文章编号:1671-4598(2025)06-0067-09 DOI:10.16526/j.cnki.11-4762/tp.2025.06.009

:TP391.41 文献标识码:A

基于机器视觉和边云协同的 道岔缺口检测方法

钱智坤,曹炳尧,吴雅婷

(上海大学 通信与信息工程学院,上海 200444)

摘要:针对目前道岔缺口检测精确度低、鲁棒性差、难以满足边缘计算设备性能要求等问题,提出了一种基于机器 视觉和边云协同的道岔缺口检测方法;采用 YOLOv8 算法对缺口和检测柱进行高效目标检测,并通过图像处理技术精确 获取边缘信息,以计算缺口的偏移量;实验结果表明,该方法在正常和摄像头抖动情况下均展现出优越的检测性能,平均误差控制在 0.1 mm 以内,满足铁路现场实际工程上的应用;采用边云协同的工作模式显著提升了数据处理效率,优化了资源使用,降低了对单一计算节点的依赖,单次处理平均耗时在 59.16 ms,相比单独依靠边缘设备平均耗时降低 了 48.99%。

关键词:道岔缺口检测;深度学习;YOLOv8;边云协同;图像处理;自动化

A Switch Gap Detection Method Based on Machine Vision and Edge & Cloud Collaboration

QIAN Zhikun, CAO Bingyao, WU Yating

(School of Communication and Information Engineering, Shanghai University, Shanghai 200444, China)

Abstract: Aiming at the problems of low accuracy, poor robustness and difficulty in meeting the performance requirements of edge computing equipment in turnout gap detection, a turnout gap detection method based on machine vision and edge and cloud collaboration is proposed; The YOLOv8 algorithm is used to efficiently detect gaps and detection columns, and the edge information is accurately obtained through image processing technology, which calculates the offset of gaps; Experimental results show that this method exhibits superior detection performance under normal and camera shaking conditions, with an average error controlled within 0.1 mm, which meets the practical application in railway field engineering; The edge and cloud collaboration significantly improves data processing efficiency, optimizes resource utilization, and reduces dependence on a single computing node. The average processing time for a single transaction is 59.16 ms, which is 48.99% lower than that of relying solely on edge devices.

Keywords: turnout gap detection; deep learning; YOLOv8; edge and cloud collaboration; image processing; automation

0 引言

铁路作为国家重要的交通命脉,承担着巨大的客货运输量,是经济发展和区域联通的关键。根据中国国家铁路局发布的《2022年铁道统计公报》,2022年全国铁路货运总发送量完成49.8亿吨,全国运送旅客量达16.73亿人次^[1],这一庞大的数字不仅彰显了铁路运输

的繁忙程度,也对铁路系统的稳定性和防护措施提出了 前所未有的考验^[2],确保铁路运输安全,提升铁路系统 的可靠性和安全性,对于维护社会秩序和推动经济发展 具有至关重要的作用^[3]。其中,道岔作为铁路轨道的重 要组成部分,是实现铁路轨道间转换的关键连接设 备^[4],而转辙机作为控制道岔转换的核心设备,其性能 和可靠性直接关系到道岔转换是否顺利^[5]。如果转辙机

收稿日期:2024-05-09; 修回日期:2024-06-18。

作者简介:钱智坤(1999-),男,硕士研究生。

吴雅婷(1984-),女,博士,副教授。

通讯作者:曹炳尧(1985-),男,博士,高级实验师。

引用格式:钱智坤,曹炳尧,吴雅婷.基于机器视觉和边云协同的道岔缺口检测方法[J].计算机测量与控制,2025,33(6):67-75.

工作发生故障,可能会导致列车脱轨等严重事故^[6]。因此,保证转辙机的正常工作是确保铁路运输安全有效运行的前提条件^[7]。

转辙机缺口是评估转辙机运行状况的关键指标,它 能够间接显示道岔在定位和反位状态之间转换时尖轨与 基本轨的密合程度。通过测量间隙的大小,可以有效地 判断道岔的转换是否顺畅。在早期,铁路维护通常依赖 于定期的人工巡检^[8],工作人员通过视觉检查或使用特 定的检测工具来手动检测转辙机的间隙。这种方法存在 诸多不足,包括在夜间进行检测时的误差较大、实时监 控能力不足、工作量庞大以及效率低下等问题,无法满 足铁路运行的要求,迫切需要实时在线的缺口检测系 统。如今转辙机缺口检测的方法主要借助传感器实现, 分为直接检测和间接检测两类[9],直接检测方法一般通 过在转辙机的内部安装物理传感器,主要包括了接触式 导电触头传感器检测方法^[10]、非接触磁电式传感器检 测方法[11]、光电式检测方法[12]等,对相关参数进行测 量,如电压、电流、功率等,但是这种方式在很大程度 上受温度和磁场的干扰,存在明显的局限性。间接检测 方法也称基于图像处理的检测方法[13],通常涉及到在 转辙机内部安装摄像头以捕获缺口图像,应用图像处理 技术对这些图像进行分析。这种方法能够在一定程度上 克服传统直接检测方式的缺陷,并且由于其对环境条件 的依赖性降低,因此具有更高的稳定性和可靠性。目前 已有许多研究者对基于图像处理技术的铁路道岔缺口检 测系统实现方案展开研究。文献 [14] 通过应用图像处 理技术(如 Sobel 边缘检测和小面积删除法等)提取缺 口的特征曲线,并据此计算出缺口的具体尺寸。文献 「15 采用自适应阈值分割技术,实现了低算力应用场 景下的下的转辙机缺口检测。文献 [16] 结合了自适应 小波去噪与数学形态学,开发了一种高效的缺口边缘检 测方法。文献 [17] 采用了 Canny 算子进行边缘识别, 并结合 Hough 变换技术对岔尖图像进行分析, 以此来 确定道岔尖轨是否达到了紧密贴合的状态。文献[18] 使用高斯滤波、阈值分割、形态学凸壳和亚像素精度轮 廓等算法提取缺口边缘特征,从而得出缺口位置大小, 实现转辙机缺口状态的实时在线检测。文献[19]采用 了图像处理技术来识别和测量转辙机的缺口位置。通过 亮度调整和去噪等图像优化手段处理图像,并将处理后 的图像数据与预设标准进行比较,以准确评估转辙机缺 口的实际状态。文献「20]采用高清摄像头采集图像数 据,并将图像数据通过网络实时上传到室内检测主机, 对图像分析处理和计算得到转辙机缺口大小或缺口偏移 量大小。文献「21]采用一种基于超像素的快速模糊聚 类算法,用于对缺口图像进行精确分割,这种方法避免 了在表示杆上附加额外标记物的需要,同时也减少了因 标记物粘贴不当而可能引入的误差。文献[22]提出了 基于数量统计的边缘检测优化算法,以便提高缺口检测 精度。文献[23]提出一种基于 FPGA (Field Programmable Gate Array)的转辙机表示缺口检测模块设 计方案,图像数据无需缓存即可处理,该方案速度快且 精度高。文献[24]提出了基于机器视觉的转辙机缺口 检测方法,通过降低图像信号维度,快速获取转辙机缺 口数值。然而,传统基于图像处理的方法存在着以下几 点问题:

 1)传统的图像处理方法难以处理转辙机复杂的内 部环境,很容易受到环境光照的影响,难以精确地对缺 口进行定位和识别,检测精度不高。

2)在实际工程应用中,传统的图像处理方法由于 检测精度不高,往往需要结合人工通过标定软件提前标 定的预处理步骤进行处理。人工标定的数据是固定的, 不能根据转辙机内部和摄像头位置的实际情况的变化而 自动改变,需要人工不定期的进行重新标定和维护,若 因为列车行驶经过道岔引发的转辙机的震动导致摄像头 位置发生改变,则原本标定的数据失效,需重新进行人 工标定。这种方法既浪费了人力资源,又存在鲁棒性差 的问题。

3)在实际铁路公司的实现场景中,用于承担处理 缺口检测任务的计算设备往往是机械室内的上位机,而 这种上位机由于历史原因其计算能力较差,既无法承担 较为复杂的图像处理算法的计算任务,更无法承担深度 学习神经网络的推理任务,而目前研究中提出的图像处 理或深度学习的算法往往对于这些边缘计算设备来说过 于复杂,在这种设备上进行实时运行难度较大,同时若 考虑大规模地更换这些边缘计算设备也存在成本较高的 问题。

为了解决上述问题,我们引入了深度学习和边云协 同的创新解决方案,该方法利用深度学习模型强大的特 征学习能力,通过目标检测直接定位特征,节省了人工 定位特征的流程,显著提升了检测的自动化程度和精确 性,简化和改善后续图像处理算法的难度和复杂程度, 并且通过边缘云和边云协同架构的设计,解决了因深度 学习算法而带来的在边缘端的计算负担较大和资源消耗 较多的问题,为未来轻量化部署奠定了基础。

1 道岔与转辙机缺口检测问题描述

1.1 道岔概述

道岔一般安装在铁路站场的上下行咽喉区,由基本 轨、尖轨、合拢轨、护轨和辙叉组成。其中,只有两根 尖轨可以移动,其余部件均被固定在线路上。道岔工作 状态如图1所示。

当道岔正常工作时,必须保证道岔两根尖轨中的一



图1 道岔工作状态示意图

根与基本轨密贴,而另一根与基本轨分离。若尖轨1与 基本轨1密贴而尖轨2与基本轨2分离,道岔便会开通 正向。驶入的列车会在道岔基本轨、尖轨1、合拢轨和 辙叉的引导下正向驶入站内的1股道。若尖轨1与基本 轨1分离而尖轨2与基本轨2密贴,道岔便会开通侧向 并引导列车侧向驶入站内的3股道。但是,若无法保证 道岔两根尖轨中的一根与基本轨密贴,导致道岔两侧尖 轨均不能与基本轨密贴,道岔便会发生故障。此时,如 果有列车驶入,其车轮便会与道岔尖轨发生碰撞或挤进 道岔尖轨基本轨间的缝隙,造成列车脱轨和倾覆的严重 行车事故,导致人员伤亡和财产损失。因此,对尖轨与 基本轨的闭合程度的检测对铁路的安全性与稳定性至关 重要。

1.2 转辙机概述

由于 S700K 型转辙机应用广泛,本研究以 S700K 型 转辙机为例,探讨了其在铁路道岔系统中的关键作用。

S700K型转辙机的表示缺口工作原理涉及锁块、接 点组和指示标之间的相互作用。如图2所示,当左侧尖 轨与基本轨密贴时,右侧锁块弹出而左侧锁块缩入,形 成下检测杆的表示缺口,此时速动开关组的第1系和第 3系接点组接通,电路指示尖轨密贴状态。若两侧尖轨 均未密贴,则锁块均缩入,无表示缺口形成,第1系和 第4系接点组接通,电路指示道岔未锁闭。当右侧尖轨 密贴时,右侧锁块缩入而左侧锁块弹出,形成上的表示 检测杆缺口,第2系和第4系接点组接通,电路指示右 侧尖轨密贴。这一过程通过速动开关组的接点组状态变 化实现对道岔位置的实时监测和控制。因此,只要测量



出转辙机缺口大小,就可以计算出道岔的闭合程度。

2 缺口与检测柱目标检测算法设计

2.1 基于 YOLOv8 网络的缺口与检测柱目标识别

在道岔缺口检测的任务中,需要检测目标的为缺口 和检测柱。随着目标检测技术的发展,YOLO系列模 型已成为业界的佼佼者,其精度和识别速度均表现优 异,且在不断地迭代更新版本,技术非常成熟,在工程 应用中非常流行。因此,本文选择YOLO系列。如今, YOLO相继推出了YOLOv5、YOLOv7和YOLOv8等。 其中,YOLOv8不仅继承了系列算法在实时性、精确度 及多尺寸目标捕捉方面的优势,还通过引入创新技术和 优化策略,实现了性能的显著提升。YOLOv8将目标检 测流程简化为一个回归问题,通过单阶段检测框架避免 了传统多阶段检测器中的复杂区域提议步骤,实现了在 计算效率与检测精度上的优化平衡。YOLOv8的创新之 处在于采用了自适应锚框和特征融合技术,进一步提升 了检测的准确度。同时,它支持多样化的网络架构,以 适应多变的应用环境。

YOLOv8 目标检测模型的具体结构如图 3 所示。



图 3 YOLOv8 结构图

本文采集大量的道岔缺口图像,包括不同环境条件 下的缺口图像,如不同的摄像头、光线和机器内部环境 等。使用 Qt 编写的标注工具 LabelImg 对缺口图像的训 练集和验证集进行缺口标注,可生成 YOLO 系列模型 训练所需的标签,其中用于训练的图片 8 800 张,用于 验证的图片 792 张,用于测试的图片 528 张。

在训练集中,由于考虑到在道岔转辙机复杂的内部 环境中,光线和噪声等环境因素会极大影响处理性能, 本文使用图像增强技术,如图像增强、增加噪音、颜色 变换、光线变换、Mosaic数据增强等,增加数据多样性,提高模型的泛化能力。

本文采用了几个关键的评价指标来衡量目标检测的 准确性,包括平均精度(mAP, mean Average Precision)、精确率(Precision)、召回率(Recall)以及 F_1 分数(F_1 -score)。这些指标共同提供了对检测系统性能 的全面评估,确保了检测结果的可靠性和有效性。计算 公式如公式(1)~(3)所示:

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

$$Recall = \frac{TP}{TP + FN}$$
(2)

$$F_{1} = \frac{2 \times Precision \times Recall}{Precision + Recall}$$
(3)

式中, TP 为模型正确地将正类样本预测为正类的数量, FP 为模型错误地将负类样本预测为正类的数量, FN 为 模型错误地将正类样本预测为负类的数量。

mAP的计算公式如公式(4)(5)所示:

$$AP = \int_{0}^{1} P(R) \,\mathrm{d}R \tag{4}$$

$$mAP = \frac{\sum_{i=0}^{c} AP(c)}{C}$$
(5)

式中, P 为当前检测类别的准确率, R 为当前检测类别的召回率, C 为类别个数。

2.2 基于快速图像处理的缺口与检测柱边缘检测

通过目标检测算法识别检测柱和缺口后,还需要进 一步通过图像处理的方式精准获取检测柱和缺口的边缘 信息,从而计算缺口的偏移量。处理流程如图4所示。



图 4 图像处理流程

由于边缘设备计算能力羸弱,为了提高处理效率和 节约计算资源,我们采用了图像裁剪技术,专注于图像 的核心区域并排除边缘可能引入的噪声或不相关背景, 减少计算量。具体而言,我们的目标是从目标图像中裁 剪出位于中心的若干行像素。该过程涉及确定裁剪区域 的边界坐标,这些坐标基于图像的尺寸和所需裁剪区域 的大小。裁剪过程和效果如图 5 所示。

为了简化图像处理的复杂度并专注于图像的纹理和 轮廓信息,我们对选定的图像执行了灰度化处理。灰度 化,也称为灰阶化,是一种将彩色图像转换为单通道图 像的过程,它通过合并彩色图像的红色、绿色和蓝色通 道来创建。灰度化不仅减少了计算量,而且对于某些视 觉任务,如边缘检测和形状识别,提供了足够的信息。



图 5 图像载剪效果

对于标准的 RGB 色彩空间, 灰度图像? 可以通过 以下加权公式从原始 RGB 图像中计算得出:

 $I_{\rm gray} = 0.298 \; 9 \times I_R + 0.587 \; 0 \times I_G + 0.114 \; 0 \times I_B$ (6)

其中: I_R 、 I_G 、 I_B 分别为图像的红色、绿色和蓝色 通道的强度值。

边缘保留滤波(EPF, edge preserving filter)是一种在去除噪声的同时保留图像边缘信息的图像处理技术。实现EPF的方法有多种,其中两种常见的方法是高斯双边滤波(Bilateral Filter)和均值迁移滤波(MeanShift Filter)。本文使用高斯双边滤波进行进行图像去噪处理,原因在于其独特的边缘保留特性,能够在平滑噪声的同时保留图像的重要边缘信息。

高斯双边滤波器的输出像素值是通过对输入图像中 的像素值进行加权平均得到的,其中权重由空间域的高 斯函数和强度域的高斯函数共同决定。经过 EPF 滤波 后的效果如图 6 所示。



图像二值化是将图像转换为仅包含两种像素值的过程,通常是黑白。在二值化图像中,像素值通常为0(黑色)和255(白色),但也可以是其他表示黑白的值。二值化是图像处理和计算机视觉中的一项基本技术,常用于简化图像、强调边缘和轮廓、或为进一步的图像分析做准备。对于一个给定的灰度图像*I*,其中每

个像素的灰度值范围在 [0, *L*-1] (*L* 通常是 256, 对 于 8 位图像), 二值化操作可以用公式 (7) 表示:

$$B(x,y) = \begin{cases} 255 & \text{if } I(x,y) > T\\ 0 & \text{if } I(x,y) \leqslant T \end{cases}$$
(7)

其中: B(x,y) 为二值化图像在坐标 (x,y) 处的像 素值, I(x,y) 为原始灰度图像在坐标 (x,y) 处的像素 值, T 为二值化的阈值, 是一个介于 0 和 L - 1 之间的 常数。

经过二值化处理后,效果如图7所示。



闭运算(Closing Operation)是形态学图像处理中的一种基本操作,它通过先膨胀后腐蚀的顺序来实现。 闭运算的目的是填充小的空洞、断裂线条、移除小物体,以及平滑较大物体的边界。闭运算的效果如图 8 所示。



图 8 闭运算效果

可以看到闭运算去掉了两边的黑色噪点。

Canny 边缘检测算法由 Canny 于 1986 年提出^[25], 它是一种基于梯度的多阶段算法,被广泛应用于图像边 缘检测领域。Canny 算法的核心在于其能够识别图像中 边缘的细微变化,同时具有良好的方向响应和噪声抑制 特性。

Canny 边缘检测效果如图 9 所示。



统计缺口的边缘所在位置的平均坐标,作为缺口的 边缘,计算两个边缘中心线,得出缺口的中心线位置, 同理可得出检测柱的中心线位置,结果如图 10 所示。



图 10 检测结果

假设缺口物理宽度为 wp_s,检测柱物理宽度为 wp_d,缺口两个边缘的像素横坐标值为 l_s,r_s,检测柱两个边缘的像素横坐标值为 l_d,r_d,图像像素宽度 w_{image} 为则根据摄像头成像原理和几何关系可得,物理缺口偏移量如公式(8)所示:

 $v = \frac{wp_{g}}{r_{g} - l_{g}} \times \frac{r_{g} + l_{g} - w_{\text{image}}}{2} - \frac{wp_{d}}{r_{d} - l_{d}} \times \frac{r_{d} + l_{d} - w_{\text{image}}}{2}$ (8)

2.3 边缘云与边云协同

我国致力于云服务与边缘计算服务的协同发展, 这 两者在数字化基础设施中扮演着至关重要的角色。云计 算作为数字化新基建的核心,象征着未来的发展方向和 先进的生产力。在现代工业自动化和智能监控系统中, 边云协同架构发挥着不可替代的作用。其中,边缘计算 作为这一架构的前沿技术,负责对原始图像数据进行初 步处理,而云计算则承担着执行更为复杂的深度学习推 理任务。两者的协同工作,对于提升系统性能和效率至 关重要。云计算是一种集中式的资源管理模式,它涉及 到软硬件资源的管理、调度和销售。随着 5G、物联网 以及云应用的快速发展,数据量呈现出爆炸性增长,这 要求终端侧能够提供"大连接、低时延、大带宽"的云 资源。为了应对这一挑战,边缘云应运而生。边缘云是 由大量地域分散的边缘云节点组成的分布式云系统,通 常部署在数据流量密集的"热点"区域,如铁路道岔转 换的机械室等关键位置。每个边缘云节点都包含计算、 存储和网络功能,而多个节点则可以联合起来,形成一 朵完整的云。边缘云本质上依然是"云", 它继承了云 计算的所有核心特性,包括资源的池化管理、弹性伸缩 能力以及高度的可靠性和安全性。除此之外,边缘云还 具有低延迟和终端云化的优势,这使得它能够更好地满 足实时性和本地化处理的需求。当边缘云与人工智能等 先进技术相结合时,它可以在多个行业中发挥巨大的作 用,为产业带来显著的价值。

本研究中,我们采用了边缘云和边云协同的方法, 以实现对道岔缺口图像的高效检测,处理流程如图 11 所示。



图 11 边云协同架构与流程

首先,边缘端设备负责采集高分辨率的图像数据, 并进行预处理,包括图像裁剪、缩放和格式转换等,以 优化网络传输的效率。这些轻量级的图像处理任务在边 缘端迅速完成,确保了数据的实时处理和低延迟响应。

接着,预处理后的图像数据通过 HTTP 协议安全 地传输至云平台。云计算的核心优势在于其强大的计算 能力,它能够运行深度学习模型,进行高精度的目标检 测。在本研究中,云端部署了定制的深度学习网络,用 于识别图像中的缺口和检测柱。通过深度学习推理,云 端能够准确地定位目标位置,并将这些信息以结构化数 据的形式发送回边缘端。

最后,边缘端设备接收到云端的推理结果后,进一步执行必要的图像处理任务。这一过程不仅提高了数据 处理的效率,而且通过分布式计算优化了资源的使用, 降低了对单一计算节点的依赖。

边云协同的工作模式为实时图像分析和目标检测提 供了一种创新的解决方案。通过将计算任务合理分配给 边缘端和云端,我们不仅实现了对图像数据的快速响 应,还确保了深度学习模型的充分利用,从而在保持高 准确性的同时,也满足了实时性的需求。

3 实验结果与分析

3.1 数据集

本文使用的数据集为和某铁路公司项目合作采集, 用于训练的图片 8 800 张,用于验证的图片 792 张,用 于测试的图片 528 张。

3.2 实验环境

本文使用的操作系统是 Windows 11, 使用 Pytorch 作为深度学习的框架。边缘云模拟实验环境采用携带轻 量专用 GPU 的计算机,如表 1 所示。边缘设备模拟实 验环境采用 CPU 性能叫贫弱且不携带专用 GPU 的计算机,如表 2 所示。这种实验环境的设置能更好地模拟现场环境的真实情况。

表 1 边缘云模拟实验环境			
类别	配置		
中央处理器	Intel $(\mathbb{R}$ core TM i5 - 8300 HCPU @2.30 GHz 16 GB		
图形处理器	GeForce RTX 1050ti 4 GB		
系统环境	Windows11		
4 2 70	Pytorch2. 2. 0+cu121		
世栄	SpringCloud		
编程语言	Python3. 9		
畑住店百	Lawa IDK1 0		

表 2	边缘设备模拟实验环境
12 4	23 0 田 大 10 大 迎 2 3

类别	配置
中央处理器	Intel®core [™] i5−6500CPU @3. 20GHz 16GB
图形处理器	Intel®HDGraphics 530
系统环境	Windows10
框架	Opencv
编程语言	Python3. 9

3.3 模型训练过程

在训练阶段,优化器采用随机梯度下降(SGD), 初始学习率 *lr*0 为 0.01,最终学习率为 *lrf* 为 0.01,动 量因子 momentum 为 0.937,权重衰减系数为 0.000 5, 输入图像分辨率设置为 640 px×640 px,批尺寸 batch size 为 16,使用 YOLOv8n 在缺口数据集上训练,为获 得泛化能力,防止出现过拟合现象,在训练过程中引入 了早停方法。在训练过程中使用 Mosaic 增强,能有效 地增加模型的泛化能力,如图 12 所示。



图 12 Mosaic 增强训练

3.4 测试及分析

将测试集输入训练后的检测模型,YOLOv8 模型的 测试结果如表 3 所示。模型的测试结果很好,可以胜任 缺口检测任务。

表 3 模型测试结果

模型	大小/MB	mAP50	<i>mAP</i> 50 : 95
YOLOv8n	5.95	0.995	0.992 75

图 13 为利用 YOLOv8 模型进行缺口和检测柱检测 的可视化结果,图中方框标记出缺口和检测柱的区域, 由此可见,利用该方法可以准确检测图片中所有的缺口 和检测柱。



图 13 缺口和检测柱检测效果

3.5 图像处理功能验证

使用 opencv 库对算放进行验证,选取代表性图片 投入程序中,得出结果如图 14 所示。

将缺口和检测柱图像经算法处理后,能够得到很好 的边缘提取效果。因此利用本文提出的图像处理算法, 能够有效地检测到缺口和检测柱边缘位置,算法具备有 效性。

3.6 检测性能验证

为了进一步验证本方法的实际性能,本文对测试集 图片进行了检测,并且人为模拟摄像头发生抖动导致的 偏移情况,通过人工激光测距仪器的校验实验结果与实 际结果的误差,本文方法检测性能相较于传统的人工标 注处理框的方法检测性能的实验结果如表4所示。

实验情况	方法	误差/mm
工告	人工标注方法	0.091
正市	本文方法	0.092
再确认先开料动	人工标注方法	0.278
城傢大及生件列	本文方法	0.097

表 4 方法检测性能结果

通过人工标注方法与本文方法的比较结果,在正常 情况下两者检测的误差相差不多,都能正常工作,但在



摄像头发生抖动导致位置发生变化时,原有方法检测性 能下降较为严重,而本文方法通过深度学习的方式能够 重新定位目标,仍能保持良好的检测性能。

综上所述,本文方法对转辙机的缺口具有较好的检 测性能,能满足铁路现场实际运用的需要。

3.7 边云协同功能验证和性能验证

云端通过 Java 的 SpringCloud 架构搭建后端框架。 边缘端设备通过 Python 的 Requests 模块的 Post 方法向 云端服务器发送请求。云端和边缘端采用 Http 协议进 行通信。边缘端先进行初步处理,包括图像采集、图像 尺寸缩小和图像压缩编码,再通过 Post 请求将数据发 给云端,云端接受数据后进行解码和推理,再将结果返 回给边缘端,边缘端再进行后续的图像处理,得出缺口 偏移量。通过模拟 10 个边缘节点向云端发送请求,发 送 10 000 次,记录测试数据如表 5 所示。

边云协同的处理速度优于单边缘计算。综上所述, 本文方法对转辙机缺口具有较好的检测性能,满足地铁 路现场实际运用的需要。

4 结束语

本研究提出了一种基于深度学习和边云协同架构的 道岔缺口检测方法,旨在提高铁路转辙机缺口检测的自

秋 ◎ 送 召仍内任祀祖永			
方法	步骤	平均耗时/ms	
	图像压缩和编码	2.57	
	传输数据到云	4.20	
	云端解码	2.44	
边云协同	云端 GPU 推理	31.09	
	云端回传数据	0.91	
	图像处理	17.95	
	总计	59.16	
	图像压缩和编码	2.57	
的市场让你	边缘端推理	95.46	
半辺缘り昇	图像处理	17.95	
	总计	115.98	

表 5 边云协同性能结果

动化程度、精确性和实时性。通过采用 YOLOv8 算法, 我们成功实现了对缺口和检测柱的高效目标检测,同时 通过图像处理技术精确获取了缺口和检测柱边缘信息。 实验结果表明,该方法在正常和摄像头抖动情况下均展 现出了优越的检测性能,误差控制在可接受范围内,满 足了铁路现场实际运用的需求。

此外,边云协同的工作模式显著提升了数据处理效 率,云端强大的计算能力与边缘端的快速响应相结合, 优化了资源使用,降低了对单一计算节点的依赖。通过 模拟测试,我们验证了所提方法在边云协同架构下的处 理速度优于传统的单边缘计算,充分证明了边云协同在 道岔缺口场景下的实时图像分析和目标检测中的有效性。

综上所述,本研究的道岔缺口检测方法不仅提高了 检测精度和效率,而且具有较强的鲁棒性和实用价值, 为铁路道岔的智能化监测提供了一种新的技术手段。未 来的工作将进一步探索模型的轻量化和优化,以实现更 广泛的工程应用。

参考文献:

- [1] 佚 名. 国家铁路局发布《2022 年铁道统计公报》 [J]. 城市轨道交通研究, 2023, 26 (7): 176.
- [2] WANG G, XU T, TANG T, et al. A Bayesian network model for prediction of weather-related failures in railway turnout systems [J]. Expert Systems with Applications, 2017, 69: 247 - 256.
- [3] 陈梦竹. 以高水平安全保障铁路高质量发展 [N]. 人民 铁道, 2024-01-10 (001).
- [4] 许庆阳. 道岔故障诊断及健康状态预测 [D]. 北京: 北 京交通大学, 2018.
- [5] 李 超,赵林海,刘伟宁.基于 Canny 算子的转辙机缺口 自动检测算法 [J].铁道学报,2018,40(10):81-87.
- [6] 孙启发. S700K 道岔转换与锁闭设备原理及维护知识问答 [M]. 北京:中国铁道出版社,2001.
- [7] DINDAR S, KAEWUNRUEN S, AN M. Identification of

appropriate risk analysis techniques for railway turnout systems [J]. Journal of Risk Research, 2018, 21 (8): 974 - 995.

- [8] 娄生超. 基于视频图像识别技术的转辙机缺口检测系统的 研究 [D]. 兰州: 兰州交通大学, 2013.
- [9] 李政锋,林冬云,彭侠夫,等.基于模板匹配的转辙机缺 口检测算法 [J]. 铁道学报, 2021, 43 (8): 88-96.
- [10] 金雪军, 左丽含, 马全松. 转辙机表示缺口监测装置 [J]. 铁道通信信号, 2005, 41 (5): 37.
- 「11】张少夫,张辉程,李乌江,等. DCQK-B型转辙机表示 缺口监测报警系统 [J]. 铁道通信信号, 2005, 41 (5): 34 - 35.
- [12] 仲 峰,吴文颇,吴继友. ZQJ-01 型转辙机缺口光电监 测报警系统 [J]. 铁道通信信号, 2004, 40 (9): 8-10.
- 「13] 杜彤彤. 转辙机缺口检测方式的研究「J]. 现代制造技 术与装备, 2022, 58 (2): 162-164.
- [14] 郑 霄. 基于图像处理技术的转辙机实时在线检测的研 究 [D]. 北京:北京交通大学, 2009.
- [15] 钟志旺,陈建译. 基于 CMOS 面阵的道岔缺口定位检测 研究「J]. 铁道学报, 2016, 38 (12): 70-74.
- [16] XU T, WANG G, WANG H, et al. Gap measurement of point machine using adaptive wavelet threshold and mathe-
- (上接第53页)
- [8] ZHAO W, CHEN F, HUANG H, et al. A new steel defect detection algorithm based on deep learning [J]. Computational Intelligence and Neuroscience, 2021: 1-13.
- [9] NIU M, SONG K, HUANG L, et al. Unsupervised saliency detection of rail surface defects using stereoscopic images [J]. IEEE Transactions on Industrial Informatics, 2020, 17 (3): 2271-2281.
- [10] 陈德阳, 唐 智, 何牧耕. 基于 OCR-UNet 的金属表面 缺陷分割 [J]. 组合机床与自动化加工技术, 2023 (11): 169-173.
- [11] ZHENG Z, HU Y, ZHANG Y, et al. Casppnet: a chained atrous spatial pyramid pooling network for steel defect detection [J]. Measurement Science and Technology, 2022, 33 (8): 85403.
- [12] COHN R, ANDERSON I, PROST T, et al. Instance segmentation for direct measurements of satellites in metal powders and automated microstructural characterization from image data [J]. JOM, 2021, 73 (7): 2159-2172.
- [13] GUPTA C, CHAUHAN G, AIYAR H D S. Detection of defective steel surface with image segmentation $\lceil C \rceil //$ 2022 International Conference on Sustainable Computing and Data Communication Systems (ICSCDS): IEEE, 2022: 1578-1582.
- [14] HE K, GKIOXARI G, DOLLáR P, et al. Mask r-CNN [C] //Proceedings of the IEEE International Conference on Computer Vision, 2017: 2961-2969.

matical morphology [J]. Sensors, 2016, 16 (12): 2006.

- [17]张宇宁,谢 琦.一种基于机器视觉的铁路道岔检测方 法 [J]. 计算机应用与软件, 2015, 32 (1): 225-228.
- [18] 龙 彬,尚春阳,张 丹.基于视频监控技术的转辙机 缺口检测系统研究「J]. 铁路计算机应用, 2013, 22 (11): 43-46.
- 「19〕仲祎敏. 转辙机缺口视频检测系统在铁路既有线的应用 [D]. 兰州: 兰州交通大学, 2016.
- [20] 刘金明,张红星,周长义,等. HTK 道岔缺口检测系统 的研究「J]. 哈尔滨铁道科技, 2021 (1): 3-6.
- [21] 刘云婷. 基于图像处理的转辙机缺口自动检测算法研究 [D]. 兰州: 兰州交通大学, 2023.
- [22] 杜 森,张 烁,梁景源,等.基于像素数量统计的道 岔转辙机缺口边缘检测算法 [J]. 城市轨道交通研究, 2023, 26 (7): 241-245.
- [23] 叶 斌,杨云国. 基于 FPGA 的转辙机表示缺口检测模 块设计 [J]. 铁道通信信号, 2023, 59 (2): 23-27.
- [24] 吴宪驰,殷 玲,万敏华.一种基于机器视觉的道岔缺口 快速检测方法 [J]. 科技与创新, 2024 (8): 77-78.
- [25] CANNY J. A computational approach to edge detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1986 (6): 679-698.
- [15] 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.
- [16] LIN T, DOLLáR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2117-2125.
- [17] HUANG L, YUAN Y, GUO J, et al. Interlaced sparse self-attention for semantic segmentation [J]. Computer Vision and Pattern Recognition, 2019, ArXiv, abs/1907. 12273.
- [18] DEMIR K, AY M, CAVAS M, et al. Automated steel surface defect detection and classification using a new deep learning-based approach [J]. Neural Computing & Applications, 2022, 35 (11): 8389-8406.
- [19] BOLYA D, ZHOU C, XIAO F, et al. Yolact: real-time instance segmentation $\lceil C \rceil$ //Proceedings of the IEEE/ CVF International Conference on Computer Vision, 2019: 9157 - 9166.
- [20] WANG X, ZHANG R, KONG T, et al. Solov2: Dynamic and fast instance segmentation [J]. Advances in Neural Information Processing Systems, 2020, 33: 17721-17732.
- [21] HE K, GKIOXARI G, DOLLáR P, et al. Mask r-CNN [C] //Proceedings of the IEEE International Conference on Computer Vision, 2017: 2961-2969.