

# 基于深度学习的智能治超场景下 货车车型识别

张磊, 康进实, 杨劲涛

(甘肃航空旅信息科技有限公司, 兰州 730000)

**摘要:** 针对智能治超场景下超载车辆自动化检测的需求, 在 YOLOv5s 的基础上从数据、模型和算法 3 个方面提出了一种改进的货车车型识别算法; 在数据层面, 使用的数据增强模拟了现实中面对恶劣天气、图像噪声和数据损坏等复杂场景, 丰富了训练数据的多样性, 提高了模型在复杂场景下的鲁棒性; 在模型方面, 提出了一种新的注意力机制来综合考虑不同通道的重要性和编码特征的位置信息, 提高了模型的识别准确性; 在算法层面, 针对现有算法的不足, 提出了一种更通用的标准来判断货车与轮轴的隶属关系, 以适用更复杂的场景; 实验结果表明, 提出的改进模型对货车和轮轴的识别精度分别达到 99.34% 和 99.22%, 对货车车型识别的准确率为 98.71%; 与经典的 YOLOv5s 网络相比, 货车和轮轴的平均识别精度提高了 2.39%, 货车车型的识别准确率提高了 2.22%; 综上, 所提出的方法实现了对货车车型自动和准确的识别, 可以为智能治超场景下的货车车型识别提供理论支撑。

**关键词:** 智能治超; 深度学习; 目标检测; 车型识别; 注意力机制

## Type Recognition of Trucks Based on Deep Learning in Intelligent Overload Management Scenarios

ZHANG Lei, KANG Jinshi, YANG Jintao

(GHATG Information Technology Co., Ltd., Lanzhou 730000, China)

**Abstract:** In response to the automated detection demand of overloaded trucks in intelligent overload management scenarios, based on YOLOv5s, an improved method is proposed to recognize the truck type from three aspects of data, model, and algorithm. At the data level, the dataed data enhancely simulates complex scenarios such as facing severe bad weather conditions, image noise, and data damage in real life, which enriches the diversity of training data and improves the robustness of the model under complex scenarios. In terms of the model, a new attention mechanism is proposed to comprehensively consider the importance of different channels and the positional information of encoding features, which improves the recognition accuracy of the model. At the algorithmic level, in order to overcome the shortcomings of existing algorithms, a more general standard for determining the subordinate relationship between trucks and axles is proposed to be applied in more complex scenarios. The experimental results show that the proposed improved model achieves the recognition accuracy of 99.34% and 99.22% for trucks and axles, respectively, and the recognition accuracy of truck type is 98.71%. Compared with classic YOLOv5s networks, the average recognition accuracy of trucks and axles has increased by 2.39%, and the truck type recognition accuracy by 2.22%. In summary, the proposed method achieves automatic and accurate recognition of truck type, which can provide a theoretical support for truck type recognition in intelligent overload management scenarios.

**Keywords:** intelligent overload management; deep learning; object detection; vehicle type recognition; attention mechanism

## 0 引言

超限超载运输损坏公路路面、路基和桥梁, 对交通安全、国家道路、运输市场秩序等造成了极大危害。为加强对非法超限运输治理, 保障公路设施和人民生命财产安全, 发展与完善智能治超系统<sup>[1]</sup>具有重大的现实意义。

在智能治超场景下, 货车在高速出入口经过不停车称重检测, 摄像头拍摄货车侧方图输入给模型, 模型实时识

别出货车车型继而确定货车限重, 结合称重与限重来判断货车是否存在超载运输。因此, 货车车型的限重识别是智能治超中的重要技术环节。我国交通运输部根据货车车轴数量和联结方式, 确定了不同货车进入高速公路的重量限额, 表 1 展示了部分不同货车类型及其重量限制。但由于确定货车限重比较复杂, 目前的工作主要是由收费站工作人员在高速公路入口处人工完成, 存在识别速度慢, 识别

收稿日期:2023-05-30; 修回日期:2023-06-09。

基金项目:甘肃省科技计划资助(21YF11GA014)。

作者简介:张磊(1981-),男,硕士研究生,高级经济师。

引用格式:张磊,康进实,杨劲涛,等.基于深度学习的智能治超场景下货车车型识别[J].计算机测量与控制,2023,31(11):248-254,259.

结果不准确等问题。

表 1 货车类型和重量限制

货车	轮轴的数量	重量限度(吨)
	2 轴	18
	3 轴	25
	4 轴	31
	5 轴	42
	6 轴	49

为了实现车型识别的自动化, 传统进行车型识别的方法主要有地感线圈法<sup>[2]</sup>、激光红外线识别<sup>[3]</sup>以及动态压电检测法<sup>[4]</sup>。地感线圈法和动态压电检测法通过在路段下埋设电感线圈或压电开关, 不同类型的车辆经过产生不同的电感信号波形来区分不同的车型。这样的方法不容易区分相似车型, 在车速较快时准确率不高, 且安装成本高, 需要破坏路面, 不易维护。激光红外线识别通过在检测道路的旁边设立红外线发射装置和接收装置。发射装置发射红外线到车体, 接收装置接收从车体反射回去的光线, 根据车辆不同部位的反射信息不同来识别出不同的车型。这样的方法都存在施工复杂且维护成本较高等缺点。传统的识别方式已经无法满足信息化、智能化交通系统的建设需求了。

近年来, 机器学习以及计算机视觉技术的发展成功应用在了车型识别领域。刘卫东等<sup>[5]</sup>提出将机器视觉技术用于高速收费车型的判别。桑军等人<sup>[6]</sup>使用 Faster R-CNN 来实现实时的车型识别。贺甜<sup>[7]</sup>利用卷积神经网络对公路货车常见的九种车型进行了识别与分类。尽管这些方法能在一定程度上实现货车的分类, 但其依赖车辆外形特征进行车型识别, 未充分利用货车轴数作为货车车型判别的首要特征。Mo 等人<sup>[8]</sup>分析建立了轴数数量与位置分布和货车限重之间的关系, 提出了一种以改进的霍夫和聚类算法为核

心的圆检测方法来识别货车轮轴。张念等人<sup>[9]</sup>提出了一种改进的 YOLOv3 模型, 该模型首先对图像中货车及其轮轴的位置进行检测和识别分类, 然后, 提取轮轴预测框中心点位置及货车预测框位置, 最后, 通过计算轮轴中心点与货车预测框位置信息的相对关系来判定货车与轮轴的隶属关系, 进而由轮轴数实现货车车型识别。尽管这些方法对感兴趣目标识别的算法不同, 但由于进一步考虑了货车与轮轴的位置关系, 均实现了更精准的货车车型识别。

与上述工作不同, 本文从 3 个方面对货车车型识别模型提出改进。从数据方面, 考虑到现实中更加复杂的场景, 本文通过模拟恶劣天气、图像噪声和数据损坏来对原始数据进行增强, 丰富训练数据多样性, 从而提高模型在自然场景中的鲁棒性。从模型方面, 本文改进了现有 YOLOv5s 模型, 通过添加注意力机制来增强模型对位置信息的编码从而提高模型识别准确性。在货车与轮轴隶属关系判别算法方面, 本文提出了一种通用的判别算法能适用于更加丰富的场景, 弥补了现有算法的不足。

## 1 YOLOv5 网络模型结构分析

YOLO<sup>[10-12]</sup> (You Only Look Once) 以其高效、高精度、重量轻等优点成为目前最著名的目标检测算法之一, YOLOv5<sup>[13]</sup>作为 YOLO 的检测网络系列之一, 在实时目标检测任务中应用广泛。本文在 YOLOv5 的基础上进行改进, 用于货车及其车轴的实时识别。本文首先介绍了 YOLOv5 的网络结构。如图 1 所示, YOLOv5 的网络结构由输入、主干网络、颈部网络和预测四部分组成。

输入: 输入是对输入图像进行图像预处理的阶段。预处理包括数据增强、自适应图像缩放和锚框计算。YOLOv5 采用马赛克数据增强方法, 通过随机布局、裁剪和缩放, 将四幅图像拼接成一张新照片, 极大地丰富了检测内容。并且在批归一化计算中可以直接计算四幅图像的数据, 提高了训练效率。YOLOv5 将锚框计算嵌入到训练中, 在初始锚框上输出预测框, 然后与真值进行比较, 计算损失, 从而不断更新锚框尺寸, 自适应计算最优锚框值。

主干网络: 主干网络实现图像特征提取, 它包括 Focus、CBL、CSP1、CSP2 和 SPP 五个模块。Focus 的关键作用是对输入图像进行切片, 使特征图像变小, 减少层数和参数, 提高卷积运算速度。CBL 由卷积层 (Conv)、批量归一化层 (BN) 和激活函数 (Leaky ReLU) 组成。它的功能是对切片图像进行卷积、归一化和激活操作。CSP 网络有 CSP1 和 CSP2 两种结构, 在特征提取中使用了具有残差结构的 CSP 来优化网络中的梯度, 使得层与层反向传播时梯度值得到增强, 从而可以有效避免由于网络加深而导致的梯度消失。SPP 由 CBL 和 MaxPool 组成 SPP 模块最重要的功能是扩大感受野。SPP 使用不同大小的卷积核输入不同大小的特征图进行最大池化, 然后将不同的结果与没有池化操作的数据拼接, 使得输出的特征向量维数保持一致。

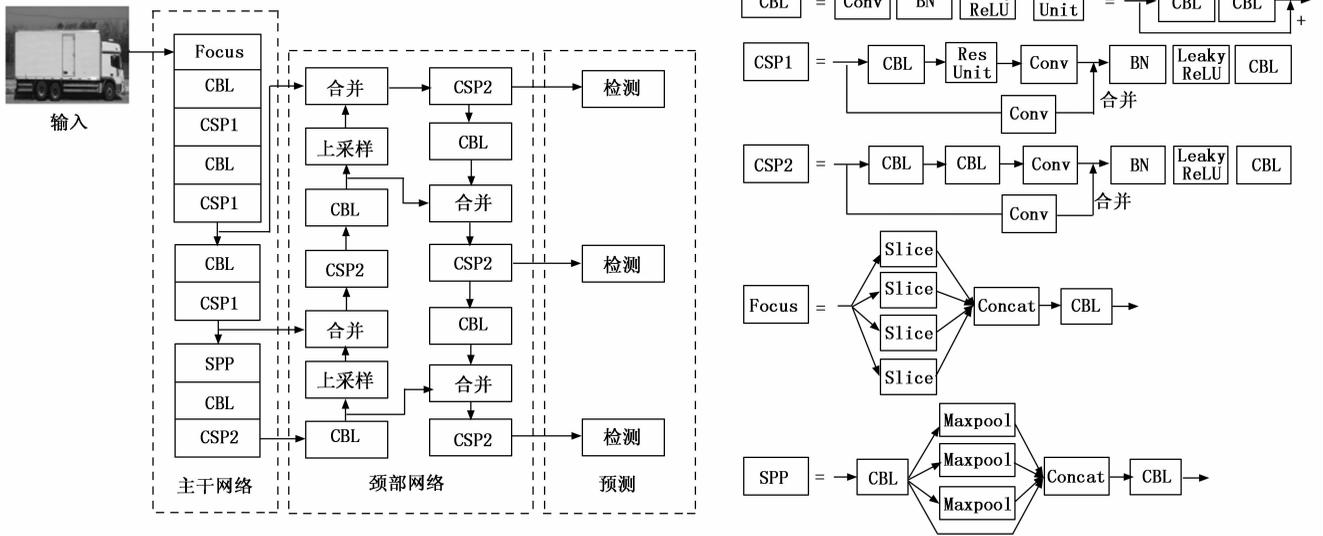


图 1 YOLOv5 网络结构

**颈部网络:** 颈部网络实现多尺度特征信息融合, 它采用特征金字塔网络 (FPN, feature pyramid network) 和金字塔注意力网络 (PAN, pyramid attention network) 的结构, 由若干自下而上的路径和若干自上而下的路径组成。FPN 自上而下对特征图进行上采样, 并将提取的特征与主干网络提取的特征融合。PAN 用于自下而上对特征图进行下采样, 提取的特征与 FPN 层提取的特征进行融合。通过 FPN + PAN, 可以聚合主干网络和检测网络提取的特征, 提高网络的特征融合能力。提取的特征通过 CSP2 模块进行融合。

**预测:** YOLOv5 考虑到边界框中心点的距离信息, 在 IOU<sup>[14]</sup> (intersection over union) 损失函数的基础上使用新的损失函数 CIOU<sup>[15]</sup> (complete intersection over union)。在此过程中还使用了 DIOU\_NMS<sup>[16]</sup> (distance intersection over union based non-maximum suppression) 来代替传统的 NMS 操作, 目的是更好地抑制冗余框, 从而进一步提高算法的检测精度。

## 2 改进的货车车型识别算法

### 2.1 复杂场景下的数据增强

在实际检测中常常遇到光线弱、雨雪天气等复杂场景<sup>[17]</sup>, 由于传统的识别算法容易受到上述复杂场景的影响, 因此, 无法满足真实场景的应用。一个简单有效的方式是尽可能使训练数据覆盖更多的场景, 然而对应复杂场景下的数据难以收集。为了克服这一局限性, 本文使用 ImageNet-C<sup>[18]</sup> 中的数据增强技术来模拟恶劣天气、图像噪声和数据损坏等复杂场景, 以增强数据集的多样性, 从而提高模型的鲁棒性<sup>[19]</sup>。

ImageNet-C 是评估视觉模型在损坏情况下的鲁棒性的一个众所周知的基准, 它总共包含 19 种数据增强, 分为四类即天气、模糊、噪声和数字 (如图 2 所示)。天气模拟恶

劣天气, 如雾, 雪, 霜和溅。模糊使用不同的技术平滑图像像素的强度, 如高斯, 玻璃, 运动, 散焦和变焦。噪声使用不同的函数随机扰动像素值, 如射击, 脉冲, 高斯和散斑。数字由修改图像分辨率 (即 JPEG 压缩, 像素化, 弹性) 或像素强度 (即饱和度, 亮度和对比度) 引起的各种数据损坏构成。本文在每一次迭代之前随机选择对原始数据进行增强, 以丰富数据的多样性, 提高模型的鲁棒性与泛化能力<sup>[20]</sup>。

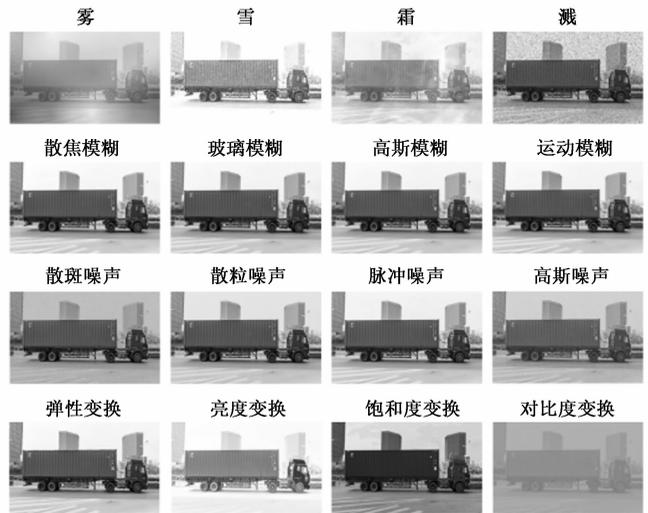


图 2 不同数据增强示例

### 2.2 改进的通道注意力机制 Local-SE

YOLOv5 颈部结构为 FPN + PAN 模型, 如图 3 所示。FPN 是一个自顶向下的特征金字塔, 通过上采样和卷积传递高级语义特征。但 FPN 只增强了语义信息, 没有传递位置信息。PAN 结构通过在 FPN 之后添加一个自底向上的特征金字塔很好地补偿了这一点。PAN 对 3 种不同尺寸的图

像分别使用 8 次、16 次和 32 次下采样和卷积来完成特征提取和转移, 在此过程中, 会丢失大量的位置信息, 使得模型在检测小目标时精度降低。

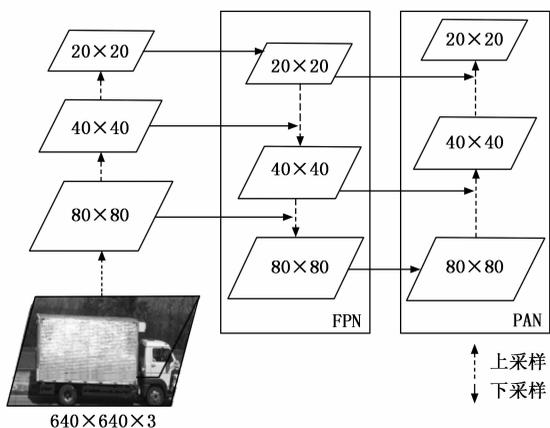


图 3 FPN+PAN 模型

近年来, 注意机制<sup>[21]</sup>被广泛用于提高现代深度神经网络的性能, 为了解决上述问题, 本文在通道注意力机制<sup>[22]</sup>(SE-Net Squeeze-and-Excitation Networks)的基础上引入了一种新的注意力机制。SE 模块关注通道之间的关系, 允许模型自动识别不同通道特征的重要性, 但忽略了位置信息。位置信息在捕获目标结构的视觉任务中非常重要, 而 PAN 会产生大量的通道和位置信息, 本文将位置信息嵌入到通道注意中, 形成一种新的注意机制 Local-SE。Local-SE 在 YOLOv5 中的实现如图 4 所示。它将被添加到 PAN 结构的下采样过程中。

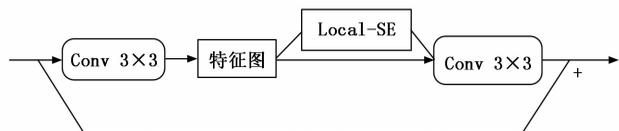


图 4 Local-SE 注意力机制

为了更好地解释 Local-SE, 首先简要介绍 SE 模块。标准卷积本身很难获得通道关系, 但这些通道关系信息对模型的最终分类决策具有重要意义。SE 模块通过使模型更多的关注最具信息量的通道特征并抑制不重要的通道特征来实现更好的特征提取。其工作原理是: 首先对卷积得到的特征图进行挤压得到通道的全局特征, 然后对全局特征进行激励, 学习各通道之间的关系, 得到各通道的权重, 最后与原始特征图相乘得到最终特征。给定输入  $f$ , 第  $c$  个通道的挤压方程如下:

$$z_c = G_{sq}(f_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W f_c(i, j) \quad (1)$$

其中:  $z_c$  是第  $c$  个通道的全局特征, 它是通过用特征编码通道上的整个空间而获得的。 $H$  和  $W$  分别表示特征图的高度和宽度。 $G_{sq}$  表示集合中特征映射压缩后的全局平均。

通过挤压得到特征的全局描述后, 需要通过激励操作得到通道之间的关系。传统的 SE 模块使用 sigmoid 形式的

门控机制:

$$s = F_{ex}(z, W) = \sigma(g(z, W)) = \sigma(W_2 \text{ReLU}(W_1 z)) \quad (2)$$

其中:  $F_{ex}$  表示激励操作,  $W_1$  和  $W_2$  表示两个线性变换, 每个通道的权值通过学习得到。 $\sigma$  为非线性激活函数, 它归一化以获得通道的重要性。

式 (1) 只压缩了全局空间信息, 没有保留位置信息, 本文提出的 Local-SE 旨在弥补这一缺失。将式 (1) 分解为垂直  $V$  和水平  $L$  的两个方向, 希望在不同方向对每个通道进行成对的一维特征编码。垂直方向高度为  $v$  的第  $c$  个通道的输出为:

$$z_c^v(v) = \frac{1}{L} \sum_{i=1}^L f_c(v, j) \quad (3)$$

同样, 水平方向上宽度为  $l$  的第  $c$  个通道的输出为:

$$z_c^l(l) = \frac{1}{V} \sum_{i=1}^V f_c(i, l) \quad (4)$$

式 (3) 和式 (4) 将沿着水平和垂直两个空间方向收集特征, 并将最终在相应的方向上生成一对感知特征图。与 SE 模块的不同之处在于, Local-SE 可以在一个空间方向上学习各个通道之间的关系权重, 同时在另一个空间方向上收集精确的位置信息。这种方法有助于 YOLOv5 更精确地定位感兴趣的目标。

为了充分利用收集到的位置信息, 本文提出了一种新的计算权重的方法。创建一个共享的  $1 \times 1$  卷积变换函数  $F$ , 由式 (3) 和式 (4) 生成的聚集特征的子集将被送到该函数中, 激励操作为:

$$f' = \sigma(F(z^v, z^l)) \quad (5)$$

其中:  $(z^v, z^l)$  表示聚合特征子集和非线性激活函数  $\sigma$  的串联操作,  $f'$  表示具有在两个不同方向上编码信息的中间特征图。相似的, 将  $f'$  沿水平和垂直方向拆分成两个单独的张量  $f'_v$  和  $f'_l$ 。因此有:

$$\omega^v = \sigma(F_v(f'_v)) \quad (6)$$

$$\omega^l = \sigma(F_l(f'_l)) \quad (7)$$

其中:  $F_v$  和  $F_l$  为两个  $1 \times 1$  的卷积操作,  $\sigma$  为 sigmoid 函数,  $\omega^v$  和  $\omega^l$  为不同通道的注意力权重。把得到的权重与原始特征图相乘, 得到最终的特征。Local-SE 模块输出特征  $X$  为:

$$x_c(i, j) = f_c(i, j) \times \omega_c^v(i) \times \omega_c^l(j) \quad (8)$$

综上所述, Local-SE 模块不仅考虑不同通道的重要性, 还关注编码的位置信息。本文将两个不同方向的注意同时应用到输入张量上, 得到的注意图可以确定对应的方向是否存储了感兴趣的目标。此外还可以在编码过程中调整注意力, 使感兴趣目标位置的定位更加准确, 从而提高模型的目标检测能力。

### 2.3 货车车型判断

货车车型的判断方法应当适应多种场景, 当一帧图像中仅包含单辆货车时 (如图 5 (a) 所示), 只需要对轮轴进行计数便可识别出单辆货车车型。当一帧图像中包含非完整的多辆货车时 (如图 5 (b) 所示), 需要先去除非法目

标,才能正确识别货车车型。当一帧图像中包含完整的多辆货车时(如图 5(c)所示),需要判断轮轴与不同货车之间的隶属关系才能进行正确识别。

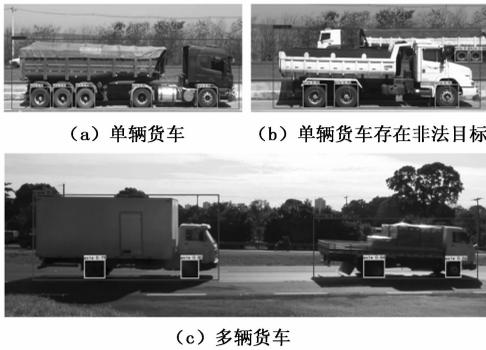


图 5 一帧图像中的不同情况

本文针对上述不同情况,提出了一种通用的基于目标位置信息的判别算法。该算法利用货车与轮轴的位置信息,通过分析轮轴与货车分布位置关系来判断货车与轮轴的隶属关系。

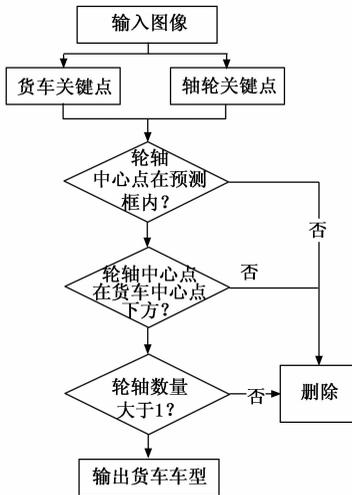


图 6 货车与轮轴隶属关系判定算法

货车与轮轴隶属关系判定算法流程如图 6 所示。首先,利用优化后的 YOLOv5 网络识别货车侧方图像,得到货车及轮轴的预测框坐标。在此基础上,提取轮轴预测框中心点位置信息和货车预测框边缘点信息,如果轮轴中心点落在边缘框内则记录进行下一步处理。然后,提取货车预测框中心点位置信息,计算货车预测框中心点与轮轴中心点的位置关系,根据轮轴位于货车中心点下方的先验知识判定货车与轮轴的隶属关系。最后,筛选出轮轴数量大于 1 的目标,得到货车类型的识别结果。

### 3 实验结果与分析

本文实验所使用的操作系统为 Ubuntu 20.04.5,处理器为 Intel-Xeon CPU E5-2630 v4,显卡为 Nvidia GeForce TITAN XP,编程语言为 Python 3.7.13,深度学习框架为

Pytorch 1.12.0。

#### 3.1 数据集与实验设置

本文使用的数据集为自主采集的货车车辆行驶数据图像及网络上收集的图像,共 3 000 张,如图 7(a)所示。其中,2 400 张用于训练,600 张用于测试。数据集使用 labeling 标注图像软件工具对原始图像数据集进行标注,如图 7(b)所示。



(a) 货车图像数据集



(b) 货车图像数据标注

图 7 数据集处理

所有实验均使用 YOLOv5s 模型,并加载在 COCO (Common Object Context) 数据集上训练好的模型作为预训练权重。模型总共训练 600 个世代,其中前 50 个世代固定模型的主干网络。设置批大小为 16,使用 Adam 优化器,初始学习率为 0.01。

#### 3.2 实验评估指标

实验采用的评估指标包括:精确率 (Precision)、召回率 (Recall)、平均精度 (AP, Average Precision) 和 F1 分数,具体定义如下:

$$Precision = TP / (TP + FP) \quad (9)$$

$$Recall = TP / (TP + FN) \quad (10)$$

$$AP = \frac{TP + TN}{TP + TN + FP + FN} \quad (11)$$

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (12)$$

其中: TP 为真实值是正样本,模型预测得出的结果为正样本, FN 为真实值是正样本,模型预测得出的结果为负样本, FP 是真实值为负样本,模型预测得出的结果为正样本, TN 是真实值为负样本,模型预测得出的结果为负样本。

#### 3.3 模型训练

完成数据集收集与标注之后,将提出的数据增强添加到数据预处理模块中,搭建基于 Local-SE 注意力机制的 YOLOv5s 模型。修改数据配置文件和模型配置文件,使用在 COCO 数据集上预训练好的模型来初始化模型参数,使

用经典 YOLOv5s 的损失函数, 设置好优化器参数。

完成上述设置后, 模型开始训练, 随着迭代次数的增加, 模型的每一次预测结果与标注结果进行比对, 计算损失利用梯度来更新模型参数。模型训练过程中训练集与验证集损失如图 8 所示, 识别平均准确率如图 9 所示, 经过 300 次迭代之后, 各项数值变化基本趋于平稳状态, 模型完成训练。训练结束后, 输入一张货车形式侧方位图片, 模型可以准确的识别出图片中货车和轮轴所在区域, 模型输出的形式为目标类别, 锚框的中心点坐标、锚框的宽高以及识别目标的置信度。根据模型输出, 送入到本文提出的货车与轮轴隶属关系的判别算法中, 即可得到最终货车车型识别结果。

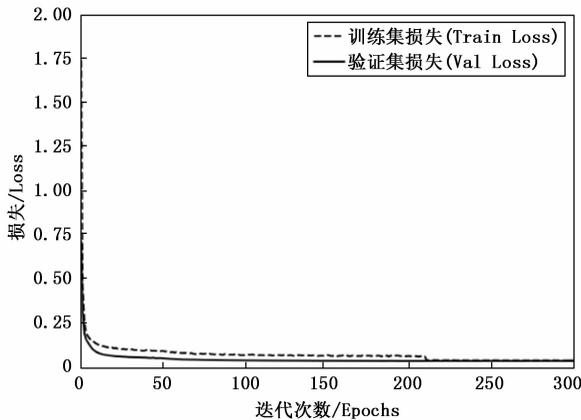


图 8 训练集及验证集损失曲线

### 3.4 实验结果分析

本文在添加数据增强和注意力机制的基础上对模型的

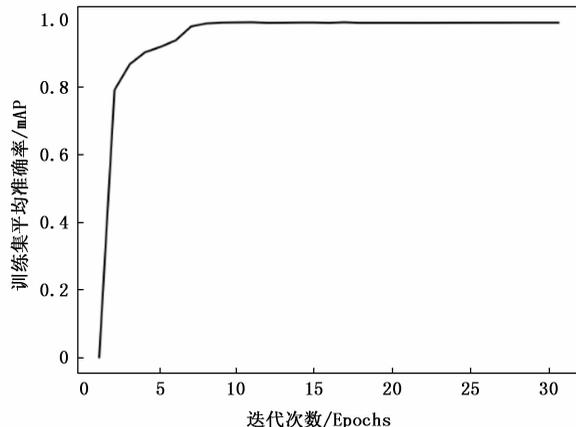


图 9 训练集平均准确率曲线

实验结果进行分析。图 10 展示了模型在不同分数阈值下货车和轮轴的精确率、召回率和 F1 分数, 实验结果选取的分数阈值为 0.5。货车车型识别在测试集上的表现如表 2 所示, 检测模型对货车和轮轴的识别精度分别达到了 99.34% 和 99.22%。通过判断轮轴与货车的隶属关系, 模型最终在测试集上对货车车型识别的准确率为 98.71%。总的来说, 该模型能够对货车车型及其轮轴进行较为准确的识别。

表 2 货车车型识别模型测试结果

评价指标	单位/%
货车识别准确率	99.34
轮轴识别准确率	99.22
类平均准确率	99.28
货车车型识别准确率	98.71

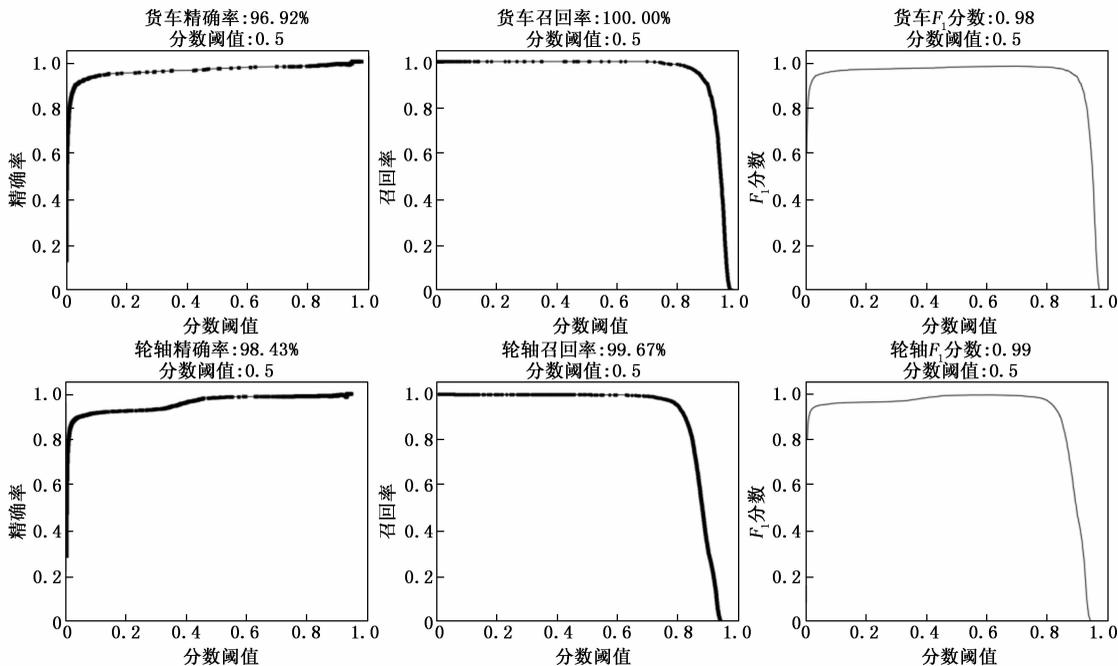


图 10 测试集各参数指标

表 3 展示了在 YOLOv5s 模型基础上添加数据增强和注意力机制对实验结果的影响。从表中可以看到, 添加数据增强和注意力机制都在不同程度上提高了模型对货车和轮轴的识别准确率, 从而提高了货车车型的识别准确率。数据增强是从训练数据层面扩展了训练域的覆盖范围, 在一些光照条件弱, 模糊的场景下提高了模型的识别能力。注意力机制的引入是在特征方面增强了模型对上下文信息的编码, 提高了模型对小目标的定位与识别能力。综上, 本文提出的两种方法在不同的层面上对模型的识别起到了促进作用。

表 3 货车车型识别模型消融实验

评价指标	YOLOv5s	+数据增强	+Local-SE
货车识别准确率/%	97.88	98.60	<b>99.34</b>
轮轴识别准确率/%	95.90	98.92	<b>99.22</b>
类平均准确率/%	96.89	98.76	<b>99.28</b>
货车车型识别准确率/%	96.49	97.92	<b>98.71</b>

为了更加直观地展示本文所提出模型的改进效果, 图 11 为部分改进前后模型预测结果对比。图 11 (a) 从左往右分别展示了 3 种经典 YOLOv5s 模型预测失败的示例: 左图由于轮轴分布密集, 光线强度弱, 数据集中对于 6 轴以上的货车侧方图片占比较少, 从而导致原始的模型预测失败; 中间图因为光照和轮轴形变的因素, 导致原始模型漏检; 右边图主要是光照因素导致模型仅定位了货车而未能检测出其对应轮轴位置。图 11 (b) 展示了改进后的模型对预测结果的改善, 由于数据增强的引入, 让模型对光照、噪声、模糊等因素的干扰具有了一定的鲁棒性, 此外注意力机制的加入也提高了模型对密集轮轴的预测的性能。

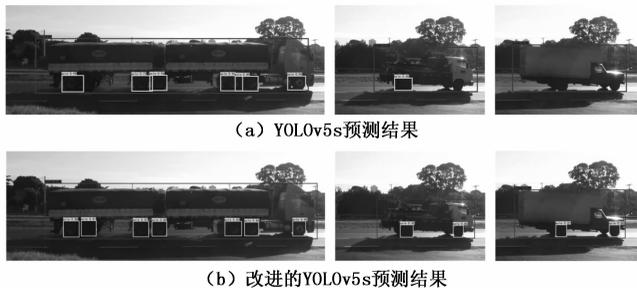


图 11 改进前后模型预测结果对比

总的来说, 从定量与定性结果上都展示出了所提出方法的有效性。优化后的模型对货车和轮轴的识别准确率高达 99%, 在此基础上使用本文提出的货车与轮轴隶属关系判定算法能够对货车车型进行准确的识别。本文提出的方法能帮助货车超载判断实现无人化、自动化, 对智能治超的应用具有一定的参考价值。

#### 4 结束语

针对智能治超场景下的货车车型识别问题, 本文从数据集处理、模型设计和货车车型判别算法 3 个方面提出改进。本文建立了货车侧方图像数据集, 并对图像进行数据

增强来模拟不同的复杂场景, 丰富了训练数据的多样性, 提高了模型的鲁棒性与泛化性。通过加入 Local-SE 这一注意力机制来优化 YOLOv5 网络加强了其对位置信息的编码能力, 提高了模型的检测精度。最后, 本文提出了一种通用的基于目标位置信息的判别算法来判定货车及其轮轴隶属关系, 弥补了现有判别算法的不足。总的来说, 本文提出的方法实现了对货车车型自动、快速和准确的识别, 为智能治超的应用提供了一定参考意义。

本研究存在的不足是数据集中货车图像主要为侧方位, 下一步研究需要扩充更多的数据样本, 甚至是更多的数据形式 (如: 视频数据, 三维点云数据等), 进一步提高货车车型识别模型的应用范围。

#### 参考文献:

- [1] 张晓枫. 面向道路的非现场智能治超系统设计与实现 [D]. 广州: 华南理工大学, 2021.
- [2] 王水波. 基于线圈感应信号匹配的车辆测速技术研究与应用 [D]. 西安: 长安大学, 2008.
- [3] 张晓娟, 邹存名. 基于激光传感技术的车位自动检测和定位研究 [J]. 激光杂志, 2020, 41 (11): 37-41.
- [4] KIM J, YOU K, CHOI H. Post-voltage-boost circuit-supported single-ended class-b amplifier for piezoelectric transducer applications [J]. Sensors, 2020, 20 (18): 5412.
- [5] 刘卫东, 魏周朝, 郭长全. 深度学习车型识别在联网收费系统中应用浅析 [J]. 中国交通信息化, 2016 (S1): 79-83.
- [6] 桑军, 郭沛, 项志立, 等. Faster-RCNN 的车型识别分析 [J]. 重庆大学学报, 2017, 40 (7): 32-36.
- [7] 贺甜. 基于神经网络的货车车型识别系统研究 [D]. 西安: 西安工业大学, 2019.
- [8] MO X, SUN C, LI D, et al. Research on the method of determining highway truck load limit based on image processing [J]. IEEE Access, 2020, 8: 205477-205486.
- [9] 张念, 张亮. 基于深度学习的公路货车车型识别 [J]. 交通运输工程学报, 2023, 23 (1): 267-279.
- [10] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection [C] // Proceedings of the IEEE conference on computer vision and pattern recognition. 2016: 779-788.
- [11] ALGHYALINE S. Real-time Jordanian license plate recognition using deep learning [J]. Journal of King Saud University-Computer and Information Sciences, 2022, 34 (6): 2601-2609.
- [12] FARHADI A, REDMON J. Yolov3: An incremental improvement [C] // Computer vision and pattern recognition. Berlin/Heidelberg, Germany: Springer, 2018, 1804: 1-6.
- [13] 杨文涛, 张维光. 基于改进 YOLOv5m 的弱小目标识别方法 [J]. 计算机测量与控制, 2022, 30 (12): 218-223.
- [14] YU J, JIANG Y, WANG Z, et al. Unitbox: An advanced object detection network [C] // Proceedings of the 24th ACM international conference on Multimedia. 2016: 516-520.

(下转第 259 页)