

文章编号: 2095-4980(2024)11-1221-07

基于改进 Faster R-CNN 的高铁扣件弹条缺陷检测

梁楠¹, 张伟^{*1}, 刘洋龙², 荆海林¹

(1. 河南省科学院 应用物理研究所有限公司, 河南 郑州 450000; 2. 重庆邮电大学 自动化学院, 重庆 400065)

摘要: 针对复杂光照环境导致的高铁扣件弹条缺陷检测困难问题, 提出一种基于改进 Faster R-CNN 的弹条缺陷检测方法。通过多层卷积神经网络提取缺陷特征图, 提高网络对缺陷特征的关注程度, 降低对复杂光照环境干扰的影响; 设计区域候选网络生成候选区域, 并根据候选区域进行池化, 在特征图中提取相对应的具体缺陷位置; 利用区域候选网络的全连接网络层计算获得缺陷的具体类别与精确位置, 得到最终的检测结果。所提算法可充分抑制光照环境干扰影响, 显著增强缺陷特征的代表能力; 简化了图像预处理环节, 降低了对原始图像成像质量的要求。实验结果表明, 所提算法能够实现对接扣件弹条缺陷的有效检测。与现有算法相比, 具有较高的精确度和较强的鲁棒性, 运算效率也得到显著提升。

关键词: 缺陷检测; 扣件弹条; 区域卷积神经网络; 区域候选网络; 图像噪声

中图分类号: TP273

文献标志码: A

doi: 10.11805/TKYDA2023253

Fastener clips defect detection based on improved Faster R-CNN in high-speed railway

LIANG Nan¹, ZHANG Wei^{*1}, LIU Yanglong², JING Hailin¹

(1. Institute of Applied Physics Co., Ltd, Henan Academy of Sciences, Zhengzhou Henan 450000, China;

2. College of Automation, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract: In response to the difficulty in detecting defects in high-speed rail clip springs caused by complex lighting environments, an improved Faster Region Convolutional Neural Networks(R-CNN)-based defect detection method for clip springs is proposed. By extracting defect feature maps through multi-layer convolutional neural networks, the network's attention to defect features is enhanced, and the impact of interference from complex lighting environments is reduced. A region proposal network is designed to generate candidate regions, and based on these regions, pooling is performed to extract the corresponding specific defect locations in the feature maps. The fully connected layers of the region proposal network are employed to calculate the specific categories and precise locations of defects, yielding the final detection results. The proposed algorithm can fully suppress the interference of lighting environments, significantly enhance the representation ability of defect features, simplify the image pre-processing stage, and reduce the requirements for the quality of the original image. Experimental results show that the proposed algorithm can effectively detect defects in high-speed rail clip springs, and compared to existing algorithms, it has a higher accuracy, stronger robustness, and significantly improved computational efficiency.

Keywords: defect detection; fastener spring clips; region-based convolutional neural networks; region proposal network; image noise

扣件是高铁的关键零部件, 其作用是将铁轨保持在固定位置。弹条是高铁扣件中最易失效的元件, 由于弹

收稿日期: 2023-09-08; 修回日期: 2024-01-04

基金项目: 河南省科学院科技开放合作基金资助项目(210907008); 河南省科技攻关基金资助项目(232102210056); 河南省科技研发计划联合基金资助项目(235200810049)

*通信作者: 张伟 email:KG08_13@163.com

条在高速列车载荷作用下具备振动特性,当钢轨波磨时,弹条的振动加速度将显著增大,尤其是蝶形弹条的振动模态与外部激励频率接近时,跟端圆弧处易产生疲劳断裂,严重影响行车安全性。因此,针对弹条的检测是高铁巡检中的关键环节,为确保行车安全,需高频率执行。但现有高铁的桥隧比普遍较高,采用传统的人工巡检成本高,效率低且存在人身安全问题。随着计算机视觉等领域的发展,高铁扣件的缺陷检测成为研究热点,得到研究机构的高度重视^[1]。正常的标准扣件结构特征完全固定,模板匹配等传统图像处理方法具备技术可行性,对于扣件丢失和明显的断裂具备较好的检测能力。随着扣件自动检测问题研究的不断深入,传统检测方法的缺陷也逐渐暴露。由于轨检车在运动状态下摄像机会发生振动,很难保证成像位置、成像角度的高度一致性,常规图像处理很难有效判别弹条是否存在微小形变,对微小裂痕的捕捉能力也相对较差。此外,受光照环境的影响,弹条可能呈现局部高亮特征,通过阈值分割的方法易将正常弹条误判为局部断裂,虚警率普遍较高。

上述问题是基于模板匹配的图像处理算法中普遍存在的问题。近年来,深度学习技术逐渐成为高铁扣件图像检测领域的研究热点。文献[2]采用高速激光测距相机,围绕像素和直方图相似性展开算法设计;文献[3]设计了扣件六角螺母中心定位方法提取扣件的轮廓特征;文献[4]采用单发多盒检测器模型,从捕获图像中定位扣件区域;文献[5]则采用先分割再定位的思想,通过分析扣件掩模的几何特征克服缺陷样本稀缺,设计级联缺陷检测网络实现扣件的高分辨力检测;文献[6]采用概率主题模型检测部分磨损和完全缺失的扣件;文献[7]考虑了扣件样本不平衡工况下的检测问题,提出由扣件定位和扣件检测组成的分层学习方法;文献[8]采用基于深度卷积神经网络的检测模型并结合样本生成方法提升对不平衡样品条件下的检测性能;文献[9]考虑到故障样本较少,设计多鉴别器循环一致对抗网络生成方法,使用大量无缺陷图像生成缺陷扣件图像;文献[10-13]设计了基于相似性的深度网络处理数据集不平衡问题。综上,现有研究的聚焦点在于故障样本少、定位算法效率低等方面,多采用理想化条件,未充分考虑光照环境干扰等复杂因素。

针对复杂光照环境导致的高铁扣件弹条缺陷检测困难的问题,本文提出一种基于改进 Faster R-CNN 的弹条缺陷检测方法。首先,通过多层卷积神经网络提取缺陷特征图,提高网络对缺陷特征的关注程度,降低对环境干扰和成像定位偏差的影响;然后,设计区域候选网络并生成候选区域,根据候选区域进行池化,在特征图中提取相对应的具体缺陷位置;最后,利用区域建议网络的全连接网络层计算获得缺陷的类别与精确位置,得到最终的检测结果。所提算法可充分抑制环境干扰影响,显著增强缺陷特征的特征能力,简化了图像预处理环节,降低了对原始图像成像质量的要求。

1 区域候选网络设计

1.1 特征提取网络设计

设计区域候选网络增强算法的鲁棒性。区域候选网络优势在于可接受任意尺寸大小的图像,将其经过多层卷积神经网络并得到特征图,然后输出图像中缺陷的候选框以及对应的置信度。为避免传统全连接结构的卷积神经网络因反馈信号微弱导致的梯度消失问题,采用残差网络替换 Faster R-CNN 模型中的全连接卷积神经网络,将上游网络层的输出张量直接与下游网络层的输出张量相加,形成残差连接。其优势在于很大程度上避免了网络层特征提取环节中的信息丢失现象。残差连接的示意图如图 1。

模型的特征提取采用 ResNet50 网络,其网络结构见图 2。首先,对输入图像数据进行零填充,然后经过 5 个阶段进行特征提取获得特征图。阶段 1 由卷积层、批量标准化、ReLU 激活函数和最大池化层组成;阶段 2~阶段 5 均采用残差连接网络,主要由卷积块和恒等块组成,它们之间的差别在于使用不同次数的恒等块网络。卷积块与恒等块的差别在于:残差连接时,恒等块将上游网络层的输出直接与下游网络层相加;卷积块需要将上游网络层的输出经过一次卷积操作并进行批量标准化后,再与下游网络层相加。阶段 5 的输出为特征图像。

1.2 区域候选网络设计

获得特征图后,需在特征图的滑动窗口确定检测目标缺陷的位置与对应的概率值。特征图被输入至 2 个全连接网络层中,其中 1 个卷积网络层用于目标框位置的回归,另 1 个卷积网络层用于目标框分类。目标框的位置由每个滑动窗口中具有不同尺寸和比例的先验框产生的偏移量决定,偏移量的主要参数包括框的中心坐标、长宽缩放比例以及先验框的位置坐标。

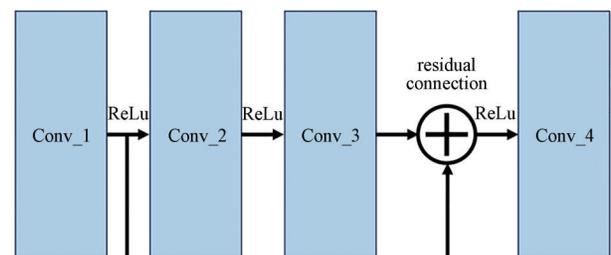


Fig.1 Schematic of residual connection
图 1 残差连接示意图

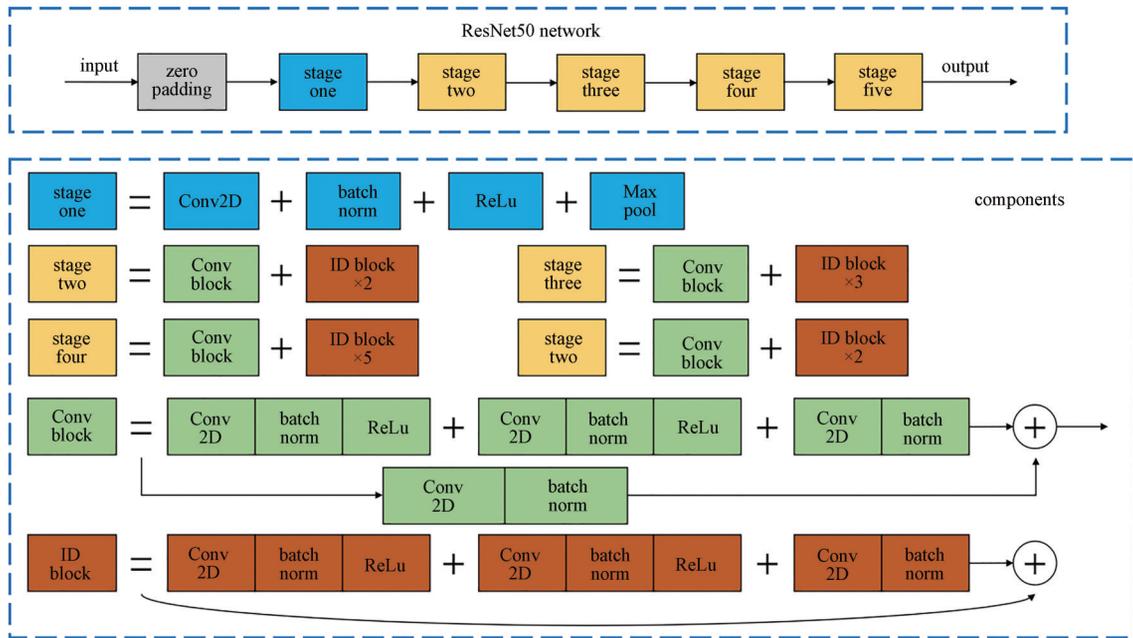


Fig.2 The structure of the ResNet50 network
图2 ResNet50网络结构

根据偏移量计算得到预测框：

$$\begin{cases} G_x = P_x + D_x P_w \\ G_y = P_y + D_y P_h \\ G_w = P_w e^{D_w} \\ G_h = P_h e^{D_h} \end{cases} \quad (1)$$

式中： G_x 、 G_y 为修正后的目标框的中心坐标； G_w 、 G_h 分别为修正后的目标框的宽和高； P_x 、 P_y 为原始先验框的中心坐标； P_w 、 P_h 分别为原始先验框的宽度和高度； D_x 、 D_y 为中心坐标的偏移量； D_w 、 D_h 分别为宽和高的偏移量。预测框计算示意图见图3。

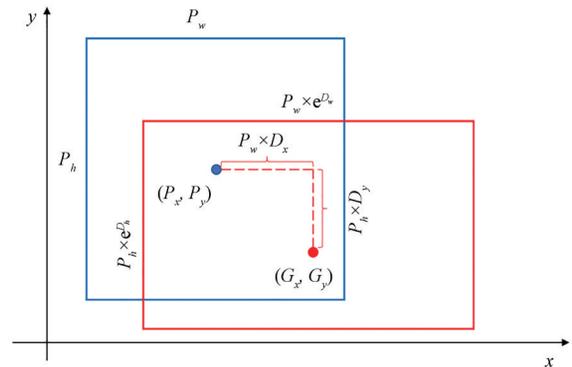


Fig.3 Schematic of prediction box calculation
图3 预测框计算示意图

为使预测网络尽可能覆盖扣件图像中的典型缺陷目标，需定义不同尺寸的先验框。考虑典型的缺陷为弹条丢失、弹条断裂、弹条扭曲形变，相应的缺陷目标尺寸较大，而弹条裂纹的尺寸可能较小，为此所设计的特征图中每个滑动窗口采用3类不同尺度(128^2 、 256^2 和 512^2)和3种不同比例(1:1、1:2和2:1)的先验框。针对每类尺寸，均采用3种不同比例变换，因此，每个滑动窗口共包含9类先验框。在分别经过分类卷积层和回归卷积层后，得到每个先验框对应的置信度和偏移量。区域候选框的生成见图4。

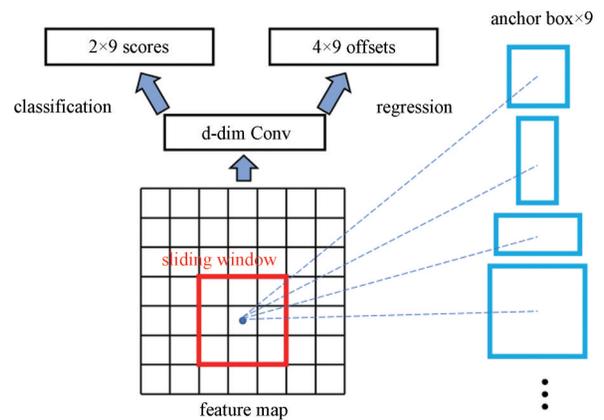


Fig.4 Generation schematic diagram of region candidate box
图4 区域候选框的生成示意图

在得到网络输出分类层的置信度和回归层的偏移量后，便可获取建议候选框。根据偏移量对每个原始先验框进行修正，按照置信度将所有候选框由大到小进行排序，排除掉置信度较低的候选框。当滑动窗口位于特征图的边缘时，部分候选框会超出特征图的范围，因此需要进行边界处理，即将超出边界的候选框收拢至特征图内。考虑如弹条断裂等较大的缺陷目标，其特征可能会出现在多个窗口内，故允许同1个缺陷目标产生较多的区域候选框，这需要对所有的候选框进行非极大值抑制，根据候选框之间的交并比(Intersection over Union, IoU)淘汰多余的候选框，其算式为：

$$IoU = \frac{A \cap B}{A \cup B} \tag{2}$$

式中： A 和 B 分别为候选框与目标框； IoU 在 0 和 1 之间，值越大，表示重叠度越高。

使用非极大值抑制时，首先，将所有的候选框按照对应的置信度进行排序，选择出当前排序下具有最高置信度的候选框作为目标框；其次，遍历同类别的其余所有候选框，如果当前交并比大于一定阈值，则认定当前候选框与目标框中所识别的缺陷是相同的，可将当前候选框删除；最后，继续从未处理的候选框中选择具有最高置信度的候选框，重复上述过程，直到处理完毕。该方法的缺陷在于，选择具有最高置信度的候选框时可能遗漏掉一些置信度并非最高但包含最大特征的候选框。因此，本文采用非极大值加权抑制算法，通过一种加权方法来获取最终输出的候选框，具体描述为：

$$\begin{cases} B = \sum_i^n w_i \times F_i / \sum_i^n w_i \\ w_i = C_i \times IoU(F_i, F_{\arg \max C_i}) \end{cases} \tag{3}$$

式中： B 为输出的候选框； w_i 为每个候选框的权值； F_i 为模型预测的所有候选框的集合； C_i 为每一个候选框的置信度； n 为候选框的数量。

至此，区域候选网络将输出所有可能含有缺陷目标的候选框的左上角和右下角坐标。

2 ROI 池化层设计

为避免破坏扣件弹条图像信息的完整性及尺寸范围，采用感兴趣区(Region of Interest, ROI)池化层结构，见图 5。ROI 池化层的输入为特征提取网络输出的特征图，以及区域候选网络输出的候选框坐标。将区域候选网络产生的候选框坐标映射到特征图中对应的区域上，考虑到实际扣件特征候选框的尺寸不一致，映射到特征图上的尺寸也有差异。因此将映射后的 ROI 区域划分为相同大小的块，在每个块上进行最大池化操作，将不同尺寸的 ROI 区域调整到固定尺寸。图 5 给出 2 个候选框在特征图上的映射，将其区域划分为 7×7 的块，并对每个块进行最大池化操作，最终得到长度为 49 的向量。所设计池化层的优势在于，保证了固定长度的输出，便于后续进行故障分类。

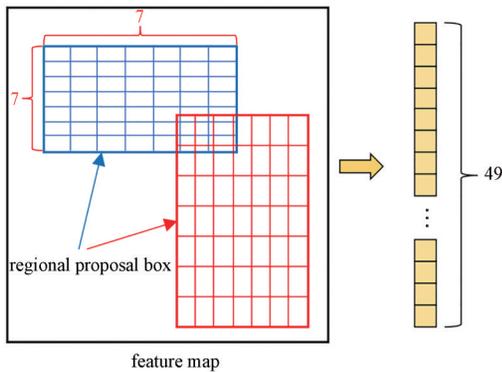


Fig.5 Structure of ROI pooling layer
图 5 ROI 池化层结构

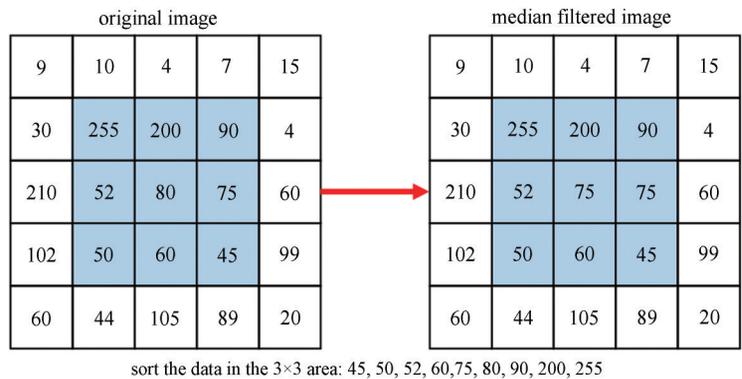


Fig.6 Schematic of median filter
图 6 中值滤波示意图

3 检测模型设计

3.1 图像预处理

考虑巡检车的运动特性及复杂光照环境下的成像质量问题。在数据采集端对原始图像进行中值滤波，消除原始图像中存在的椒盐噪声。设计滑动窗口并对所有灰度值进行统计排序，取排序后的像素序列的中值作为滤波器的响应输出，见图 6。

图像经过中值滤波后，高频噪声可得到有效抑制，但也会产生一定程度的模糊。为实现更好的滤波效果，还需对背景进行模糊化处理，同时需保留图像中的边缘信息，因此需对图像采用双边滤波。双边滤波器的输出像素值依赖于邻域像素值的加权组合：

$$g(i, j) = \frac{\sum_{k, l} f(k, l) w(i, j, k, l)}{\sum_{k, l} w(i, j, k, l)} \quad (4)$$

式中： (k, l) 为位于 (i, j) 像素点的邻域像素点； $w(i, j, k, l)$ 为权重系数，其值取决于定义域核和值域核的乘积：

$$w(i, j, k, l) = d(i, j, k, l) r(i, j, k, l) \quad (5)$$

$$d(i, j, k, l) = \exp \left[- (i - k)^2 + \frac{(j - l)^2}{2\sigma_d^2} \right] \quad (6)$$

$$r(i, j, k, l) = \exp \left[- \frac{\|f(i, j) - f(k, l)\|^2}{2\sigma_r^2} \right] \quad (7)$$

3.2 网络模型设计

综上所述，本文所设计的扣件弹条故障检测网络模型见图 7。将预处理后的图像输入到 ResNet50 网络中进行特征提取并得到特征图，经过 3×3 的卷积后分别被输入到分类网络和回归网络中。回归网络基于先验框计算偏移量得到候选框；分类网络计算候选框所属类别的概率。上述过程也可表示为在特征图上滑动一个窗口，分别输出候选框和对应的类别。同时，实际工况下得到候选框的数量是非常巨大的，必然存在相同的缺陷目标重复检测，采用非极大值抑制方法，删除多余的候选框。然后，将每个候选框映射到特征图中进行 ROI 最大池化操作，池化后的结果通过全连接层和 Softmax 环节对所有候选框进行类别判定，并再次对候选框进行修正，以获取更高精确度的预测框。

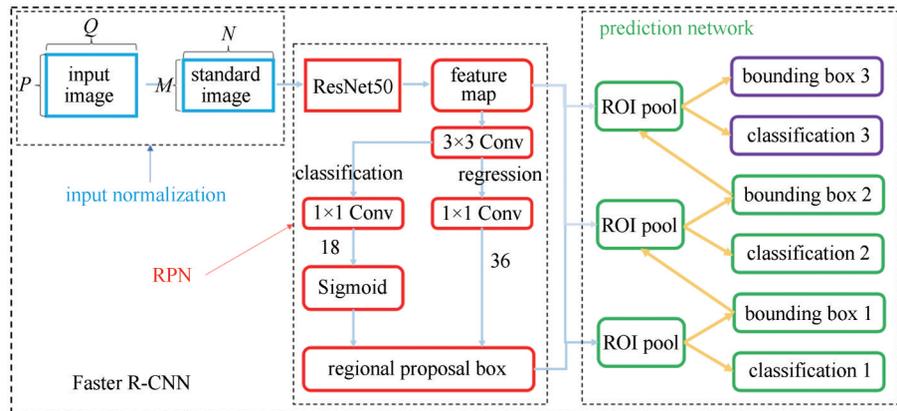


Fig.7 Diagram of network model structure
图 7 网络模型结构图

本文设计的网络框架本质上属于两阶段目标检测模型，训练过程分为 2 个环节进行：RPN 网络和 Faster R-CNN 网络。其中，RPN 网络包含 ResNet50 特征提取网络、分类网络和回归网络；Faster R-CNN 网络包括 ResNet50 特征提取网络和用于预测的全连接层。特别地，RPN 网络和 Faster R-CNN 网络中的特征提取网络是相同的。在网络训练时，首先训练 RPN 网络，更新共享网络层、分类网络和回归网络的权重参数，并将共享网络层的权重参数固定，仅训练分类网络和回归网络；然后训练 Faster R-CNN 网络，更新共享网络层和全连接层的权重参数，实现网络更新，同样将共享网络层的权重参数固定，仅训练全连接层。该模型的损失函数包括分类损失和回归损失，分类损失函数为：

$$L_{cls} = \frac{\sum_i L_{cls}(p_i, p_i^*)}{N_{cls}} \quad (8)$$

式中： N_{cls} 为类别的数目； p_i 为预测框对应的分类概率； p_i^* 为二值化参数，当预测框为正样本时， p_i^* 为 1；否则， p_i^* 为 0。 L_{cls} 为 2 个类别的对数损失：

$$L_{cls}(p_i, p_i^*) = -\log [p_i p_i^* + (1 - p_i)(1 - p_i^*)] \quad (9)$$

模型的回归损失函数为：

$$L_{\text{reg}} = \frac{\sum_i p_i^* L_{\text{reg}}(t_i, t_i^*)}{N_{\text{reg}}} \quad (10)$$

式中: N_{reg} 为预测框的数目; t_i 为模型预测框的偏移量; t_i^* 为实际框的偏移量; $L_{\text{reg}}(t_i, t_i^*)$ 的算式为:

$$L_{\text{reg}}(t_i, t_i^*) = \begin{cases} 0.5(t_i - t_i^*)^2 \times 1/\sigma^2, & \text{if } |t_i - t_i^*| < 1/\sigma^2 \\ |t_i - t_i^*| - 0.5, & \text{otherwise} \end{cases} \quad (11)$$

综合式(9)~式(11), 整体模型的损失函数为:

$$L_{\text{loss}} = \frac{1}{N_{\text{cls}}} \sum_i L_{\text{cls}}(p_i, p_i^*) + \lambda \frac{1}{N_{\text{reg}}} \sum_i p_i^* L_{\text{reg}}(t_i, t_i^*) \quad (12)$$

式中 λ 为平衡分类损失和回归损失之间的归一化权重。

4 实验分析

4.1 实验准备

为验证本文提出的基于 Faster R-CNN 算法的高铁扣件缺陷检测精确度, 搭建机器视觉系统, 该系统包括光源、工业相机和镜头等结构。综合考虑实际测量和国产化应用等需求, 选用海康威视 MV-CA020-10GM 黑白面阵工业相机搭配 ZX-SF2514B(25 mm) 镜头, 其具体参数见表 1。

本文共收集 5 200 张图像, 其中 3 200 张图像用作训练集和验证集, 2 000 张作为测试集。所有的训练过程在一台配置为 2.71 GHz Core i7 CPU、32 G 内存、NVIDIA 2060 的计算机上进行, 超参数设置见表 2。典型有形变缺陷的扣件弹条见图 8。

表 1 相机参数

Table1 Camera parameters

category	parameter
sensor type	CMOS
shutter mode	global shutter
resolution ratio	1 624×1 240
exposure time	1 μ s~10 s
signal to noise ratio	4.3 dB
pixel size	4.5 μ m × 4.5 μ m
lens focus/mm	25 mm

表 2 超参数设置

Table2 Hyperparameter settings

type	parameter
input image size	600×600
prior frame size	[128 ² , 256 ² , 512 ²]
number of freezing rounds of feature extraction layer	60
total training rounds	500
optimizer	Adam
initial learning rate	10 ⁻⁴
minimum learning rate	10 ⁻⁶
batch_size	5
validation interval rounds	5



Fig.8 Typical defective fastener images clip

图 8 典型故障扣件弹条

4.2 实验结果与分析

采用准确度(Accuracy)、召回率(Recall)、精确度(Precision)、F1 值和 ROC(Receiver Operating Characteristic) 曲线下面积 (Area Under Curve, AUC) 值等指标对计算结果进行评估, 其结果见图 9。

高铁扣件缺陷检测中, 如果具有缺陷的扣件被漏检, 将会产生严重损失, 因此该系统更加强调精确度, 即模型需要具有较高的精确度。从图 9 中可以看出, 该模型具有 99.33% 的精确度。如果仅使用召回率和精确度评估模型, 则只能体现部分性能, F1 值则综合了召回率和精确度的指标, F1 值越大, 表明该模型综合性能越好。AUC 值描述的是 ROC 曲线下的面积, 其值越大, 表示模型越好。

采用 ROC 曲线和 P-R 曲线对模型进行评估, 结果见图 10。

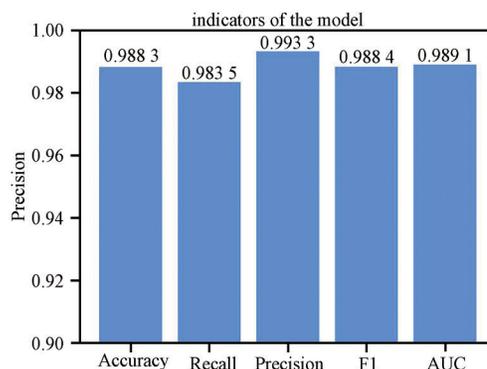


Fig.9 Model evaluation results

图 9 模型评估结果

从图中可以看出，当模型预测出假的正样本比例逐渐减少时，此时的模型仍具有较高的召回率；随着模型召回率的增大，越来越多的实际正样本会被预测为正样本，此时模型仍具有较高的精确度。综上所述，本文提出的高铁扣件缺陷检测算法具有较高的性能。

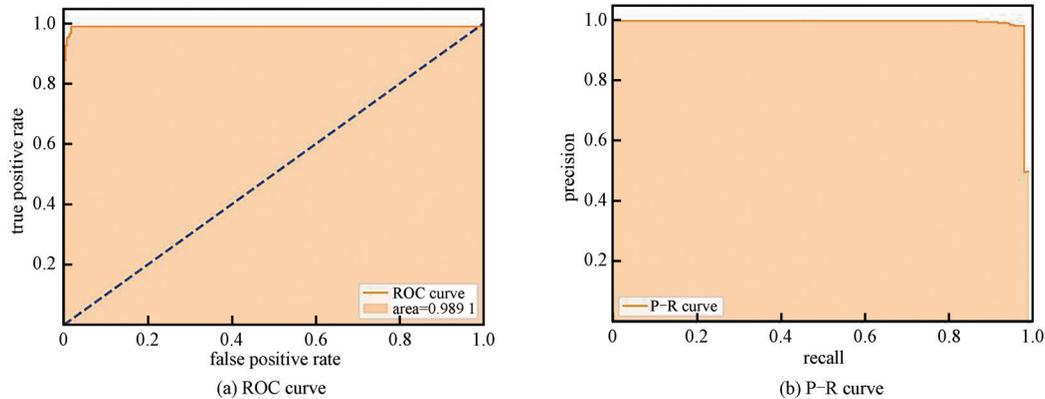


Fig.10 ROC curve and P-R curve

图 10 ROC 曲线与 P-R 曲线

5 结论

本文实验结果表明了所提算法的有效性，由于充分体现了区域特征提取的优势，与现有算法相比，对于扣件缺陷具有更高的检测精确度。所提算法很大程度上简化了图像预处理环节，仅需中值滤波和双边滤波处理，极大降低了对前端数据采集环节的硬件依赖，适合部署于较低成本的采集电路，可显著降低实施成本。

参考文献：

- [1] ZHONG Haoyu, LIU Long, WANG Jie, et al. A real-time railway fastener inspection method using the lightweight depth estimation network[J]. Measurement, 2022(189):110613. doi:10.1016/j.measurement.2021.110613.
- [2] AYTEKIN C, REZAEITABAR Y, DOGRU S, et al. Railway fastener inspection by real-time machine vision[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2015, 45(7):1101-1107. doi:10.1109/TSMC.2014.2388435.
- [3] PENG Zhiyong, WANG Chao, MA Ziji, et al. A multifeature hierarchical locating algorithm for hexagon nut of railway fasteners[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(3):693-699. doi:10.1109/TIM.2019.2905309.
- [4] LIU J W, LIU H L, CHAKRABORTY C, et al. Cascade learning embedded vision inspection of rail fastener by using a fault detection IoT vehicle[J]. IEEE Internet of Things Journal, 2023, 10(4):3006-3017. doi:10.1109/JIOT.2021.3126875.
- [5] TU Zhenwei, WU Songrong, KANG Gaoqiang, et al. Real-time defect detection of track components: considering class imbalance and subtle difference between classes[J]. IEEE Transactions on Instrumentation and Measurement, 2021(70):5017712-1-12. doi:10.1109/TIM.2021.3117357.
- [6] FENG Hao, JIANG Zhiguo, XIE Fengying, et al. Automatic fastener classification and defect detection in vision-based railway inspection systems[J]. IEEE Transactions on Instrumentation and Measurement, 2014, 63(4):877-888. doi:10.1109/TIM.2013.2283741.
- [7] LIU Jianwei, TENG Yun, SHI Bo, et al. A hierarchical learning approach for railway fastener detection using imbalanced samples[J]. Measurement, 2021(186):110240. doi:10.1016/j.measurement.2021.110240.
- [8] LIU Jianwei, TENG Yun, NI Xuefeng, et al. A fastener inspection method based on defective sample generation and deep convolutional neural network[J]. IEEE Sensors Journal, 2021, 21(10):12179-12188. doi:10.1109/JSEN.2021.3062021.
- [9] LIU Jianwei, MA Ziji, QIU Yuan, et al. Four discriminator cycle-consistent adversarial network for improving railway defective fastener inspection[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(8):10636-10645. doi:10.1109/TITS.2021.3095167.
- [10] LIU Junbo, HUANG Yaping, ZOU Qi, et al. Learning visual similarity for inspecting defective railway fasteners[J]. IEEE Sensors Journal, 2019, 19(16):6844-6857. doi:10.1109/JSEN.2019.2911015.
- [11] WEI Xiukun, YANG Ziming, LIU Yuxin, et al. Railway track fastener defect detection based on image processing and deep learning techniques: a comparative study[J]. Engineering Applications of Artificial Intelligence, 2019(80):66-81. doi:10.1016/j.engappai.2019.01.008.