划分为大小相等的部分(其数量等于输出维度),找到每一部分的最大值(最大池化操作);
- 3) 将找到的最大值保留并输出。

利用 RoI Pooling 可以显著加快训练和测试的速度,提高检测精度,并允许以端到端的方式训练模型。




图 5 将 RoI 映射到 VGG16 输出的特征图

1.4 分类和回归

利用 Softmax 计算生成候选区域的类别,同时使用边界框回归获得检测框最终的精确位置。

最后的分类部分通过 Fast R-CNN 预测检测框的类别和转换为目标框的平移缩放系数,要先将经过池化后的 RoI 从三维转换成一维,再传递给全连接层。利用已经获得的生成候选区域特征图,通过全连接与 Softmax 判定每个生成候选区域所属的

类别(是否正确佩戴安全帽);同时再次对生成候选区域进行边界框回归,获得更高精度的检测框。

图 6 中,红色的神经元代表该特征已被找到或激活,而同一层中的其他神经元没有找到帽的特征,或者是特征不明显,而全连接层会将这些被找到的特征进行整合,从而判断出该目标类别是帽的可能性最大。同样,关于安全帽佩戴的检测也是一样的原理。




图 6 全连接层分类

1.5 非极大值抑制

对于基于锚点类型的目标检测算法来说,由于事先不清楚目标的尺度大小以及具体位置,所以必须用重叠采样或滑动窗口等方式来穷举所有可能的目标。但这种做法会导致许多候选框指向同一目标物体,产生冗余,因此需要删除重复的候选框。

非极大值抑制(Non-Maximum Suppression, NMS)算法的思想是抑制非极大值的目标,从而找出局部极大值的目标,也就是去冗余、找最优^[21]。该算法的输入是上一步检测到的边界框(同一目标物体可能对应很多边界框,每个边界框都有自己的分类置信度),输出为最优的边界框,大致过程如下所述。

- 1) 对于一个候选框列表 B,找出其中置信度最高的边界框,记作 M;
- 2) 将 M 从候选框列表 B 中删除,再将删除的 M 添加到最后保留的列表 D 中;
- 3) 将列表 B 中所有的边界框与 M 计算交并比(Intersection over Union, IoU)^[22],删除 B 中所有 IoU 大于给定阈值(重复度过高)的边界框;
- 4) 重复上述步骤,直到遍历完所有的候选框,列表 D 中的框即为所需。

传统的 NMS 算法容易误删图片中的重叠目标,也就是说当检测框中本来就有重叠的目标时,NMS 算法也会直接进行删除。如图 7 所示,检测算法本来应该输出 2 个框,但当 2 个框的 IoU 大于设定的阈值时,NMS 算法就会删除置信度较低的绿框,导致只检测到了 1 个物体,影响检测效果。

针对该问题,本文在 Faster R-CNN 的基础上



图 7 非极大值抑制去除冗余候选框

加入改进的 NMS 算法,即 Soft NMS 算法。Soft NMS 算法在执行过程中不会直接删除 IoU 大于阈值的检测框,而是降低其原有的置信度得分。此外,Soft NMS 算法可以很方便地被引入到目标检测算法中,不需要重新训练模型,代码容易实现,计算量比较小,可以有效去除冗余检测框。

2 实验设计及评价指标

2.1 数据集

通过扩大训练数据量以及增加数据集的多样性、加入噪声等方法进行数据采集,包括有意识地未佩戴安全帽、依靠以及并肩行走等情况的数据。本文在实验验证过程中,采集到数据大小为 1 080×720 的数据集约 12 000 张图片,其中涉及到煤矿生产作业中人员的各种行为,包括弯腰、蹲下、正常直立、2—3 人成团、拥挤以及稀疏等情况。本文的数据集尽可能地覆盖到各种矿工行为,使检测模型具有更强的鲁棒性。

2.2 硬件设备

实验所用硬件设备要求采用 GPU 对数据集进行深度学习加速训练,实验环境所用操作系统为 Linux,显卡为 NVIDIA GTX 2080Ti GPU,采用 pyTorch1.10.0 的深度学习框架。

2.3 评价指标

在模型检测目标时,通常依据两框的重合情况,将最终的输入结果划分为以下 4 类情况:TP(真正例)、TN(真反例)、FP(假正例)、FN(假反例)。具体情况如图 8 所示。




图 8 检测框类型

使用训练之后的模型对输入图像进行测试时,会在可能有目标的位置对应给出其预测框,那么该框则为正例框。以此框与其类别下真实框进行 IoU 运算,若得出的数据大于其阈值(通常取值为 0.5),则这种正例框为 TP(真正例),反之,数据小于阈值,则为 FP(假正例)。反之,若在真实框中存在负

例框,那么该框称之为 FN(假反例),即漏检框。

在目标检测算法领域中,常常使用精确率、召回率作为模型重要衡量指标,精确率即查准率,可用来评估模型检测准确性,其定义为正确预测为正的占全部预测为正的的比例。召回率即查全率,可用来评估模型检测全面性,其定义为正确预测为正的占全部实际为正的的比例,精确度 P 、召回率 R 、平均检测精度 mAP 计算公式如下所示。

$$P = \frac{TP}{TP + FP} \tag{1}$$

$$R = \frac{TP}{TP + FN} \tag{2}$$

$$mAP = \frac{1}{N} \sum_{n=1}^N AP(n) \tag{3}$$

$$AP = \frac{\sum_{k=1}^m (P(k) \times r(k))}{|R(n)|} \tag{4}$$

3 实验

将原 Faster R-CNN 算法与改进后算法在相同硬件条件的实验平台下分别独立训练 200 轮,在训练结束之后观察两者的 $mAP@0.5$ 对比曲线,如图 9 所示。改进后模型为较粗的红色曲线,原模型则为较细的红色曲线,其中横轴为训练轮次,纵轴为平均精度均值。由图 9 可直观看出来,改进前后的模型在训练 100 轮之后逐渐趋于稳定,且均保持在较高数值的水平,训练效果乐观,都没有出现过拟合或欠拟合的状态。通过图 9 还得出改进后模型在平均精度均值方面对比原模型有了明显的提升,进一步说明改进方向的有效性,即改进后模型检测性能更优。




图 9 改进前后 $mAP@0.5$ 曲线对比

将本文算法与目前存在的主流检测算法 YOLOv3、YOLOv4-tiny、YOLOv5 s、YOLOX-S、SSD、Faster-RCNN 在相同硬件设备与数据集下进行对比实验,对比结果见表 1。

由表 1 可知,改进后模型算法的平均精度均值能够达到 94.62%,相对于目前主流检测算法 YOLOv3、YOLOv4-tiny、YOLOv5 s、YOLOX-S、SSD、Faster-RCNN 分别高出 11.26%,5.55%,

表 1 与当前主流检测算法对比结果

检测算法	mAP@0.5/%	R/%	FPS/(帧·s ⁻¹)
YOLOv3	83.36	78.41	16.1
YOLOv4-tiny	89.07	84.26	22.7
YOLOv5 s	90.92	86.79	29.4
YOLOX-S	90.05	85.13	24.4
SSD	73.82	68.57	9.6
Faster-RCNN	92.25	88.45	4.7
Ours	94.62	91.81	28.3

3.70%,4.57%,20.80%,2.37%,经过对比发现,就平均检测精度而言,改进后模型算法明显优于其他现有检测算法。在召回率方面,改进后模型算法比 Faster R-CNN 高出 3%左右,对比其他算法查全效果更为显著。与 Faster R-CNN 算法相比,运算速度提升了 23 帧/s,但对应检测精度得到较大的提升。综合来说,改进后模型算法在平均检测精度和运算速度上都取得了良好效果。本文方法检测效果如图 10 所示。




图 10 安全帽检测结果

4 结论

1) 为实现对施工现场人员的安全帽佩戴情况的自动检测,本文利用卷积神经网络构建安全帽佩戴检测模型,使用基础网络 Faster R-CNN,并将 VGG16 网络用来进行特征提取,并在 Faster R-CNN 的基础上加入 Soft NMS 算法,不需要重新训练模型,减少模型计算量,可以有效去除冗余检测框。

2) 经实验证明,深度卷积神经网络对于图像特征有很好的提取效果,在安全帽佩戴检测方面的发展前景很大,相较于一些传统的检测方法具有明显的优势。

3) 本文只应用了原始的 Faster R-CNN 算法进行研究,未进行有效的优化和改进,在未来的工作中,还需进一步对网络优化、检测速度和模型鲁棒性等问题展开研究。

参考文献:

[1] 杜青,杨仕教,郭钦鹏,等. 地下矿山作业人员佩戴安

全帽智能检测方法[J]. 工矿自动化, 2023, 49(7): 134-140.

[2] 王国法,杜毅博,任怀伟,等. 智能化煤矿顶层设计研究与实践[J]. 煤炭学报,2020,45(6):1909-1924.

[3] 王国法. 煤矿智能化最新技术进展与问题探讨[J]. 煤炭科学技术,2022,50(1):1-27.

[4] 程德强,寇旗旗,江鹤,等. 全矿井智能视频分析关键技术综述[J]. 工矿自动化,2023,49(11):1-21.

[5] 贾峻苏,鲍庆洁,唐慧明. 基于可变形部件模型的安全头盔佩戴检测[J]. 计算机应用研究,2016,33(3): 953-956.

[6] PARK M W,ELSAFTY N,ZHU Zhenhua. Hardhat-wearing detection for enhancing on-site safety of construction workers [J]. Journal of Construction Engineering and Management,2015,141(9). DOI:10. 1061/(ASCE)CO. 1943-7862. 0000974.

[7] GU Yuwan, WANG Yusheng, SHI Lin, et al. Automatic detection of safety helmet wearing based on head region location[J]. IET Image Processing, 2021,15(11):2441-2453.

[8] GIRSHICK R B,DONAHUE J,DARRELL T,et al. Rich feature hierarchies for accurate object detection and semantic segmentation [J]. CoRR, 2013, abs/ 1311. 2524.

[9] GIRSHICK R. Fast R-CNN[J]. Computer Science, 2015:1440-1448.

[10] REN Shaoqing, HE Kaiming, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence,2017,39 (6):1137-1149.

[11] DAI Jifeng,LI Yi, HE Kaiming, et al. R-FCN: object detection via region-based fully convolutional networks[J]. CoRR,2016,abs/1605. 06409.

[12] REDMON J,DIVVALA S,GIRSHICK R,et al. You Only Look Once: unified, real-time object detection [J]. CoRR,2015,abs/1506. 02640.

[13] 唐聪,凌永顺,郑科栋,等. 基于深度学习的多视窗 SSD 目标检测方法[J]. 红外与激光工程,2018, 47(1):302-310.

[14] 徐守坤,王雅如,顾玉宛. 基于改进区域卷积神经网络的安全帽佩戴检测[J]. 计算机工程与设计,2020, 41(5):1385-1389.

[15] 李天宇,李栋,陈明举,等. 一种高精度的卷积神经网络安全帽检测方法[J]. 液晶与显示,2021,36(7): 1018-1026.

[16] 张春堂,管利聪. 基于 SSD-MobileNet 的矿工安保护戴设备检测系统[J]. 工矿自动化,2019,45(6): 96-100.

[17] 李忠飞,冯仕咏,郭骏,等. 融合坐标注意力与多尺度特征的轻量级安全帽佩戴检测[J]. 工矿自动化, 2023,49(11):151-159.

[18] 刘赞. ReLU 激活函数下卷积神经网络的不同类型噪声增益研究[D]. 南京:南京邮电大学,2023.

[19] KONIG D, ADAM M, JARVERS C, et al. Fully convolutional region proposal networks for multispectral person detection[J]. IEEE, 2017. DOI: 10. 1109/CVPRW. 2017. 36.

[20] ROSARIO B L, WEISSFELD L A, LAYMON C M, et al. Inter-rater reliability of manual and automated region-of-interest delineation for PiB PET [J]. Neuroimage,2011,55(3):933-941.

[21] 赵云龙,田生祥,李岩,等. 基于注意力模型和 Soft-NMS 的输电线路小目标检测方法[J]. 电子科技大学学报,2023,52(6):906-914.

[22] REZATOFIGHI H, TSOI N, GWAK J Y, et al. Generalized intersection over union: a metric and a loss for bounding box regression[C]. 2019 IEEE/ CVF Conference on Computer Vision and Pattern Recognition, Los Angeles, 2019.

~~~~~

(上接第 56 页)

[14] 刘晨. 基于 DL-TDOA 的隧道内车辆实时定位系统研究[D]. 北京:北方工业大学,2022.

[15] 李名城,张博通,陈溢铭,等. 卷积增强循环神经网络在文本分类中的应用[J]. 咸阳师范学院学报,2021, 36(2):24-29.

[16] 王丽,涂冰花,王伟,等. 长短期记忆循环神经网络在自动语音识别中的应用[J]. 单片机与嵌入式系统应用,2023,23(10):49-52,56.

[17] 董于春. 基于循环神经网络和可形变卷积的视频超分方法[D]. 上海:华东师范大学,2022.

[18] 齐战硕,高彦东. 面向消除通信时延的车辆轨迹多步预测方法[J]. 计算机与现代化,2022(5):114-118.

[19] PARK S H, KIM B D, KANG C M, et al. Sequence-to-sequence prediction of vehicle trajectory via LSTM encoder-decoder architecture [C]. IEEE Intelligent Vehicles Symposium, 2018. DOI: 10. 1109/ IVS. 2018. 8500658.

[20] 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, 2017, 39 (6): 1137-1149.

[21] 单德兴. 快速定量装车站智能装车关键技术研究 [D]. 阜新:辽宁工程技术大学,2020.

[22] 汪怡然,阮欣培,李鹏舜,等. 铁路货车装载超限的无人机视觉检测技术[J]. 铁路计算机应用,2018,27 (7):80-84.