

文章编号: 2095-2163(2020)01-0137-07

中图分类号: U216.3

文献标志码: A

基于 YOLO 改进算法的轨道扣件状态检测研究

王兵水, 郑树彬, 李立明, 钟倩文

(上海工程技术大学 城市轨道交通学院, 上海 201620)

摘要: 扣件作为固定钢轨和轨枕的器件,其状态的好坏直接影响着行车的安全。然而,目前国内主要采用人工巡检的方式,该方式效率低下,漏检率高,检测结果严重依赖巡检人员的技术熟练程度并且由于巡检设备拍摄的扣件目标较小,图像中扣件与背景区分度小。现提出一种改进的 YOLO 算法来实现对轨道扣件状态的检测,其核心思想以 Darknet-53 为基础网络,采用多尺度特征检测,通过特征通道赋权重来改善传统 YOLO 中小目标特征信息丢失问题,并结合 K-means 对数据集目标框进行聚类分析,以提高检测速度与准确率。对部分样本图像进行增广扩充数据集,使得数据集样本分布更均衡。实验结果表明,改进后的 YOLO 能够快速准确地识别出扣件状态,查全率达到了 95.2%,平均精度值达到了 96.7%。

关键词: YOLO; 多尺度特征融合; K-means 聚类分析; 数据增广

Research on state detection of track fastener based on YOLO improved algorithm

WANG Bingshui, ZHENG Shubin, LI Liming, ZHONG Qianwen

(School of Urban Rail Transportation, Shanghai University of Engineering Science, Shanghai 201620, China)

[Abstract] Fasteners as devices for fixing rails and sleepers, have a direct impact on driving safety. However, at present, manual patrol inspection is mainly used in China, which is inefficient and has a high rate of missed detection. The detection results rely heavily on the technical proficiency of the patrol personnel. In addition, the tiny difference between the fastener and the background in the image is small because of the small target of the fastener taken by the patrol equipment. This paper presents an improved YOLO algorithm to detect the status of track fasteners. The core idea adopts multi-scale feature detection and assigns weights to feature channels to solve the problem of feature information loss of small and medium targets in traditional YOLO using Darknet-53 as the basic network and improve the detection speed and accuracy by doing Clustering Analysis of Data Set Target Box combining with K-means. Now, some sample images are augmented and expanded to make the sample distribution of the data set more balanced. The experimental results show that the improved YOLO can quickly and accurately identify the fastener status, and the recall rate reaches 95.2% while the average accuracy reaches 96.7%.

[Key words] YOLO; multi-scale feature fusion; K-means cluster analysis; data augmentation

0 引言

为了能够及时发现会严重影响列车行车安全的隐患,铁路部门需要定期地对铁路沿线进行相关巡查,其中重要的一项便是对轨道扣件进行检测。轨道扣件作为固定钢轨和轨枕的连接件,扣件状态的好坏直接影响着行车的安全。但目前国内主要采用人工巡检的方式,该方式存在的弊端是巡检效率低下,漏检率高并且检测结果与巡检人员技术熟练程度严重正相关。

随着近年来人工智能研究的日趋深入,作为其应用基础的图像检测技术也获得飞速发展。代表性成果主要有:通过对含有待检测目标的图像利用卷积神经网络提取目标特征并正确识别出目标的技术,例如人脸识别技术^[1],车牌识别技术等。然而,

目前主流的应用在目标检测方面的智能算法主要有两类。一类是基于区域的目标检测算法,主要有 Fast R-CNN^[2], Faster R-CNN^[3]等,该类算法虽有较高的检测精度,但是检测速度较慢。另一类是基于回归的目标检测算法,主要有 YOLO^[4], SSD^[5]等,该类算法的特点是采用端到端的检测,具有较快的检测速度。基于卷积神经网络的扣件检测算法具有广泛的应用前景和巨大的商业价值。

本文提出一种基于改进 YOLO 算法的扣件状态检测方法,通过对采集到的扣件图像进行预处理后输入到改进的 YOLO 网络中即可得到标注类别的输出结果,准确高效。本文改进了传统的 YOLO 网络,增加了 Darknet-53 基础网络。由于拍摄图像并非处于实验室环境下,图像中扣件与背景差异甚小,传

基金项目: 上海市地方院校建设项目(18030501300)。

作者简介: 王兵水(1994-),男,硕士研究生,主要研究方向:轨道智能检测研究;郑树彬(1979-),男,博士,教授,主要研究方向:轨道交通车辆/轨道设备状态检测技术与理论研究。

通讯作者: 王兵水 Email:wangbingshui01@163.com

收稿日期: 2019-08-04

统 YOLO 网络对此处理容易丢失特征信息,所以本文进行多尺度的特征融合并且针对不同特征通过赋予不同权重,则可保证特征信息得到充分可靠的呈现。最后仿真对比了在同一数据集下的传统 YOLO 与改进 YOLO 的训练结果对比性能。结果数据均显示,改进后的网络损失值相较之前收敛更快且更低,在检测速度与精度上都有明显提升。

1 传统 YOLO 算法

轨道扣件状态检测的传统的 YOLO 算法的核心思想是从现场通过线阵相机采集回来的扣件图片作为

网络的输入,制作对应的数据集后进行训练,并直接在输出层进行回归得到对应的扣件的位置和类别,实现端到端的训练与检测工作。对于基于传统的 YOLO 算法的扣件状态检测系统流程,拟做阐释解析如下。

(1)将线阵相机拍摄的轨道扣件照片尺寸标准化到 448×448 。

(2)将标准化后的照片作为 YOLO 多层网络结构的输入,在中间层进行卷积和池化操作。

(3)再经非极大值抑制优化,最终得到检测结果如图 1 所示。




图 1 传统 YOLO 算法的扣件状态检测流程

Fig. 1 Fastener status detection process of traditional YOLO algorithm

传统的 YOLO 算法检测机制是通过将目标检测转化为边框预测和对应类别的概率回归问题,从而实现了单个卷积神经网络直接从完整的图像预测边框和类别概率^[4]。考虑到整个检测过程只在同一尺度的轨道扣件特征图上进行,所以容易出现准确率较低的问题。在此基础上对传统 YOLO 算法进行改进,重点从回归尺度、特征权重并对数据集进行增广与聚类分析等方面做出改进,从而提高检测速度与准确性。

2 用于扣件状态识别的改进 YOLO 算法模型

2.1 网络结构的改进

在基于传统的 YOLO 网络的基础上以 Darknet-53 为辅助网络构建 YOLO 改进算法模型,其网络结构如图 2 所示,将扣件图像进行放缩为 608×608 的像素大小作为网络的输入,在 3 个不同尺度内通过

卷积的方式实现局部特征的提取。输出的 3 个不同大小的特征图 19×19 、 38×38 和 76×76 分别对应尺度 1、尺度 2 和尺度 3。其中,尺度 19×19 是在辅助基础网络之后通过增加一些卷积块再卷积输出检测框信息,尺度 38×38 是在尺度 1 的末尾之前的卷积基础上再引入新一轮卷积块并且进行上采样之后配合 Darknet-53 网络的前五层的输入共同以张量的形式进行最终的卷积输出检测框信息,此时尺度增加了 1 倍,同理尺度 76×76 输出检测框也增加了 1 倍。然后基于交互层输出的特征图进行类别和位置的回归判断。使用逻辑回归来预测每个 bounding boxes 的对象分数,每个 bounding box 与 ground truth 的匹配策略为 1:1,并且每个 bounding boxes 使用多标签分类法预测包含的类,避免标签重叠等问题,采用二元交叉熵进行类别预测来提高准确度^[6]。

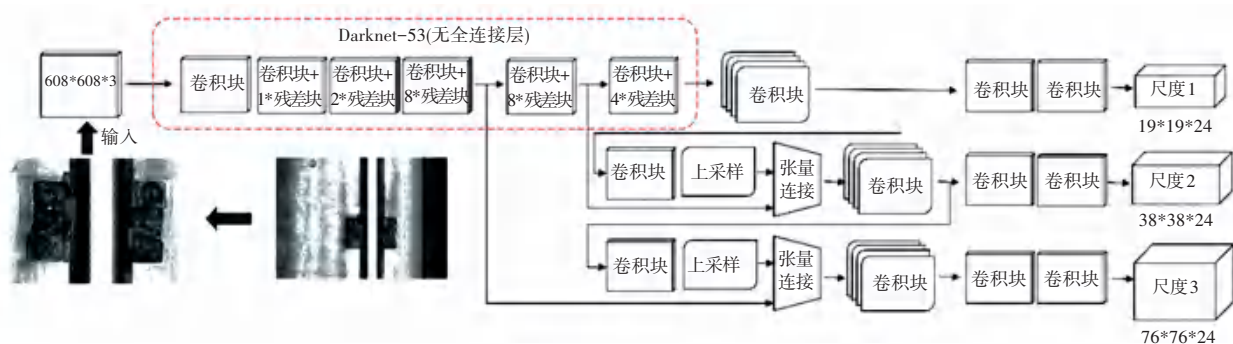


图 2 用于检测轨道扣件状态的改进 YOLO 算法框架

Fig. 2 Improved YOLO algorithm framework for detecting track fastener status

2.2 边框检测的优化

YOLO 算法将输入的轨道扣件照片进行分割为 $M \times M$ 块, 若某个物体的中心落入到某一个网格的内部, 则该网格就负责预测该物体。在算法进行训练和测试的时候, 每个格子将会预测 N 个检测边界框以及每个检测边界框对应的置信度。以上每个检测框都包含 5 个参数, 分别为物体中心位置的横坐标 x 、纵坐标 y 、置信度评分 C_{object} 、检测边框的高度 h 和宽度 w 。有效地降低了传统 YOLO 算法中采用固定检测边框尺度导致的扣件边界框回归错位的影响。但作为改进的 YOLO 算法, 不同之处在于是以 x 和 y 的偏移作为检测边框的长宽的线性表达式如式(1)–式(4)所示:

$$R_x = P_w t_x(P) + P_x, \quad (1)$$

$$R_y = P_h t_y(P) + P_y, \quad (2)$$

$$R_w = P_w e^{t_w(P)}, \quad (3)$$

$$R_h = P_h e^{t_h(P)}, \quad (4)$$

其中, R_x 、 R_y 、 R_w 、 R_h 是真实的在扣件特征图上的 4 个位置坐标的估计值; P_x 、 P_y 表示在特征图上的预设锚框的中心点坐标值; P_w 、 P_h 表示在特征图上的预设锚框的宽和高; t_x 、 t_y 、 t_w 、 t_h 代表网络学习目标。继而, 研究可得边框信息的横坐标、纵坐标, 宽和高的值求解公式如下:

$$b_x = \delta(t_x) + c_x, \quad (5)$$

$$b_y = \delta(t_y) + c_y, \quad (6)$$

$$b_w = p_w e^{t_w}, \quad (7)$$

$$b_h = p_h e^{t_h}, \quad (8)$$

其中, b_x 、 b_y 、 b_w 、 b_h 即为解得的边框的信息, 同样 t_x 、 t_y 、 t_w 、 t_h 表示网络学习目标, c_x 、 c_y 表示边框坐标的偏移量, 预设的锚边框的宽和高为 p_w 和 p_h 。在此基础上, 置信度和交并比的数学表达式如下:

$$C_{object} = P_{object} \times IOU_{pred}^{truth}, \quad (9)$$

$$IOU_{pred}^{truth} = \frac{\text{area}(BB_{dt} \cap BB_{gt})}{\text{area}(BB_{dt} \cup BB_{gt})}. \quad (10)$$

其中, P_{object} 表示目标存在单元格中的概率; IOU_{pred}^{truth} 表示当前边界检测框预测目标位置的准确度大小, $\text{area}()$ 代表面积; BB_{dt} 表示检测边界框, BB_{gt} 表示基于训练标签的参考标准框。

2.3 优化损失函数

传统 YOLO 算法只采用单一的均方和误差函数来作为损失函数, 其数学表达式如下:

$$Loss = \sum_{i=0}^{M^2} \text{CoordErr} + \text{IOUErr} + \text{ClassErr}, \quad (11)$$

综合考虑以上各损失的贡献率和在训练中的权

重, 改进的 YOLO 算法的损失函数如下:

$$\begin{aligned} N_Loss = & \lambda_{coord} \sum_{i=0}^{M^2} \sum_{j=0}^N V_{ij}^{object} [(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2] + \\ & \lambda_{coord} \sum_{i=0}^{M^2} \sum_{j=0}^N V_{ij}^{object} [(\sqrt{w_i} - \sqrt{\hat{w}_i})^2 + (\sqrt{h_i} - \sqrt{\hat{h}_i})^2] + \\ & \sum_{i=0}^{M^2} \sum_{j=0}^N V_{ij}^{object} (c_i - \hat{c}_i)^2 + \lambda_{noobject} \sum_{i=0}^{M^2} \sum_{j=0}^N V_{ij}^{object} (c_i - \hat{c}_i)^2 + \\ & \sum_{i=0}^{M^2} V_i^{object} \sum_{c \in \text{classes}} (p_i(c) - \hat{p}_i(c))^2. \end{aligned} \quad (12)$$

其中, V_i 表示网格 i 中是否有物体落入, 若有物体存在则 $V_i = 1$, 否则为 0; V_{ij}^{object} 表示第 i 个网格中第 j 个检测框中检测是否有物体落入, 若有则 $V_{ij}^{object} = 1$, 否则为 0; $\lambda_{noobject}$ 是检测框中没有发现物体时的损失权重; $V_{ij}^{noobject}$ 则与 V_{ij}^{object} 相反, 表示的是第 i 个网格中的第 j 个检测框中是否没有物体落入。

2.4 增加多尺度特征融合

为了使得特征提取得更加全面, 一般都采取增加网络的层数。但是随着网络的加深, 每一层都会丢失一些信息, 到最后一层就会丢掉比较多的信息。Liu 等人^[7] 在 European Conference on Computer Vision 会议上提出新的目标检测算法 SSD, 主要结合了 YOLO 的端到端的思想 and 一般卷积神经网络的候选框的思想, 从而引入了新的空间维度来融合不同尺度上特征信息, 并作为新的参数传给最后的预测层, 从而解决了网络层数的增加可能导致信息丢失的问题。

本文改进的 YOLO 算法模型正是结合该方法将多尺度特征融合进网络框架中, 并经过基础网络计算后再添加 4 个不同大小的卷积块。具体如图 3 所示。

通过在多个不同尺度的特征进行映射后, 能够更好地提取出扣件的特征, 还能更好地提取出图像中实际尺寸过大的目标物体, 提升定位的精度和预测的准确性。由图 5 可以看到在越大的感受野下, 网络对尺度较小的特征越不敏感^[8], 公式如下:

$$RF_{n+1} = RF_n + (k_n) \times \text{stride}_n + 1, \quad (13)$$

其中, $\text{stride}_n + 1$ 表示第 $n + 1$ 次的卷积移动的步长, RF_{n+1} 表示下一层的感受野大小。另外, 考虑到拍摄扣件照片时扣件在照片中位置分布的差异性, 就要在输入扣件照片时先进行标准化操作, 对应公式可表示为:

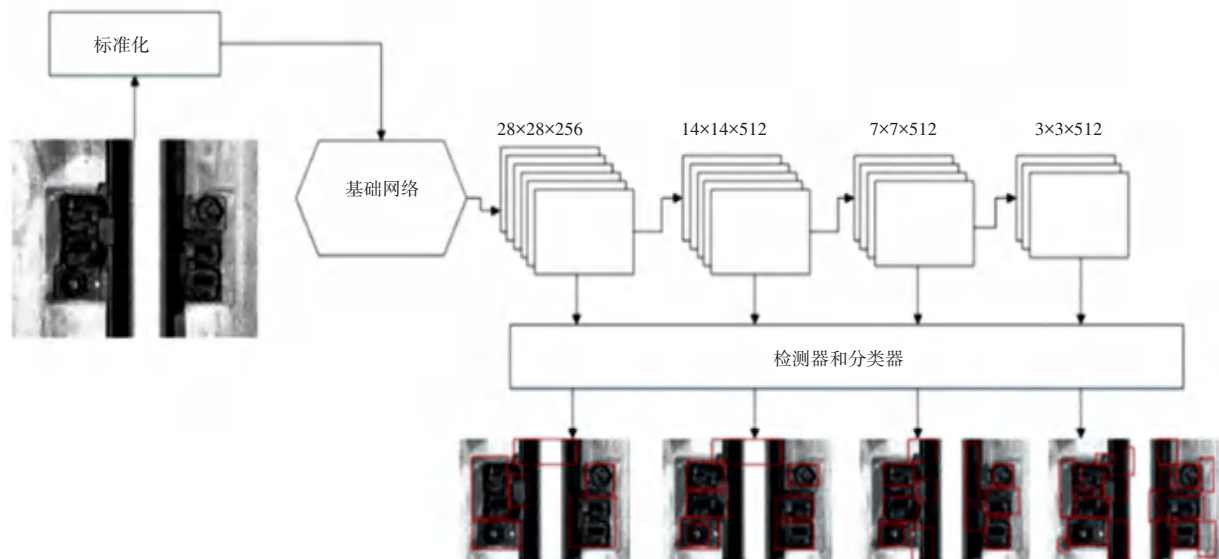


图3 多尺度特征融合效果图

Fig. 3 Multi-scale feature fusion effect diagram

$$x^k = \frac{x^k - E[x^k]}{\sqrt{\text{Var}[x^k]}}, \quad (14)$$

通过事先标定 $7 \times 7 \times 25$ 的特征维度作为第一回合的输出得到一个 $7 \times 7 \times 25$ 的张量之后,若在输出的目标信息检测中发现训练阶段设定的目标物体,则将此次张量送入下一轮并作为第二回合的输入,最终经过 2 次 $1 \times 1 \times k$ 的卷积层后再转入检测器和分类器判断阶段。分类器使用 softmax 回归函数得到的结果作为输出标定来对结果进行预测。研究可得数学公式为:

$$\sigma(z)_j = \frac{e^{z_j}}{\sum_{k=1}^k e^{z_k}}. \quad (15)$$

其中, z_j 表示上一层输出结果的预测值。

2.5 特征通道分权重

当传统 YOLO 网络的样本照片中扣件存在有遮挡物干扰或者掺杂有图像噪声时, YOLO 网络检测输出的置信度较高区域都将集中在特征图的边缘位置,从而出现检测置信度分布的不均衡。虽然已有学者提出通过提高空间的维度从而来提升网络的性能,但是一味地加深网络深度,不仅会让网络显得庞大,还会导致网络的计算速度明显下降。所以考虑从其它方面来提升网络的性能,为了保证网络学习到的是全局特征并且让置信度值在特征图中做到均衡分布,参考 Hu 等人^[9]提出的 SENet 思想,就是通过给不同特征通道赋予不同权重从而保证研究想要的有效的特征图获取较大占比的权重,效果差甚至

无效的特征图获取较小的权重占比。通过该方式可以直观显式地建立不同特征通道间的相互依赖关系,从而使模型训练达到更好的效果。这里,需用到如下数学公式:

$$u_c = v_c \times X = \sum_{s=1}^C v_c^s \times x^s, \quad (16)$$

其中, u_c 表示 C 经过标准卷积算子 Ftr 得到的结果, v_c 是网络用到的滤波器核心的第 c 通道的参数。

通道分权重的算法研发思路是将本层的特征作为下一卷积块的输入,再分两条路径传递给下一层,但其中有一条路径会进行 Squeeze 操作,其数学公式可写为:

$$Z_c = F_{sq}(u_c) = \frac{1}{W \times H} \sum_{i=1}^W \sum_{j=1}^H u_c(i, j), \quad (17)$$

这样一来,就可对上一层传递来的参数进行压缩,得到具有 n 维的特征向量,从而使其可以感受全局特征。

另一条路径则要进行 Excitation 操作,该操作类似于 LSTM 中的 gate 机制,旨在保证在经过卷积和激活函数计算后能够建立各通道间的相关性模型,同时为了让算法学习不同通道间的交互关系,减少通道间的互斥现象, gate 机制中的控制单元采用 Sigmoid 激活函数。控制单元数学表达式可写为:

$$s = \text{Fex}(z, W) = \sigma(W_2 \delta(W_1 z)). \quad (18)$$

其中, δ 表示 ReLU 函数^[10]。

考虑到本次训练数据集的量级可能会发生过拟合的情况,所以后期会对数据集进行增广操作,用来


提升数据集的大小以避免出现过拟合的现象。

3 扣件图像数据集预处理

3.1 扣件图像数据集的增广

本文所有扣件图像均来自课题组项目的实拍照

片,图像拍摄设备为线阵相机,扣件类型为潘得路扣件。起始数据集包含扣件图像 3 150 张,扣件图像有 a,b,c,d 四种状态,如图 4 所示。



(a) 无遮挡正常状态扣件 (b) 部分有遮挡的正常状态扣件 (c) 非正常状态扣件类别 1 (d) 非正常状态扣件类别 2
 (a) Unobstructed fastener in normal state (b) Partially occluded normal state fasteners (c) Unusual state fastener category 1 (d) Unusual state fastener category 2

图 4 数据集中扣件状态类别

Fig. 4 Fasteners status category in the data set

但在目标检测中将 (a) 和 (b) 统一归为正常状态扣件类,标注为“nm”,非正常状态的被标注为“um_1”与“um_2”两种。由于轨道扣件绝大部分都是处于正常状态的,只有很少一部分扣件出现损坏等非正常状态,所以扣件图像数据集存在严重的类别不平衡问题^[11]。

针对这一问题,需要增加非正常状态下的扣件图像数量。为此考虑应用图像数据增广的方法来达到这一目的。图像数据增广是通过对原始图像进行一系列无规则的处理,从而产生与原始图像相似,但又不是一样的新的图像来扩充数据集。如图 5 所示,对非正常状态扣件进行增广处理有翻转、翻转+偏移、翻转+缩放+偏移和缩放+偏移。在增广过程中产生的空白的区域,研究选择用 RGB 值均为 0 的黑色来对增广后空白区域作填充,使其可能对目标特征产生的影响降到最小。增广后的数据集由原来的 3 150 张扣件照片增加到 5 300 张。


3.2 数据集目标框的聚类分析

传统的 YOLO 网络对目标框的位置并不准确,源于网络没有事先对预测框位置做出一定的判断而是直接采取回归的方法。基于 Faster R-CNN 提出的锚的思想,YOLO 在此基础上进行改进,通过 K-means 聚类的方式对锚框的宽高进行聚类分析得到锚框集合。使用平均交并比作为聚类分析结果的量度,研究推得平均交并比的目标函数表达式如下:

$$\arg \max \frac{\sum_{i=1}^k \sum_{j=1}^{n_k} I_{IOU}(B, C)}{n} \quad (19)$$

其中, $I_{IOU}(B, C)$ 表示聚类的锚框与簇的中心框的交并比; B 表示检测框中的样本数; C 是簇的中心; n_k 表示第 k 个聚类中心的样本数; k 为簇的个数。

基于以上分析对轨道扣件图像数据集进行聚类运算,设定 $k = 9$ 得到平均交并比(Avg IOU)与 k 的关系图如图 6 所示。



(a) 原图像 (b) 增广处理后图像
 (a) Original images (b) Augmented processed image

图 5 非正常状态扣件图像增广处理

Fig. 5 Abnormal state fastener image augmentation




图 6 K-means 聚类分析结果

Fig. 6 K-means clustering analysis results

随着 k 的增加,目标函数的变化逐渐平稳,在 $k=6$ 时目标函数基本稳定不变,所以锚框数设为 6,既能有效减小检测框的误差,还能加快损失函数的收敛速度。对应预测框的大小设定为 6 个聚类中心,参数分别为 $(20, 17), (10, 20), (22, 9), (19, 13), (21, 14), (18, 11)$ 。

4 实验结果及分析

4.1 训练过程

本文实验平台配置为 Windows10 操作系统,显卡是 trx2080ti,CPU 是 i9 9900k,内存 16 GB,程序设计语言为 Python,使用了 Darknet 框架。训练集和测试集分别包含 4 200 张和 1 060 张扣件图像。

由于本文扣件图像均来自线阵相机拍摄,图像分辨率很高,研究中即统一将图像分辨率调为 608×608 作为网络输入分辨率。训练阶段基础学习率为 0.000 01,权重衰减 0.000 05,批量大小为 64,动量为 0.9。在该参数设置下,对比了传统 YOLO 与本文使

用的改进 YOLO 的训练过程中的损失值的变化,结果如图 7 所示。




图 7 损失值曲线图

Fig. 7 Loss value graph

由图 7 中可以看出,随着迭代次数的增加,两网络的损失值均迅速降低,但很明显改进 YOLO 的损失值收敛得更低、为 0.2 左右,但未改进过的损失值明显高于 0.5。因此从损失值上就可直接反映出改进 YOLO 算法的模型更加理想,检测准确性和速度更加符合实验要求。

4.2 测试结果与分析

当进行网络训练达 30 000 次左右时,损失值收敛到 0.2 左右且稳定,这时将测试集中的图像传送至训练好的网络中进行测试验证,选取部分测试结果截图如图 8 所示。

同样将该测试样本输入到未经改进过的网络中进行测试,得出的结果部分截图如图 9 所示。



(a) 截图 1

(b) 截图 2

(c) 截图 3

(d) 截图 4

(a) Screenshot 1

(b) Screenshot 2

(c) Screenshot 3

(d) Screenshot 4

图 8 改进 YOLO 算法检测结果部分截图

Fig. 8 Partial screenshot of the modified YOLO algorithm test results



(a) 截图 1

(b) 截图 2

(c) 截图 3

(d) 截图 4

(a) Screenshot 1

(b) Screenshot 2

(c) Screenshot 3

(d) Screenshot 4

图 9 传统 YOLO 算法检测结果部分截图

Fig. 9 Partial screenshot of the traditional YOLO algorithm test results

由测试结果可知,经过改进的网络识别准确度均获得较大提高,对于有遮挡的道岔区段的扣件识别准确度由 83% 提高到 98%;由图 8(b) 和图 9(b) 可以看出改进后的网络目标识别框的位置更加精准;由图 8(a) 和图 9(d) 可知数据集的增广使得网络对非正常状态的扣件识别准确度由 89% 提高到 96%。为了更好地观察改进前后的对比,对测试集的结果加以统计,其中涉及的主要参考指标为平均精度值(mAP),查全率和查准率^[12],对比结果见表 1。

表 1 性能参数对比

Tab. 1 Performance parameter comparison

	mAP	查准率/%	查全率/%
未改进 YOLO	93.1	94.2	85.1
改进后 YOLO	96.7	96.3	95.2

5 结束语

提出一种 YOLO 改进算法的扣件状态检测方法,通过对非正常状态扣件图像进行数据增广操作解决了原数据集类别不平衡问题,利用 K-means 聚类分析对检测框进行研究,提高了目标框位置的精度。由于所拍图像并非实验室环境下,图像中扣件与背景差异甚小,传统 YOLO 网络对此处理容易丢失特征信息,所以本文对多尺度的特征进行了有效融合,并且针对不同特征通过赋予不同权重,保证特征信息得到充分可靠的表现。最后通过实验仿真给出了在同一数据集下的传统 YOLO 与改进 YOLO 的训练结果对比。数据显示改进后的网络损失值相较之前收敛更快且更低,在检测速度与准确度上都有明显提升,其中查全率达到 95.2%,平均精度值达到 96.7。但是仍需指出,该模型都是基于静态图像处

理的结果,如何对动态扣件视频进行检测将是后续的主要研究方向。

参考文献

- [1] 陈翔,白创,黄跃俊. 基于 BP 神经网络的人脸识别系统研究[J]. 智能计算机与应用,2018,8(3):57-60.
- [2] REN Shaoqing, HE Kaiming, GIRSHICK R. Faster R-CNN: Towards real-time object detection with region proposal networks[C]//International Conference on Neural Information Processing Systems. Cambridge: MIT Press, 2015:91-99.
- [3] GIRSHICK R. Fast R-CNN[C]//Proceedings of 2015 IEEE International Conference on Computer Vision. Santiago: IEEE, 2015:1440-1448.
- [4] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]//Computer Vision and Pattern Recognition. Las Vegas, USA: IEEE, 2016: 779-788.
- [5] HE K, GKIOXARI G, DOLLAR P, et al. Mask R-CNN[C]//IEEE International Conference on Computer Vision and Pattern Recognition, Hawaii, USA: IEEE, 2017: 2980-2988.
- [6] REDMON J, FARHADI A. YOLOv3: An incremental improvement[J]. arXiv preprint arXiv: 1804.02767, 2018.
- [7] LIU W, ANGUOLOV D, ERHAN D, et al. SSD: Single shot multibox detector[J]. European Conference on Computer Vision. Amsterdam, The Netherlands: Adobe, et al, 2016: 21-37.
- [8] 郭继昌, 郭昊, 郭春乐. 多尺度卷积神经网络的单幅图像去雨方法[J]. 哈尔滨工业大学学报, 2018, 50(3): 185-191.
- [9] HU Jie, LI Shen, SAMUEL A, et al. Squeeze-and-excitation networks[J]. arXiv preprint arXiv: 1709.01507, 2017.
- [10] ZHOU Zhihua. Machine learning [M]. Beijing: Tsinghua University press, 2016.
- [11] KRAWCZYK B. Learning from imbalanced data: Open challenges and future directions[J]. Progress in Artificial Intelligence, 2016, 5(4): 221-232.
- [12] DOLLAR P, WOJEK C, SCHIELE B, et al. Pedestrian detection: A benchmark [C]//2009 IEEE Conference on Computer Vision and Pattern Recognition. Miami Beach, Florida: IEEE, 2009:304-311.

(上接第 136 页)

- [28] FANG Jian, XI Yugeng. A rolling horizon job shop rescheduling strategy in the dynamic environment [J]. The International Journal of Advanced Manufacturing Technology, 1997, 13(3): 227-232.
- [29] JAIN A K, ELMARAGHY H A. Production scheduling/rescheduling in flexible manufacturing [J]. International Journal of Production Research, 1997, 35(1): 281-309.
- [30] FILIP F G, NEAGU G, DONCIULESCU D A. Job shop scheduling optimization in real-time production control [J]. Computers in Industry, 1983, 4(4): 395-403.
- [31] LI Heng, LI Zhicheng, LI L X, et al. A production rescheduling expert simulation system [J]. European Journal of Operational Research, 2000, 124(2): 283-293.
- [32] UNAL A T, UZSOY R, KIRAN A S. Rescheduling on a single machine with part-type dependent setup times and deadlines[J]. Annals of Operational Research, 1997, 70:93-113.
- [33] PATRICK M, SANJA P, VÁZQUEZ - RODRÍGUEZ J A. Integrating rush orders into existent schedules for a complex job shop problem[J]. Applied Intelligence, 2010, 32(2): 205-215.
- [34] MATSUURA H, TSUBONE H, KANEZASHI M. Sequencing, dispatching and switching in a dynamic manufacturing environment [J]. International Journal of Production Research, 1993, 31(7): 1671-1688.
- [35] CESARET B, OGUZ C, SALMAN F S. A tabu search algorithm for order acceptance and scheduling[J]. Computers & Operations Research, 2012, 39(6): 1197-1205.
- [36] LIN S W, YING K C. Increasing the total net revenue for single machine order acceptance and scheduling problems using an artificial bee colony algorithm [J]. Journal of the Operational Research Society, 2013, 64(2): 293-311.
- [37] CHAURASIA S N, SINGH A. Hybrid evolutionary approaches for the single machine order acceptance and scheduling problem[J]. Applied Soft Computing, 2017, 52: 725-747.
- [38] 程虎彪, 苏春. 面向再制造的生产计划与调度研究综述[J]. 中国制造业信息化, 2008, 37(13): 13-16, 20.
- [39] 周荣辅, 王涛. 供应链生产计划研究综述[J]. 物流技术, 2014, 33(1): 270-273.