

DOI: 10.19650/j.cnki.cjsi.202311633

基于 LGF-Net 的全天候轨道入侵异物智能检测系统*

赵宗扬¹, 康杰虎¹, 梁健¹, 叶涛², 吴斌¹

(1. 天津大学精密测试技术及仪器全国重点实验室 天津 300072; 2. 中国矿业大学(北京) 机电与信息工程学院 北京 100083)

摘要:针对轨道入侵异物为行车安全带来巨大威胁,而现有的轨道目标检测模型检测精度和速度难以平衡、复杂轨道环境中多尺度目标检测鲁棒性差等问题,提出了一种全天候高精度实时多尺度轨道入侵异物检测模型。该模型通过使用双分支结构和线性特征变换提升模型的特征提取速度;通过改进 Transformer 结构使轻量型模型能够建模全局上下文信息;通过设计高丰富度特征融合结构和轻量型注意力机制进一步提升模型的多尺度目标检测能力。此外,本文将该模型进行嵌入式移植并研制智能检测系统。实验结果表明,本文所提出的模型在实际轨道场景采集的数据集中检测精度和速度分别为 94.93% 和 132 fps,比 YOLOv5s 高 3.09%,能够满足在复杂轨道场景中高精度实时检测多尺度入侵异物的应用需求。

关键词: 轨道入侵异物; 目标检测; 深度学习; 神经网络; 检测系统

中图分类号: U491.2 TH39

文献标识码: A

国家标准学科分类代码: 580.70

All-weather intelligent detection system for railway intrusion obstacles based on LGF-Net

Zhao Zongyang¹, Kang Jiehu¹, Liang Jian¹, Ye Tao², Wu Bin¹

(1. State Key Laboratory of Precision Measuring Technology and Instruments, Tianjin University, Tianjin 300072, China;

2. School of Mechanical Electronic & Information Engineering, China University of Mining & Technology, Beijing 100083, China)

Abstract: Aiming at the enormous threat that railway intrusion obstacles pose to train operation safety, and the existing railway obstacle detection models have difficulty balancing detection accuracy and speed and poor multi-scale object detection robustness in complex railway environments, this article proposes an all-weather high-precision real-time multi-scale railway obstacle detection model. The model improves the feature extraction speed of the model by using dual-branch structure and linear operation. By modifying the Transformer structure, the lightweight model can model global contextual information. By designing high richness feature fusion structure and lightweight attention mechanism, the model's multi-scale object detection ability is further improved. In addition, we embed the model and develop an intelligent detection system. The experimental results show that the proposed model has a detection accuracy and speed of 94.93% and 132 fps in the dataset collected from actual railway scenes, respectively, which is 3.09% higher than YOLOv5s. It can meet the application requirements of high-precision real-time detection of multi-scale obstacles in complex railway scenes.

Keywords: railway intrusion obstacles; object detection; deep learning; neural network; detection system

0 引言

近年来,高铁、地铁作为国家重要基础设施和大众化交通工具,在推动国家经济快速发展和满足人民便捷出行

生活需求等方面发挥着不可替代的作用。随着列车运行速度和行驶密度的不断增加^[1],轨道入侵异物的出现很大程度上威胁着列车的行车安全,甚至能够引发极其严重的轨道交通事故^[2-3]。然而,由于恶劣气候的突发性和入侵异物的不可预测性,实际轨道交通列车的运行环

收稿日期:2023-07-05 Received Date: 2023-07-05

* 基金项目:天津市交通运输科技发展规划项目(2022-09)、北京市自然科学基金(L221018)、光纤传感与系统北京实验室开放课题(GXKF2022001)、天津大学自主创新基金(2023XHX-0019)项目资助

境复杂多变且入侵异物种类冗杂、尺度各异,传统方法仅靠驾驶员观察难以精准识别入侵异物,无法保证行车安全,要想让列车在低光照、雨雪雾等复杂轨道环境中安全运行更是存在巨大挑战。因此,研究一种能够高精度实时检测多尺度轨道入侵异物的智能避障系统非常有必要,对于保障列车的行车安全和人民的生命财产安全具有很重要的现实意义。

许多学者对轨道目标检测进行了大量的研究,基于视觉的目标检测方法由于成本低廉、检测效果直观等优点在轨道入侵异物检测领域得到了愈加广泛的应用^[4-5]。基于视觉的轨道入侵异物检测方法可以分为基于传统目标检测和基于深度学习的轨道入侵异物检测方法。传统目标检测方法的共性在于都采用人为设计的手工特征进行目标特征的提取,再通过设计分类器解决某一特定场景下目标识别和分类问题。同磊等^[6]通过手工设计异物候选区的长宽比、颜色索引等特征参数,使用结合支持向量机^[7](support vector machines, SVM)分类器进行轨道入侵异物的辨识,该算法的结构简单处理速度较快,但对入侵异物的检测精度低,尤其是小目标入侵异物的漏检率较高;Rodriguez 等^[8]改进了 Hough 变换^[9]方法检测铁路轨道线区域并在此区域内利用轨道的几何性质扫描搜索入侵异物,但仍无法有效降低漏检现象。宁正等^[10]提出一种改进的混合高斯模型,使用小波变换原理消除轨道环境中的干扰点后进行差分处理以检测轨道入侵异物,模型抗雨雪雾等恶劣天气干扰的能力较强,但检测精度仍无法满足实际轨道环境下的检测需要。上述采用手工特征提取来实现轨道入侵异物检测的方法过于依赖设计者的经验,而且无法自适应提取特征,对于光照多变和雨雪雾等恶劣气候下的复杂轨道环境中入侵异物的高级语义信息难以充分挖掘,场景迁移能力差。相比之下,基于深度学习的轨道入侵异物检测方法可以自适应提取特征,对于入侵异物的检测精度较高,在轨道环境有着很大的应用潜力。

基于深度学习的轨道入侵异物检测方法可以分为两阶段算法和单阶段算法。代表性的两阶段算法如基于区域的卷积神经网络(region-based convolutional neural networks, R-CNN)系列^[11-13]在生成候选区域后再进行目标的分类和定位。徐岩等^[14]基于 Faster R-CNN 网络进行改进,通过增加锚点个数来提高对轨道入侵异物区域建议框的精确性,并使用池化层代替全连接层以降低算法的参数数量;张丽艳等^[15]将霍夫变换和 Faster R-CNN 相结合,通过比较入侵异物与轨道所在直线坐标的差异提高算法的检测鲁棒性。上述两阶段算法的检测精度较高,但计算过程过于复杂导致检测速度很慢,无法满足在实际轨道场景中实时检测入侵异物的应用需求。单阶段算法如单次多边框检测(single-shot multibox detector,

SSD)^[16]和 YOLO(you only look once)^[17-21]等将检测问题视为回归问题,直接预测目标的类别和位置。相比于两阶段算法,一阶段算法的结构更加简单,实时性提升巨大,在轨道入侵异物检测领域的应用前景广泛。Guo 等^[22]在 SSD 的基础上进行网络剪枝,在将入侵异物检测精度牺牲量限制为 1%的前提下,最大程度上提升模型的检测速度。但该方法对轨道入侵异物的检测精度较低,尤其对于小目标入侵异物检测精度的提升空间巨大。Ye 等^[23-24]和叶涛等^[25]提出一系列轨道入侵异物的检测算法并研制了检测样机,设计特征提取能力更强的主干特征提取网络,对于不同尺度的入侵异物,采用相对应的特征融合方式提取更高级的语义信息,在保证算法实时性的前提下提高了检测精度,但并未对算法进行部署优化且所设计的检测样机仍有优化空间。Tian 等^[26]针对轨道入侵异物体积的差异性设计了特征增强模块,并使用融合不同感受野的特征图以提高算法的检测精度,但该方法检测速度低且无法保证在复杂环境中高精度检测小目标入侵异物。He 等^[27]将卷积神经网络(convolutional neural networks, CNN)与 Transformer^[28-29]相结合,通过改进模型的局部容量和信息交换特性的方式,增强融合网络的多尺度特性和融合不同层次的语义信息,以此提升小目标轨道入侵异物的检测精度,但所提方法的计算复杂度高且在弱光照和雨雪雾等恶劣天气下轨道环境中的检测能力仍需进一步验证。

针对上述问题,本文提出一种全天候高精度实时多尺度轨道入侵异物检测模型(high-precision real-time and multi-scale railway obstacle detection model, LGF-Net),其检测速度为 132 fps,检测精度为 94.93%,比 YOLOv5s 高 3.09%,能够在满足实时性应用需求的同时提升模型在复杂轨道环境中多尺度轨道入侵异物的检测精度和鲁棒性,尤其是小目标轨道入侵异物检测性能。此外,本文将 LGF-Net 嵌入式移植至 NVIDIA Jetson Xavier NX 中进行优化加速,并研制小型轨道入侵异物智能检测样机,满足在低光照等实际复杂轨道环境中全天候高精度实时检测轨道入侵异物的应用需求。

1 全天候轨道入侵异物检测模型的设计原理及结构

1.1 模型设计原理和总体结构

为满足恶劣气候频发、光照强度多变等复杂轨道场景的实际应用需求,本文提出全天候轨道入侵异物检测模型(railway obstacle detection model in different weathers, LGF-Net),能够在平衡检测速度和精度的同时,提升模型在复杂轨道环境中对多尺度轨道入侵异物的检测鲁棒性,特别是小目标入侵异物。原始图像经数据增强、归一

化和 Resize 等预处理操作后输入模型进行训练。该模型的整体结构如图 1 所示,由轻量高效的特征提取模块 (lightweight and efficient feature extraction module, LEM)、高精度全局上下文信息建模模块 (high-precision global context information modeling, GCM) 以及高丰富度特征融合模块 (high-richness feature fusion module, FFM) 构成。其中,轻量高效的特征提取模块主要由 CSP-GhostNet 结构 (C-Ghost) 组成,目的是在减轻模型计算负荷的同时增强模型特征提取能力,能够在使模型轻量化的同

时提取更为丰富的特征信息;高精度全局上下文信息建模模块由改进的 Transformer 结构组成,在所提取到丰富底层特征信息的基础上有效的捕获轨道图像中入侵异物的长远距离依赖关系,实现了对轨道环境全局上下文信息的建模,进而提升模型的检测精度;高丰富度特征融合模块对不同尺度的特征信息进行充分融合,并设计轻量型注意力机制在基本不增加计算量的前提下进一步提升模型的多尺度轨道入侵异物检测性能。




图 1 LGF-Net 结构示意图

Fig. 1 Structure diagram of railway obstacle detection model in different weathers (LGF-Net)

1.2 LEM

为在提升检测速度的同时增强模型对于轨道入侵异物底层特征信息的提取能力,本文提出轻量高效的特征提取模块,由步长为 2 的下采样卷积和 C-Ghost 组成。其中,C-Ghost 结构如图 2 所示,由 CSP-Net^[30] 和 Ghost-Net^[31] 组成,前者可以避免网络学习到重复的梯度信息,能够在降低计算量的同时提升模型的检测精度,后者通过线性特征变换在保证模型特征提取能力的同时大幅度降低了计算负荷。

GhostNet 由普通卷积层和线性特征变换层两部分组成。在线性特征变换层的计算过程中,为获得与普通卷积层相似的 k 个特征图,本文 Y' 中的特征图使用线性变换操作,其计算过程如式(1)所示:

$$y_{ij} = \Phi_{i,j}(Y'_i), \quad \forall i = 1, \dots, m, \quad j = 1, \dots, s \quad (1)$$

其中, Y'_i 表示普通卷积层生成的第 i 个通道的特征图; $\Phi_{i,j}$ 代表第 i 个通道特征图的第 j 次线性变换过程,




图 2 C-Ghost 结构示意图

Fig. 2 C-Ghost structure diagram

s 为线性特征变换次数; $\Phi_{i,s}$ 代表原始输入特征图的恒等映射,最终将恒等映射的特征图和经 $s - 1$ 次线性变换后的特征图进行拼接,得到最终的输出特征图 $Y \in \mathbb{R}^{h \times w \times c_g}$ 。普通卷积和线性特征变换计算量的比值 r_s 可表

示为:

$$r_s = \frac{m \times h \times w \times c' \times d \times d}{\frac{m}{s} \times h \times w \times c' \times d \times d + (s-1) \times \frac{n}{s} \times h \times w \times c' \times g \times g} = \frac{c' \times d \times d}{\frac{1}{s} \times c' \times d \times d + \frac{s-1}{s} \times g \times g} \approx s \quad (2)$$

由于在本文中普通卷积的尺寸 $d \times d$ 和线性变换中分组卷积的尺寸 $g \times g$ 都为 3×3 , 故使用线性特征变换后计算量可近似缩减为普通卷积计算量的 s 倍。而且, 本文所使用的线性特征变换层在逐通道进行卷积运算后, 并未使用逐点卷积进行计算, 而是将恒等变换等线性特征变换所生成的特征图进行拼接, 故相比于 MobileNet 系列本文所提出模型的计算量得到了进一步降低。

此外, 本文将 CSP-Net 与线性特征变换相结合。输入特征 $X_{in} \in R^{h \times w \times c}$ 被分为两部分, 左侧部分 $X_r \in R^{h \times w \times c_r}$ 经普通卷积进行特征提取, 右侧部分 $X_g \in R^{h \times w \times c_g}$ 作为 GhostNet 的输入特征图进行线性特征变换, 最后二者进行特征拼接得到 $X_{out} \in R^{h \times w \times c}$ 。LEM 的整体计算过程可表示为:

$$X_{out} = \text{Conv}(X_r) \oplus \text{GhostNet}(X_g) \quad (3)$$

通过设计上述 LEM, 将跨阶段局部网络的策略和线性特征变换相结合, 实现了在低成本高效益利用不同特征图的冗余性和相关性的同时, 大幅度减少模型的计算量。而且, 使用梯度分流策略有利于模型学习不同的梯度流信息, 在减轻计算负荷的同时提升了模型对于轨道入侵异物的检测性能。

1.3 GCM

针对现有的轨道入侵异物检测模型全局上下文信息理解能力弱、实时性差等问题, 本文基于 Transformer 进行改进提出高精度全局上下文信息建模模块, 由 3 个数据传输速率 (external transfer rate, ETR) 结构组成, 如图 3 所示。在轻量高效的特征提取模块对底层纹理特征进行提取后, 该模块能够对轨道入侵异物的全局上下文关系进行建模, 进而提升模型的检测性能。本文将该模块放置在靠后的特征提取阶段, 原因是在特征图尺寸较小的情况下 Transformer 的计算量可以被有效限制, 能够实现性能和效率的较好平衡。

对于长、宽和通道数分别为 h 、 w 和 c 输入特征图 $x \in R^{h \times w \times c}$, ETR 首先对其进行位置编码得到 $x_p = f_p(x)$, 目的是提升模型对位置信息的感知能力, 以弥补在自注意力机制计算过程中位置信息的缺失, 该位置编码过程通过一个全连接层实现。然后, 将编码后的特征送入增强的多头注意力机制、残差连接和前馈神经网络等结构中进行计算, 本文去除了原 Transformer 中的归一化过程,




图 3 Transformer 和 ETR 结构对比
Fig. 3 Comparison of Transformer and ETR architecture

目的是在不影响全局建模性能的前提下, 提升模型的运算效率, 计算过程如式 (4) 和 (5) 所示:

$$x_a = x_p + \text{EMSA}(x_p) \quad (4)$$

$$y = x_a + \text{FFN}(x_a) \quad (5)$$

其中, EMSA 为增强的多头注意力机制。FFN 为前馈神经网络, 由两个全连接层和线性激活函数组成, W_1 、 b_1 和 W_2 、 b_2 分别为两个全连接层的权重和偏置:

$$\text{FFN}(x_a) = \max(0, x_a W_1 + b_1) W_2 + b_2 \quad (6)$$

为更好地利用轨道环境的全局特征信息和局部特征信息, 本文在增强的多头自注意力机制 (enhanced multi-headed self-attention, EMSA) 中使用 CSP-GhostNet 对模型的局部信息进行提取, 实现了模型的轻量化以及检测精度的提升, 如图 4 所示。此外, 本文使用在 EMSA 中应用 dropout 正则化, 在简化模型结构降低计算量的同时, 也避免了过拟合现象的发生, 从而进一步提升模型在复杂轨道环境中的检测能力。在多头自注意力机制中, 输入特征向量 x_s 将通过可学习参数 W_i 转换为 3 个新的特征向量 Q 、 K 和 V , 计算过程为:

$$Y_s = x_s \cdot W_i \quad (7)$$

其中, $Y_s \in [Q, K, V]$ 代表输出特征向量, $W_i \in [W_Q, W_K, W_V]$ 可在训练过程中自适应更新调整, 上述 3 个向量在自注意力机制中实现对全局上下文信息进行建模, 如式 (8) 所示, $d_k = c/n$ 为归一化系数, 目的是规避过大或过小的元素值对梯度更新带来不利影响:

$$\text{SA}(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right) V \quad (8)$$




图4 EMSA结构示意图

Fig. 4 Architecture diagram of EMSA

本文通过设计高精度全局上下文信息建模模块,建立了轨道入侵异物的长程依赖关系,其中多头自注意力机制的使用有利于捕获更丰富的特征信息,进而得到

多元化的全局上下文特征建模信息,能够有效地提升模型在复杂轨道环境中的检测精度。此外,通过局部特征提取和全局信息建模相结合的方式,实现了在提升模型检测能力的同时兼顾模型的轻量化,有利于模型的嵌入式部署和实际工业应用。

1.4 FFM

针对模型的多尺度特征表达能力差,尤其是对于小目标入侵异物难以精准识别等问题,本文提出FFM,如图5所示,以ETR建模出不同尺寸全局信息特征图的基础上,通过设计多尺度特征融合方式和轻量型注意力机制,充分整合不同尺度轨道入侵异物的特征信息并增强特征表达能力,进而提高模型的多尺度轨道入侵异物检测性能,特别是小目标轨道入侵异物检测能力。




图5 FFM结构示意图

Fig. 5 Architecture diagram of FFM

本文设计了一种自顶向下和自下而上的多尺度特征融合方式,将大尺度和中尺度特征图所涵盖的高级语义信息进一步整合至小尺度特征图中,实现了对轨道入侵异物全局高级语义特征信息的充分利用,进而达到针对性提升模型小目标检测精度的目的。以在小尺度目标检测分支 C_s 中上述多尺度特征融合方式所整合特征图的计算过程为例:

$$C_s = CSC_s(ERT1' \odot CSC_m(ERT1' \oplus ERT2) \odot (ERT2 \oplus C_{ETR3})) \quad (9)$$

其中, CSC_i 代表不同尺度检测分支中的 CSP-Net 和卷积结构,目的是在减轻模型计算量的同时实现特征提取和特征图的缩放; $ERT1' = CSC_s(ETR1)$, $ETR1$ 为小尺度目标检测头所输入的全局特征; $\oplus$ 和 $\odot$ 分别为逐元素相加和通道拼接, C_{ETR3} 为大尺度检测头中该特征融合方式所输出的特征向量。

此外,本文提出了一种轻量型注意力机制,如图6所示,通过重新分配输出通道的权值以降低复杂背景对检测结果的不利影响,在基本不增加计算量的前提下提升

了模型的多尺度轨道入侵异物检测能力。多尺度特征信息融合后的特征 T , 分别通过全局平均池化和全局最大池化提取代表性特征信息,再经全连接层进行特征整合,最后通过 H-Sigmoid 函数激活后重新规划不同通道的特征响应,经轻重型注意力机制优化后输出的特征 T' 可表示为:

$$T' = T \otimes f_h(L(g_a(T) \oplus g_m(T))) \quad (10)$$

其中, $\otimes$ 和 $\oplus$ 分别表示逐通道相乘和逐元素相加, $g_a(\cdot)$ 和 $g_m(\cdot)$ 分别全局平均池化和全局最大池化, $L(\cdot)$ 为全连接层, $f_h(\cdot)$ 代表 H-Sigmoid 激活函数,其内部不使用指数运算,可使得模型计算量进一步降低。




图6 轻量型注意力机制

Fig. 6 Lightweight attention mechanism

本文所设计的高丰富度特征融合模块能够充分的提取和利用不同尺度的特征信息,实现了在复杂环境中高精度检测多尺度轨道入侵异物。此外,本文在最后预测模块前加入轻量型注意机制,目的是对通道间的语义依赖进行编码以进一步优化不同层次的特征响应,在基本不增加计算量的前提下进一步提升了模型的多尺度目标检测能力,尤其是对于小目标轨道入侵异物的检测精度。

2 轨道入侵异物检测智能检测系统的组成

针对目标检测算法在嵌入式移植过程中实时性损失巨大至无法满足实时检测需求的实际应用难题,本文选择高性能 NVIDIA Jetson Xavier NX 开发板为计算平台,并在 LGF-Net 嵌入式移植过程中使用 TensorRT 进行加速以提升算法的实时性。此外,本文将算法移植成功后的嵌入式平台、星光相机、图像采集卡等设备进行集成研制小型智能轨道入侵异物检测样机。

2.1 嵌入式平台和图像捕获系统

本文选取 NVIDIA Jetson Xavier NX 作为嵌入式平台,使用索尼 FCB-EV9500L 星光相机作为图像捕获系统,如图 7 所示。该星光相机能够在光线强度较弱时主动增大光圈和感光度,提升所捕获轨道场景图像的质量,进而避免因光照不足导致模型检测性能下降。




图 7 嵌入式设备和星光相机

Fig. 7 Embedded device and starlight camera

为更加具体的展示星光相机在低光照轨道场景中图像捕获的有效性,本文将上述星光相机和类似于人眼观感的普通数码相机捕获的图像进行了对比,如图 8 所示。所有图像的捕获都在同一时间和地点进行,第 1 行为普通数码相机的拍摄效果,第 2 行为星光相机的图像捕获结果。实验结果表明,本文所选用的星光相机能够在低照度轨道环境中捕获较为清晰度的图像数据,避免了在低光照环境中因捕获图像质量差而导致的模型检测失效问题。

2.2 小型智能检测样机的搭建及工作流程

本文将上述 NVIDIA Jetson Xavier NX 嵌入式平台、索尼 FCB-EV9500L 星光相机和语音预警器等硬件进行



图 8 数码相机和星光相机捕获图像对比

Fig. 8 Comparison of images captured by digital camera and starlight camera

集成,研制小型轨道入侵异物智能检测样机,如图 9 所示。该样机的长宽高分别为 30、24 和 12 cm,能够满足轨道场景下高精度实时检测多尺度轨道入侵异物的实际应用需求。




图 9 检测样机实物装置

Fig. 9 Physical device of prototype

该检测样机在实际轨道环境中的工作流程如图 10 所示。图像采集层主要利用星光相机进行图像捕获,实现了在弱光环境中的自适应补光,进而有效提高复杂环境中多尺度轨道入侵异物的成像质量;图像智能处理层主要以高性能嵌入式计算平台 NVIDIA Jetson Xavier NX 为依托,在保证模型实时性的同时将 LGF-Net 嵌入式移植至嵌入式平台中并进行 TensorRT 加速,有利于在实际轨道环境中高精度实时检测入侵异物;决策规划层主要对图像智能处理层输出的信息进行处理,并结合预警策略实现列车辅助驾驶功能。本文主要针对该系统图像智能处理层中模型的检测性能为研究重点,提出了 LGF-Net,能够恶劣气候和低光照等实际复杂轨道环境中高鲁棒性检测轨道入侵异物,并通过大量的实验对比和结果分析验证了该检测模型的有效性。




图 10 轨道样机工作流程
Fig. 10 Workflow of railway prototype

3 实验结果和分析

为了评估全天候轨道入侵异物模型的检测有效性, 本文在实际轨道环境数据集上进行了实验及测试。训练服务器使用 4 块 NVIDIA GTX 1080TI 型号的 GPU 显卡和 Intel i7-6950X 型号的 CPU 处理器, 其中每块显卡的运行内存为 11 G, 同时配备有 512 GB 固态硬盘, 4 TB 机械硬盘和 64 GB 内存。服务器中的系统环境为 Ubuntu 18. 04. 5, 深度学习框架、编程语言和计算机视觉库分别为 Pytorch 1. 9. 0、Python3. 7 和 Opencv4. 5. 1。

3.1 数据采集与扩增

为了评估实际轨道场景中目标检测的性能, 本文在实际轨道场景中进行图像采集, 利用视频抽帧方法生成了 8 776 张数据图像并进行了标注, 建立了一个新的轨道交通数据库, 包含了不同天气、场景和光照条件下的真实轨道图像。该数据集的部分示例如图 11 所示, 将收集到的图像中的轨道入侵异物分为 7 个类别: 列车 (bullet train)、行人 (pedestrian)、直行轨道 (railway straight)、左转轨道 (railway left)、右转轨道 (railway right)、头盔 (helmet) 和扳手 (spanner)。

本文在实际轨道场景中采集 8 776 张图像, 并根据实际恶劣天气轨道环境视觉特征设计恶劣天气数据扩增算法, 为后续训练全天候轨道入侵异物检测模型提供更大规模的数据支持, 如图 12 所示。本文对雨雪雾、低光照和高亮度等极端天气进行模拟, 在原有数据的基础上随机生成程度不同的雨雪雾等恶劣天气下的轨道入侵异




图 11 轨道数据集示例
Fig. 11 Examples of railway dataset

物图像。此外, 本文将 Mosaic 数据增强应用至恶劣天气轨道环境数据扩增算法中, 有利于提升模型的小目标检测性能。图 12(c) 展示了模型训练过程中恶劣天气轨道

环境数据增广算法起作用的流程:首先,在实际轨道环境中所捕获图像所构成的数据库中抽取一个训练批次的图像;然后,随机选取 4 张图像进行恶劣天气模拟和 Mosaic 数据增强,使得该批次训练图像更能代表数据集的整体特

征分布并包含更多的小目标入侵异物;接着,将上述增广过程重复 batch size 次,目的是使得增强后的数据和原训练批次中的图像数目一致;最后,将恶劣天气数据增广后的图像作为轨道入侵异物检测网络的输入进行模型训练。




图 12 恶劣天气轨道环境数据增广算法数据增强过程
Fig. 12 Data augmentation process of severe weather railway environments

3.2 实验结果分析

本文在经数据增广后的轨道入侵异物数据样本库上进行实验,其中 80% 的图像用于模型的训练和验证,20% 的图像用于测试,上述过程皆在 GPU 上进行。模型采用随机梯度下降法 (stochastic gradient descent, SGD) 进行优化,初始学习率为 0.01,随后按照余弦退火策对学习率进行调整。模型最大迭代次数设定为 150 轮,动量为 0.937,权重衰减率为 0.000 5, batch size 设定为 64,非极大值抑制值 (non-maximum suppression, NMS) 和置信度阈值分别设置为 0.6 和 0.45。为验证模型对不同场景、不同目标类别和大小的检测效果,本文将所提出的 LGF-Net 与目标检测领域应用广泛的高精度检测模型 (YOLOv4^[17]、YOLOv5x、YOLOv7^[20]、SEF-Net^[22]、DFF-Net^[32]、FE-SSD^[33] 等),以及实时性检测模型 (YOLOv4-tiny^[17]、YOLOv7-tiny^[20]、YOLOXs、YOLOv6s^[19]、FB-Net^[34] 等) 分别进行对比。其中,SEF-Net、DFF-Net、FE-SSD 和 FB-Net 是专为轨道入侵异物检测而设计的模型,其余模型是目标检测领域广为使用的检测模型。使用平均检测精度 (mAP)、检测速度 (FPS) 和模型计算量 (GFLOPs) 对模型的性能进行评估,最优结果用加粗黑体

标出,实验结果如表 1 和 2 所示。

表 1 的实验结果表明: LGF-Net 的平均检测精度为 94.93% 取得最优,对于各类别轨道入侵异物的检测性能优良,检测速度和计算量分别为 132 fps 和 12.7 GFLOPs,该模型的计算量小且实时性明显优于其他模型,能够很好的平衡检测速度和精度并实现在轨道场景中全天候高精度实时检测轨道入侵异物。相比之下, YOLOv3 的检测精度较差,且检测速度仅有 67 fps,实时性与 LGF-Net 相差巨大,无法保证在实际轨道环境中高效率鲁棒地检测轨道入侵异物。相比于 YOLOv3、YOLOv4 和 YOLOv5x 的检测精度有所提升,但伴随而来的是计算量的增加和检测速度的降低,故二者无法满足实际轨道场景中实时检测入侵异物的应用需求,且二者的检测精度与 LGF-Net 相比仍有较大差距。SEF-Net 的检测精度取得次优结果但计算量较大, LGF-Net 在计算量缩减近十倍的同时实现了更快的检测速度和更高的检测精度,能够在复杂多变的轨道环境中更为精准高效地检测入侵异物且更利于在实际轨道场景中的部署应用。与其他两个专门为轨道入侵异物检测而设计的模型 DFF-Net 和 FE-SSD 相比, LGF-Net 对于所有类别异物的检测精度都有明显

表 1 高精度模型结果比较

Table 1 High-precision model results comparison

类别	模型							
	YOLOv3	YOLOv4	YOLOv5x	YOLOv7	SEF-Net	DFF-Net	FE-SSD	LGF-Net
列车/%	92.28	94.01	95.26	95.17	94.75	89.96	90.95	96.63
行人/%	86.45	94.41	94.15	92.45	94.34	90.77	88.62	98.15
直行轨道/%	95.07	98.56	98.95	98.57	99.03	90.79	90.29	96.92
左转轨道/%	95.04	95.90	95.56	90.84	97.55	90.08	89.34	91.86
右转轨道/%	93.64	97.40	97.67	96.45	97.26	90.44	90.18	96.71
安全帽/%	86.95	93.18	93.61	94.32	93.68	90.83	89.86	94.69
扳手/%	86.17	86.50	87.91	88.03	86.64	87.99	87.68	89.58
mAP/%	90.08	94.28	94.73	93.69	94.75	90.12	89.50	94.93
检测速度/fps	67	55	42	38	81	54	38	132
计算量/GFLOPs	157.3	184.2	219.0	104.7	124.6	—	—	12.7

表 2 实时性模型结果比较

Table 2 Real-time model results comparison

类别	模型							
	YOLOv4-tiny	YOLOv7-tiny	YOLOXs	YOLOv5s	Mbv2-YOLOv3	YOLOv6s	FB-Net	LGF-Net
列车/%	88.97	89.16	91.82	94.45	87.93	95.03	90.62	96.63
行人/%	72.17	80.43	90.35	90.76	81.03	94.22	82.94	98.15
直行轨道/%	91.69	94.31	92.09	95.81	96.42	94.76	90.57	96.92
左转轨道/%	89.34	90.86	91.26	90.12	85.12	91.25	88.25	91.86
右转轨道/%	88.90	96.62	96.58	93.14	93.42	96.48	90.53	96.71
安全帽/%	88.27	93.21	92.72	93.03	79.14	89.36	87.75	94.69
扳手/%	77.37	81.44	89.04	85.57	56.75	86.47	82.60	89.58
mAP/%	85.24	89.43	91.98	91.84	82.83	92.51	87.62	94.93
检测速度/fps	330	163	113	139	75	128	82	132
计算量/GFLOPs	7.0	13.7	26.8	16.5	19.6	45.3	—	12.7

提升,平均检测精度分别提升了 4.81%和 5.43%,能够在实际复杂环境中更精准的检测多尺度入侵异物。而且,LGF-Net 的检测速度是上述两个模型的数倍,满足模型在实际轨道环境中的高实时性应用需求。此外,LGF-Net 表现出了更优良的小目标检测性能,与对小目标检测取得次优结果的 YOLOv7 相比,LGF-Net 对安全帽和扳手两类目标的检测精度分别提高了 0.37%和 1.55%。总之,LGF-Net 实现了检测精度和速度的良好平衡,即便对于视觉特征匮乏的小目标轨道入侵异物也能实现准确高效的实时检测,更符合复杂轨道场景的实际应用需求。

表 2 的实验结果表明:LGF-Net 很好地平衡了轨道异物的检测速度和精度,在实现实时检测的同时以 94.93%的平均检测精度在轻量型模型中取得最优,在检测准确率方面有明显优势,更利于实际场景中的多尺度轨道入侵异物检测。此外,在检测精度指标取得最高的同时,LGF-Net 的计算量和检测速度皆优于 YOLOXs、

Mobilenetv2-YOLOv3 和 YOLOv6s,能够在实际轨道环境中更精准高效地检测入侵异物,更利于嵌入式设备中的部署和实际场景中的应用。与 FB-Net 相比,LGF-Net 的平均检测精度和检测速度均有大幅提升,对小目标安全帽和扳手的检测精度分别提升了 6.94%和 6.98%,更适合在实际轨道环境中高精度实时检测小目标入侵异物。虽然 YOLOv4-tiny 和 YOLOv7-tiny 的检测速度较快,但是它们的检测精度太低,尤其是小目标检测能力弱,无法保证高精度检测多尺度轨道入侵异物。LGF-Net 对于小目标轨道入侵异物安全帽和扳手的检测精度分别为 94.69%和 89.58%,比实现次优结果的 YOLOv5s 和 YOLOXs 分别高了 1.66%和 0.54%,即便在复杂的轨道环境中也能精准定位并检测入侵异物。而且,对于往往存在大面积遮挡且视觉特征差异大的行人类目标,LGF-Net 能够以 98.15%的高检测精度进行识别,该实验结果进一步证明了本文所提出模型优良的检测性能。总之,

视化结果如图 14 所示。




图 14 鲁棒性测试结果
Fig. 14 Robustness test results

图 14 中从上到下每一行分别为雾天、隧道、夜晚和雨天等轨道环境,每一列分别为原始图像、YOLOv7-tiny 的检测结果、YOLOv5s 的检测结果和本文模型 LGF-Net 的检测结果。鲁棒性实验结果表明,在雾天轨道环境中, YOLOv7-tiny 和 YOLOv5s 对远处视觉特征模糊的列车漏检,而 LGF-Net 能够鲁棒地检测出列车前方的所有目标且置信度较高;在光照强度较弱的隧道中, YOLOv7-tiny 和 YOLOv5s 仅能识别出直行轨道,相比之下, LGF-Net 可

以进一步识别出远处的右转轨道,能够使得列车运行的安全性进一步提升;在夜晚行车环境中, YOLOv7-tiny 无法检测出图像左侧的列车, YOLOv5s 对列车存在误识别,而 LGF-Net 能够很好的识别出左侧的列车和前方的直行轨道,进一步证明了该模型的高鲁棒性;在雨天轨道环境中, 3 个模型都能够很好的识别出了左侧的列车和直行轨道,但 LGF-Net 能够对列车的位置进行更精准的定位和回归,并且能够以 88.13% 和 94.69% 的高置信度对二者进行识别,确保列车安全驾驶。不同复杂轨道环境的鲁棒性实验表明,本文所提出的全天候高精度实时性轨道入侵异物检测算法能够在复杂轨道环境中精准高效的检测目标,满足轨道环境的实际工业应用需求。

3.4 消融实验结果对比

为验证 LEM、GCM 和 FFM 等结构的有效性,本文设计了多组消融实验并进行对比分析,如表 3 所示。“-”和“√”分别代表不存在和存在相应模块。YOLOv5s 模型不含上述 3 个模块,其检测结果作为基线对比标准; GF-Net 由全局上下文信息建模模块和高丰富度特征融合模块组成,目的是验证轻量高效的特征提取模块对模型实时性提升的有效性; LF-Net 由轻量高效的特征提取模块和高丰富度特征融合模块,目的是验证全局上下文信息建模模块对轨道入侵异物长距离依赖关系建模的有效性; LG-Net 由轻量型特征提取模块和全局上下文信息建模模块组成,以验证高丰富度特征融合模块对模型多尺度轨道入侵异物检测精度提升的有效性。

表 3 消融实验结果对比
Table 3 Comparison of ablation results

子模块名称	YOLOv5s	GF-Net	LF-Net	LG-Net	LGF-Net
LEM	-	-	√	√	√
GCM	-	√	-	√	√
FFM	-	√	√	-	√
列车/%	94.45	97.21	95.61	94.58	96.63
行人/%	90.76	96.52	90.46	97.03	98.15
直行轨道/%	95.81	95.50	95.78	94.64	96.92
左转轨道/%	90.12	90.22	89.26	92.05	91.86
右转轨道/%	93.14	96.03	96.51	94.35	96.71
安全帽/%	93.03	94.46	91.25	93.18	94.69
扳手/%	85.57	88.97	85.41	86.92	89.58
mAP/%	91.84	94.13	92.04	93.25	94.93%
检测速度/fps	139	117	146	135	132
计算量/GFLOPs	16.5	21.8	11.3	12.0	12.7

首先,本文将 GF-Net 中的底层特征提取结构替换为 LEM 模块。与 GF-Net 相比,LGF-Net 的检测速度提升了 15 fps,计算量下降了 9.1 GFLOPs,且对绝大多数轨道入侵异物类别的检测精度更高,更利于模型的高精度实时检测。首先,将 LEM 模块加入至 GF-Net 中,实现了在保证模型特征提取能力的同时提升模型的检测速度。该实验结果证明 LEM 模块能够在降低模型计算量的同时提取丰富的底层特征信息,更符合实际轨道场景检测入侵异物的实时性要求。然后,将 GCM 模块替换至 LF-Net 中,虽然检测速度略有降低,但本文所提出的模型的对多尺度轨道入侵异物的检测精度明显提高,且对小目标安全帽和扳手的检测精度分别上升了 4.17%和 2.97%,证明了 GCM 对全局上下文信息建模的有效性;最后,本文使用 FFM 模块替换 LG-Net 的特征融合结构,实验结果证明高丰富度特征融合模块

可以在几乎不对模型实时性造成负面影响的前提下大幅度提升模型的多尺度目标检测精度,尤其是小目标轨道入侵异物。

此外,为进一步阐述恶劣天气轨道环境数据增广算法对模型检测精度提升的有效性,本文将数据增强前后 LGF-Net 的检测结果进行了对比,最优结果加粗表示,如表 4 所示。实验结果表明相比于未经数据增强的模型 NL-Net,LGF-Net 能够在不对模型检测速度造成任何影响的同时,平均检测精度提升 0.37%并增强模型对所有类别轨道入侵异物的检测性能,尤其是对小目标安全帽和扳手的检测精度分别提升了 0.84%和 0.56%。实验结果表明应用恶劣天气轨道环境数据增广方法的 LGF-Net 对复杂轨道环境中的多尺度轨道入侵异物检测性能更加优越,能够在实际轨道环境中高精度实时检测目标。

表 4 数据增强前后模型检测结果
Table 4 Model test results before and after data enhancement

模型	列车/%	行人/%	直行轨道/%	左转轨道/%	右转轨道/%	安全帽/%	扳手/%	mAP/%	检测速度/fps	计算量/GFLOPs
NL-Net	96.52	98.06	96.04	91.97	96.46	93.85	89.02	94.56	132	12.7
LGF-Net	96.93	98.15	96.92	91.86	96.71	94.69	89.58	94.93	132	12.7

总之,LGF-Net 在绝大多数轨道入侵异物类别中取得了最好的检测结果,尤其是对安全帽、扳手等小目标的检测精度比 YOLOv5s 提升了 1.63%和 4.01%,在保证模型轻量化的同时也很好的平衡了检测精度和速度,能够满足全天候高精度实时检测多尺度轨道入侵异物的实际应用需求。

3.5 模型在嵌入式设备中的性能测试

本文在 NVIDIA Jetson Xavier NX 中进行算法的嵌入式移植,并使用 TensorRT 加速进一步优化模型的检测速度。表 5 展示了 YOLOv5s、YOLOv6s、YOLOv7、YOLOv5x 和本文所提出的 LGF-Net 模型在嵌入式平台中对轨道交通数据集的测试结果,评价指标为平均检测精度和检测速度,最优结果用加粗黑体标出。

表 5 不同模型嵌入式部署性能测试结果
Table 5 Embedded deployment performance test results of different models

类别	模型				
	YOLOv5s	YOLOv6s	YOLOv7	YOLOv5x	LGF-Net
优化前检测精度/%	91.84	92.51	93.69	94.73	94.93
优化后检测精度/%	91.87	92.48	93.70	94.71	94.95
优化前检测速度/fps	21	16	5	6	18
优化后检测速度/fps	40	35	12	14	38

实验结果表明,TensorRT 能够在模型检测精度基本维持不变的情况下,大幅度提升模型在嵌入式平台中的检测速度,且 LGF-Net 在 NVIDIA Jetson Xavier NX 上实现了 94.95%的检测精度和 38 fps 的检测速度,能够高精度实时检测实际轨道环境中的入侵异物。在嵌入式移植及 TensorRT 加速优化后,LGF-Net 的检测精度和速度分别比 YOLOv6s 高了 2.47%和 3 fps,检测性能更为优越。

相比于 YOLOv5s,本文所提出的 LGF-Net 模型在损失极小检测速度的前提下获得了 3.08%的精度提升,更利于精准鲁棒地检测轨道目标。YOLOv5x 和 YOLOv7 取得不错的检测精度,但二者检测速度过低,无法满足轨道异物检测的实时性要求。总之,LGF-Net 在嵌入式平台中取得了最优的检测结果且检测速度较快,能够满足轨道场景的实际应用需求。

4 结 论

针对轨道入侵异物检测领域存在的现有问题,本文提出了一种全天候高精度实时轨道入侵异物检测模型并研制小型轨道入侵异物智能检测系统,能够在实际复杂轨道环境中全天候高鲁棒性检测多尺度轨道入侵异物,进而确保行车安全。本文的贡献可以总结为如下两个方面:

1) 本文提出了一种全天候高精度实时轨道入侵异物检测模型LGF-Net,实现了在复杂轨道环境中精准高效的检测多尺度轨道入侵异物,尤其是小目标异物。实验结果表明,LAM-Net的检测精度、速度和计算量分别为94.93%、132 fps和12.7 GFLOPs,在保证模型轻量化和实时检测的基础上取得了最优的检测精度。其平均检测精度比YOLOv5s和YOLOv6s分别高3.09%和2.42%,尤其是对于小目标安全帽和扳手的检测精度比YOLOv5s高1.66%和4.01%;在检测速度方面,LGF-Net在取得最优检测结果的前提下,检测速度分别为YOLOv5x和YOLOv7的3.1和3.4倍,实时性提升巨大。此外,鲁棒性检验和泛化性实验结果表明,LGF-Net在恶劣气候等复杂轨道环境中仍能保持高性能检测多尺度目标,满足复杂轨道场景在实际应用需求。

2) 本文将检测模型嵌入式移植至NVIDIA Jetson Xavier NX中并使用TensorRT进行加速,大幅度提升了模型在嵌入式平台中的检测速度。LGF-Net的检测精度和速度分别为94.95%和38 fps,比YOLOv6s高了2.47%和3 fps,在保证模型实时性的基础上检测精度优于现有的其他目标检测模型,验证了实时预警系统的可行性。此外,本文将上述嵌入式平台、星光相机和语音报警器等集成,研制小型全天候轨道入侵异物智能检测样机,该样机具备小型化、智能化和实用化的特点,能够在低光照环境中清晰捕获多尺度轨道入侵异物的特征纹理,满足实际复杂轨道环境中的辅助驾驶需求,进而确保行车安全。

3) 扩充轨道交通数据样本库所涵盖的入侵异物类别、与增量学习等方式进行结合使得LGF-Net具备终身学习的能力是本文下一阶段的工作重点。

参考文献

[1] 龙陵波, 赵宏, 杨聪, 等. 铁路道岔参数机器视觉在位测量方法与装置[J]. 电子测量与仪器学报, 2023, 37(4): 80-89.

LONG L B, ZHAO H, YANG C, et al. Machine-vision based method and apparatus for in-situ measurement of railway turnout parameters [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(4): 80-89.

[2] TIAN R, SHI H, GUO B Q, et al. Multi-scale object detection for high-speed railway clearance intrusion[J]. Applied Intelligence, 2021(8): 1-16.

[3] PARK M S, EOM J K, CHOI J, et al. Analysis of the railway accident-related damages in south korea [J]. Applied Sciences, 2020, 10(24): 8769.

[4] RISTI-DURRANT D, FRANKE M, MICHELS K. A review of vision-based on-board obstacle detection and distance estimation in railways [J]. Sensors, 2021, 21(10): 34-52.

[5] GUAN L, JIA L, XIE Z, et al. A lightweight framework for obstacle detection in the railway image based on fast region proposal and improved YOLO-tiny network [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71(1): 1-16.

[6] 同磊, 朱力强, 余祖俊, 等. 基于车载前视摄像机的轨道异物检测[J]. 交通运输系统工程与信息, 2012, 12(4): 79-83.

TONG L, ZHU L Q, YU Z J, et al. Railway obstacle detection using onboard forward-viewing camera [J]. Journal of Transportation Systems Engineering and Information Technology, 2012, 12(4): 79-83.

[7] 陈超, 沈飞, 严如强. 改进LSSVM迁移学习方法的轴承故障诊断[J]. 仪器仪表学报, 2017, 38(1): 33-40.

CHEN CH, SHEN F, YAN R Q. Enhanced least squares support vector machine based Transfer learning strategy for bearing fault diagnosis [J]. Chinese Journal of Scientific Instrument, 2017, 38(1): 33-40.

[8] RODRIGUZE A, URIBE J, BONILLA J. Obstacle detection over rails using hough transform [C]. 2012 XVII Symposium of Image, Signal Processing, and Artificial Vision (STSIVA), 2012: 317-322.

[9] 李艳获, 徐熙平, 钟岩. 特征弦约束随机Hough变换在椭圆检测中的应用[J]. 仪器仪表学报, 2017, 38(1): 50-56.

LI Y D, XU X P, ZHONG Y. Application of RHT based on character string constraint in ellipse detection [J]. Chinese Journal of Scientific Instrument, 2017, 38(1): 50-56.

[10] 宁正, 牛宏侠, 张肇鑫. 基于改进混合高斯模型的铁轨异物入侵检测方法[J]. 传感器与微系统, 2021, 40(5): 146-149.

NING ZH, NIU H X, ZHANG ZH X. Rail foreign object intrusion detection method based on improved mixed

- gaussian model [J]. Transducer and Microsystem Technologies, 2021, 40(5): 146-149.
- [11] LI H, HUANG Y, ZHANG Z. An improved faster R-CNN for same object retrieval[J]. IEEE Access, 2017, 5(1): 13665-13676.
- [12] REN S, HE H, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [13] 马志程, 李 丹, 张宝龙. 基于改进 Mask R-CNN 的光学元件划痕缺陷检测研究[J]. 电子测量与仪器学报, 2023, 37(4): 231-239.
- MA ZH CH, ZHANG D, ZHANG B L, et al. Research on scratch defect detection of optical elements based on improved Mask R-CNN [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37 (4): 231-239.
- [14] 徐岩, 陶慧青, 虎丽丽. 基于 Faster R-CNN 网络模型的铁路异物侵限检测算法研究[J]. 铁道学报, 2020, 42(5): 91-98.
- XU Y, TAO H Q, HU L L. Railway foreign body intrusion detection based on Faster R-CNN network model[J]. Journal of the China Railway Society, 2020, 42(5): 91-98.
- [15] 张丽艳, 韩熠, 赵艺璇, 等. 霍夫变换和 Faster-RCNN 轨道上行人检测方法[J]. 大连交通大学学报, 2020, 41(2): 100-103.
- ZHANG Y L, HAN Y, ZHAO Y X, et al. Hough transform and Faster-RCNN method for detecting pedestrians on rails [J]. Journal of Dalian Jiaotong University, 2020, 41(2): 100-103.
- [16] LIU W, ANGUELOV D, ERHAN C, et al. SSD: Single shot multibox detector [C]. European Conference on Computer Vision (ECCV), 2016: 21-37.
- [17] REDMON J. You only look once: Unified, real-time object detection[C]. Conference on Computer Vision and Pattern Recognition (CVPR), 2015: 779-788.
- [18] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection[J]. ArXiv Preprint, 2020, ArXiv: 2004.10934.
- [19] GE Z, LIU S, WANG F, et al. YOLOX: Exceeding YOLO series in 2021[J]. ArXiv Preprint, 2021, ArXiv: 2107.08430, 2021.
- [20] LI C Y, LI L L, FENG Y F, et al. YOLOv6: A single-stage object detection framework for industrial applications [J]. ArXiv Preprint, 2023, ArXiv: 2301.05586.
- [21] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7464-7475.
- [22] GUO B, SHI J, ZHU L, et al. High-speed railway clearance intrusion detection with improved SSD network[J]. Applied Sciences, 2019, 9 (15): 2981-3001.
- [23] YE T, ZHAO Z Y, WANG S A, et al. A stable lightweight and adaptive feature enhanced convolution neural network for efficient railway transit object detection[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(10): 17952-17965.
- [24] YE T, ZHANG J, ZHAO Z Y, et al. Foreign body detection in rail transit based on a multi-mode feature enhanced convolutional neural network [J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(10): 18051-18063.
- [25] 叶 涛, 赵宗扬, 郑志康. 基于 LAM-Net 的轨道侵入界异物自主检测系统[J]. 仪器仪表学报, 2022, 43(9): 206-218.
- YE T, ZHAO Z Y, ZHENG ZH K. Research on the autonomous detection system for railway intrusion obstacles based on LAM-Net [J]. Chinese Journal of Scientific Instrument, 2022, 43(9): 206-218.
- [26] TIAN R, SHI H, GUO B, et al. Multi-scale object detection for high-speed railway clearance intrusion[J]. Applied Intelligence, 2021, 8(4): 1-16.
- [27] HE D, QIU Y, MIAO J, et al. Improved Mask R-CNN for obstacle detection of rail transit[J]. Measurement, 2022, 190(28): 1-10.
- [28] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An image is worth 16×16 words: Transformers for image recognition at scale [C]. International Conference on Learning Representations, 2021.
- [29] SONG F, ZHANG S, LEI T, et al. MSTDSNet-CD: Multiscale swin transformer and deeply supervised network for change detection of the fast-growing urban regions [J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19(1): 1-5.
- [30] WANG C, MARK L, WU H, et al. CSPNet: A new

backbone that can enhance learning capability of CNN[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), 2020: 1571-1580.

- [31] LIANG X, HAN F. MFL image recognition method of pipeline corrosion defects based on multilayer feature fusion multiscale ghostNet[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71(1): 1-8.
- [32] YE T, ZHANG X, ZHANG Y, et al. Railway traffic object detection using differential feature fusion convolution neural network[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 22(3): 1375-1387.
- [33] YE T, ZHANG Z H, ZHANG X, et al. Autonomous railway traffic object detection using feature-enhanced single-shot detector[J]. IEEE Access, 2020, 8(1): 145182-145193.
- [34] LI J, ZHOU F Q, YE T. Real-world railway traffic detection based on faster better network[J]. IEEE Access, 2018, 6(1): 68730-68739.

作者简介



赵宗扬, 2020 年于中国矿业大学(北京)获得学士学位, 2023 年于中国矿业大学(北京)获得硕士学位, 现于天津大学仪器科学与技术专业攻读博士学位, 主要研究方向为深度学习、目标检测和轨道交通等。

E-mail: azhaozongyang@163.com

Zhao Zongyang received his B.Sc. degree from China University of Mining and Technology (Beijing) in 2020, and received his M.Sc. degree from China University of Mining and Technology (Beijing) in 2023. He is currently pursuing his Ph.D. degree in the Department of Instrumentation Science and Technology at Tianjin University. His main research interests include deep learning, object detection and rail transit.



康杰虎(通信作者), 2010 年、2013 年和 2021 年在天津大学分别获得学士、硕士和博士学位, 现为天津大学仪器科学与技术专业博士后, 主要研究方向为计算机视觉、视觉测量等。

E-mail: kangjiehu_305@tju.edu.cn

Kang Jiehu (Correspondence author) received his B.Sc., M.Sc., and Ph.D. degrees all from Tianjin University in 2010, 2013, and 2021, respectively. He is currently a postdoctoral

fellow with the Department of Instrumentation Science and Technology at Tianjin University. His main research interests include compute vision and vision measurement technology.



梁健, 2021 年于哈尔滨工程大学获得学士学位, 2023 年于天津大学获得硕士学位, 现于天津大学仪器科学与技术专业攻读博士学位, 主要研究方向为深度学习、三维测量等。

E-mail: liangjian@tju.edu.cn

Liang Jian received his B.Sc. degree from Harbin Engineering University in 2021, and received his M.Sc. degree from Tianjin University in 2023. He is currently pursuing his Ph.D. degree in the Department of Instrumentation Science and Technology at Tianjin University. His main research interests include deep learning and three-dimensional measurement.



叶涛, 2009 年于中国矿业大学获得学士学位, 2012 年于中国矿业大学(北京)获得硕士学位, 2016 年于北京航空航天大学获得博士学位, 现为矿业大学(北京)机械电子与信息工程学院的高级工程师, 主要研究方向为深度学习、计算机视觉等。

E-mail: ayetao198715@163.com

Ye Tao received his B.Sc. degree from China University of Mining and Technology in 2009, received his M.Sc. degree from China University of Mining and Technology (Beijing) in 2012, and received his Ph.D. degree from Beijing University of Aeronautics and Astronautics in 2016. He is currently a senior engineer in the School of Mechanical Electronics and Information Engineering at University of Mining and Technology (Beijing). His main research interests include deep learning and compute vision.



吴斌, 1997 年和 2002 年在天津大学分别获得学士和博士学位。现为天津大学仪器科学与技术专业的教授, 主要研究方向为目标检测、视觉测量等。

E-mail: wubin@tju.edu.cn

Wu Bin received his B.Sc. and Ph.D. degrees both from Tianjin University in 1997 and 2002, respectively. He is currently a professor with the Department of Instrumentation Science and Technology at Tianjin University. His main research interests include object detection and vision measurement technology.