文章编号:1673-0291(2026)01-0140-12 **DOI**:10.11860/j.issn.1673-0291.20250090

基于层次化语义融合的铁路天窗作业安全检测算法

王佳丽[1],谢征宇[1],杨庆玺[2],王佳林[3],刘显辉[1],王增卿[1]
(1.北京交通大学 交通运输学院,北京 100044;2.焦作大学 基础教学部,河南 焦作 454000;
3.中国铁路郑州局集团有限公司 调度所,郑州 450052)

摘 要:针对铁路天窗作业中轨行区提取精度低及风险响应滞后等问题,提出一种基于层次化语义融合的铁路天窗作业安全检测算法.首先,为解决远距离轨道结构细长、易受背景干扰且传统分割网络计算冗余大的问题,构建层次化语义融合的轨道区域分割算法框架,采用层次化特征编码器与轻量化语义融合解码器,显著降低参数量与计算复杂度,在有限硬件资源下实现对轨道区域的高精度、实时分割,为后续风险判定提供可靠的区域基础.然后,为适应不同天窗期作业需求与风险调控,设计基于横向距离度量的层次化安全区域(核心作业区A层、辅助作业区B层、非作业区C层)划分方法,并结合跨阶段特征耦合的超限实时辨识算法,通过融合区域先验信息与多尺度目标特征,完成作业人员检测、工服识别、安全帽检测等多任务分析,实现对安全装备规范情况与超限作业行为的精准判定.最后,在自建的RailScapes铁路天窗作业数据集上验证算法的有效性.研究结果表明,该算法能有效解决传统视频监控盲区覆盖不足、人工依赖度高的问题,并通过分级预警机制实现对违规行为的实时主动报警,为铁路天窗作业提供高精度、低功耗、强韧性的主动安全防护技术支撑.

关键词:韧性交通;铁路天窗作业;语义分割;层次化安全区域划分;超限检测
中图分类号:U298 **文献标志码**:A

Hierarchical semantic fusion-based safety detection algorithm for railway maintenance windows

WANG Jiali[1], *XIE Zhengyu*[1], *YANG Qingxi*[2], *WANG Jialin*[3], *LIU Xianhui*[1], *WANG Zengqing*[1]
(1.School of Traffic and Transportation, Beijing Jiaotong University, Beijing 100044, China;
2.Department of Basic Teaching, Jiaozuo University, Jiaozuo Henan 454000, China;
3.Dispatching Center, China Railway Zhengzhou Group Co., Ltd., Zhengzhou 450052, China)

Abstract: To address the issues of low extraction accuracy of track areas and lagged risk response during railway maintenance windows, this paper proposes a safety detection algorithm based on hierarchical semantic fusion. First, to overcome challenges such as the slender geometry of distant tracks, background interference, and high computational redundancy in traditional segmentation networks, a hierarchical semantic fusion-based track area extraction algorithm framework is constructed. By employing

收稿日期:2025-07-02;**修回日期**:2025-11-28
基金项目:国家重点研发计划(2022YFB4301305);中央高校基本科研业务费专项资金资助(2024JBZY023)
Foundation items: National Key R&D Plan (2022YFB4301305); Fundamental Research Funds for the Central Universities (2024JBZY023)
第一作者:王佳丽(1996—),女,河南郑州人,博士生.研究方向为铁路安全监测. **email**:21114069@bjtu.edu.cn.
通信作者:谢征宇(1983—),女,浙江天台人,教授,博士生导师. **email**:xiezhengyu@bjtu. edu. cn.

引用格式:王佳丽,谢征宇,杨庆玺,等.基于层次化语义融合的铁路天窗作业安全检测算法[J].北京交通大学学报,2026,50(1):140-151.
WANG Jiali, XIE Zhengyu, YANG Qingxi, et al. Hierarchical semantic fusion-based safety detection algorithm for railway maintenance windows[J]. Journal of Beijing Jiaotong University, 2026, 50(1): 140-151. (in Chinese)

a hierarchical feature encoder and a lightweight semantic fusion decoder, the algorithm significantly reduces parameter counts and computational complexity. This enables high-precision, real-time segmentation of track areas under limited hardware resources, providing a reliable spatial foundation for subsequent risk assessment. Second, to adapt to diverse operational requirements and risk control needs during maintenance windows, a hierarchical safety zoning method based on lateral distance measurement is designed, categorizing are-as into a core operation zone (layer A), an auxiliary operation zone (layer B), and a non-operation zone (layer C). Combined with a cross-stage feature-coupled real-time identification algorithm for boundary violations, this approach integrates regional prior information with multi-scale target features to perform multi-task analysis, including worker detection, uniform identification, and helmet detection. This facilitates the precise determination of safety equipment compliance and unauthorized boundary incursions. Finally, the effectiveness of the algorithm is validated on the self-constructed RailScapes railway maintenance window dataset. The results indicate that the proposed algorithm effectively addresses the limitations of traditional video surveillance, such as inadequate coverage of blind spots and high manual dependency. By implementing a tiered early-warning mechanism, the algorithm achieves real-time proactive alerts for violations, providing a high-precision, low-power, and highly resilient technical foundation for active safety protection during railway maintenance.

Keywords: resilient transportation; railway maintenance window; semantic segmentation; hierarchical safety zoning; intrusion detection

随着铁路运营里程的不断增加,铁路天窗作业的复杂性和频率不断提高,施工和维修人员的安全成为铁路安全管理重点.为保障铁路线路、信号、供电、通信等基础设施的良好状态,确保运输安全,必须设置天窗对相关基础设施进行必要的检查、维修、更新与施工作业.天窗是指列车运行图中预留的、没有列车运行的封闭时间段,为各天窗作业人员提供唯一安全的“窗口期”进入铁路线路进行作业.传统安全防护主要依靠驻站联络员与现场防护员之间的人工联控,信息传递层级多、时延长,难以实现对突发超限行为的即时干预,这种被动安全防护模式易导致安全事故发生.因此,推动安全防护模式从“被动响应”向“主动预警”的技术升级,已成为当前铁路天窗作业安全管理的关键需求.轨道是铁路天窗作业环境安全主动感知的关键区域,近年来,深度学习和计算机视觉技术在铁路安全监测领域取得显著进展.

针对铁路复杂场景中的语义分割,主要围绕复杂场景下的分割精度与实时性进行研究.文献[1]提出多级空间金字塔池化模块,通过多尺度上下文聚合实现更丰富的语义表征,缓解复杂场景下的特征丢失问题.但其池化结构在面对轨道多交叉拓扑或极端光照干扰时仍可能产生边缘模糊与误分割.文献[2]基于上下文动态生成上采样核,通过局部特征重组实现分辨率恢复物理形态,其自适应的核采样机制对密集预测任务效果明显.文献[3]提出双支路网络架构BiSeNet,解决传统全卷积神经网络(Fully Convolutional Networks,FCN)在实时语义分割任务中,因提取空间信息与语义信息而牺牲计算速度的问题.文献[4]通过深度双分辨率结构结合金字塔池化,有效融合高低分辨率特征,兼顾全局与细节表达,提升复杂场景下的理解能力.但其特征融合模块计算复杂度随分辨率提升显著增加,对嵌入式设备仍不够友好.文献[5]采用多分辨率并行结构保留高分辨率特征,取得较高的精度,但多尺度交互带来庞大的参数量与计算量,难以在低算力场景中应用.文献[6]提出动态采样偏移策略,有效减少上采样冗余,提升效率,但对铁路轨道这种细长且连续形变结构的适配性有限.文献[7]通过多分辨率输入分级预测降低计算开销,适合实时场景,但牺牲弯道区域的边缘精度.文献[8]通过交织稀疏注意力矩阵增强像素间关系建模,并减少计算负担,但依然存在内存占用高的问题.文献[9]引入多尺度卷积注意力(Multi-Scale Convolutional Attention,MSCA)模块和轻量化解码器,以低复杂度卷积替代自注意力机制,在效率和精度之间取得平衡,但其全局上下文提取仍受限于卷积感受野,对极端光照或复杂拓扑的鲁棒性不足.

针对铁路现场安全防护,许多研究通过深度学习算法结合传感器进行安全监测.文献[10]利用北

斗卫星定位实现全天候高精度防护.文献[11]则融合个人防护装备(Personal Protective Equipment, PPE)、环境传感器和智能算法构建多模态保障体系.这类方法在提高安全防护的实时性和全局覆盖上具有优势,但过度依赖人车定位终端及外部传感器,面对其他类型入侵或违规行为时检测能力不足,难以替代基于视觉的风险区域划分与超限检测.当前,也有学者使用深度学习技术实现安全帽识别[12]、风险区域划分[13]、入侵检测[14]等关键任务.考虑到铁路现场环境复杂多变,文献[15]改进Mask R-CNN检测模型,提出一种红外弱光环境下多尺度密集注意力铁路异物检测方法,在红外弱光环境下可以更加准确地检测出铁路异物.文献[16]基于一个3层并行特征融合结构和YOLO解码器,实现弱照度条件下轨道交通障碍物检测,满足铁路交通中障碍物检测的需求.文献[17]提出无需位置编码的分层编码器与全MLP解码器,显著降低计算冗余,但未针对铁路场景的细长带状结构与多轨交叉形变进行优化.文献[18]利用空洞卷积和多尺度特征融合提升轨道线区域的分割精度.文献[19]通过轨道几何约束结合贝叶斯滤波提取几何轨迹图,提升复杂轨道场景轨迹定位精度.现有方法在上下文表征、特征融合和轻量化设计方面取得进展,且在铁路天窗作业环境安全检测有所应用,但现有方案多为单点技术或局部解决方案,仍存在天窗作业区域划分精度不足、响应机制僵化、实时性不足的问题,在集成度、环境适应性及应对复杂威胁方面存在局限.

针对铁路天窗作业场景中安全防护被动滞后、覆盖有限且依赖人工干预的问题,本文提出高精度轨道区域分割与多层次安全区域动态划分与超限检测方法,采用语义与几何特征融合的方式,实现高精度、低功耗的轨道区域实时分割;结合多层次风险区域划分机制与实时超限辨识算法,构建"区域划分-状态感知-主动预警"的作业安全防护方法,实现从依赖人工干预的被动防护向嵌入设备支持、系统自主研判的主动安全防护模式转变,有效增强复杂环境下铁路天窗作业的安全性与响应及时性.

1 问题描述与模型构建

1.1 问题描述

当前基于视觉的检测方法在应对铁路场景特有的复杂性与动态性时,主要面临两方面技术问题:轨道结构的长距离、细长带状特性导致分割困难.监控图像中的轨道多为细长目标,常规图像识别主干网络的多级下采样叠加空洞卷积会放大有效特征尺度,细部结构就容易被抹平甚至消失,导致分割精度的下降,在缺乏连通性与非自交等拓扑约束时,岔心区域常见两股轨道粘连或断路,最终使轨道结构分割不完整;对作业人员安全装备规范与行为的安全状态识别能力不足.在铁路天窗作业场景下,通用目标检测算法的检测框易出现定位漂移或将背景误识别为人员产生误检,现有方法无法准确有效区分作业人员是否规范着装,并缺乏对铁路场景下作业人员安全着装规范与超限作业行为的有效融合,导致系统难以准确实时地对作业人员安全装备合规性与超限作业行为进行检测.

1.2 模型构建

针对以上问题提出一种基于层次化语义融合的铁路天窗作业安全检测算法,主要包括以下两个阶段:轨道区域的精准分割;多层次风险区域作业人员检测.基于层次化语义融合的铁路天窗作业安全检测框架示意如图1所示.图1中:$\boldsymbol{w}$为可学习权重矩阵,C为特征图通道数;采用面向层次化语义融合的轨道区域分割算法对视频图像轨道线区域进行分割提取,旨在解决轨道远距离结构细长易受背景干扰且分割网络在铁路场景中存在大量计算冗余问题,为目标检测提供有效的区域信息;通过构建多层次安全区域划分,结合基于跨阶段特征耦合的轨道超限实时辨识算法,对安全区域图像中的作业人员进行超出安全作业区域行为检测,实现作业人员超限

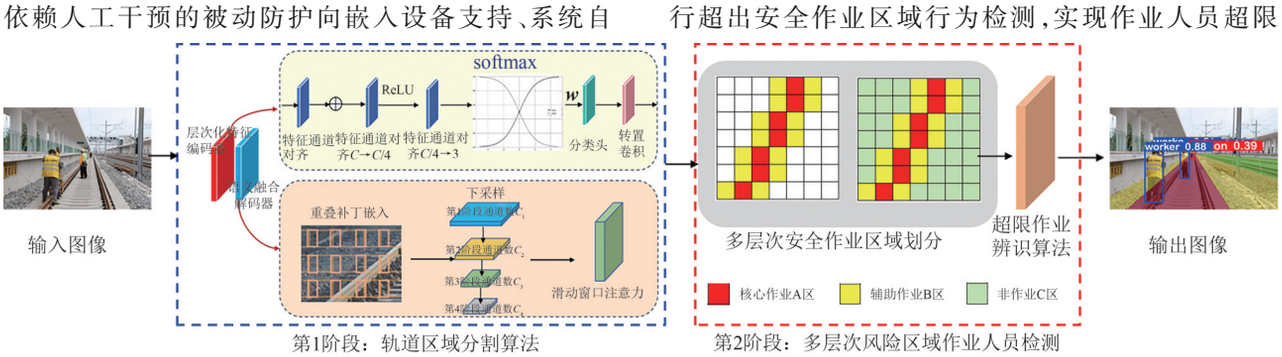


图1 基于层次化语义融合的铁路天窗作业安全检测框架

Fig.1 Safety detection framework for railway maintenance windows based on hierarchical semantic fusion

行为的精准检测与风险预警.

1.2.1　轨道区域分割算法

针对铁路远距离轨道安全限界区域提取任务面临着轨道结构细长易受背景干扰且分割网络在铁路场景中存在大量计算冗余问题,提出面向层次化语义融合的轨道区域分割算法,具体网络结构如图 2 所示.图 2 中:层次化特征编码器通过分块 L_1、L_2、L_3、L_4嵌入保留空间连续性,以滑动窗口注意力编码器替代传统全局自注意力,压缩自注意力机制中键和值的序列长度来显著降低计算复杂度同时保持分割精度;语义融合解码器采用线性层统一通道和拼接投影融合的全MLP架构,替代传统注意力与卷积解码器,通过分类头输出类别数 N_{cls},有效提高分割网络实时性.

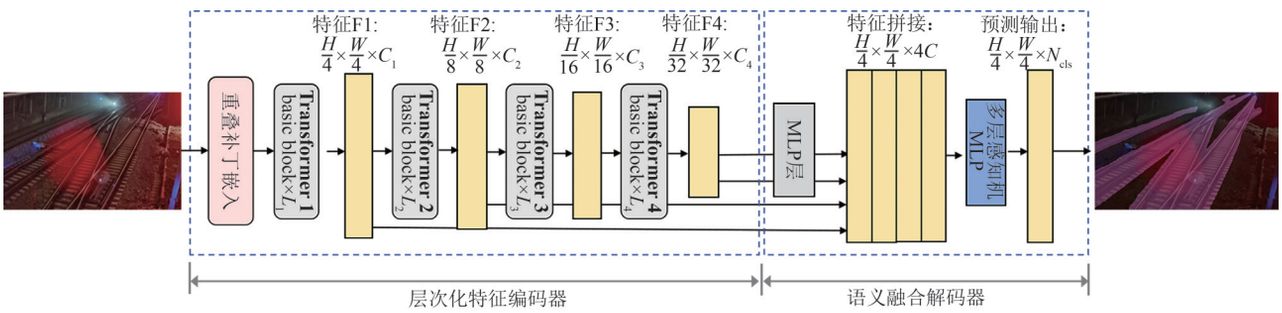


图 2　面向层次化语义融合的轨域安全划分网络框架

Fig.2　Track-domain safety partitioning network framework based on hierarchical semantic fusion

面向层次化语义融合的轨道区域分割算法主要包括层次化特征编码器与语义融合解码器两部分.

第 1 部分,通过对齐并融合不同层级的全局轮廓与局部细节的多尺度融合,最终提升复杂场景下的分割精度与实时性.通过重叠块嵌入操作对特征图进行下采样与通道扩展.设置卷积的步长小于核大小来实现块间的重叠划分,保留了局部细节与空间连续性.此过程的表达式为

$$F_l=\text{Conv}(F_{l-1};K,S,P)\in \mathfrak{R}^{\frac{H_{l-1}+2P-K}{S}+1\times\frac{W_{l-1}+2P-K}{S}+1\times C_l} \tag{1}$$

式中:F_{l-1}和F_l分别为第 l 层卷积的输入与输出特征图张量;$\text{Conv}(\cdot;K,S,P)$为带卷积核大小 K、步长 S、填充 P 的卷积;H_{l-1}和W_{l-1}为输入特征图的高和宽;$\mathfrak{R}$ 表示实数集;C_l 为第 l 层的通道数,其中 $l=\{1,2,3,4\}$.

基于式(1),第 l 层特征图的分辨率为 $F_l\in \mathfrak{R}^{\frac{H}{2^{l+1}}\times\frac{W}{2^{l+1}}\times C_l}$,随层数加深逐步增加 $C_{l+1}>C_l$;第 l 层的特征图分辨率相对输入被下采样到 $H/2^{l+1}\times W/2^{l+1}$.

在铁路轨道图像的高分辨率特征层中仅对每个局部窗口内部执行自注意力计算,显著节省计算资源.并通过窗口间偏移传递全局信息,从而在急转弯、道岔等多轨交叉场景下,以线性复杂度精准捕捉轨道局部曲率变化与长距离依赖关系,实现计算效率与分割精度的协同优化.其中,由于原始的多头自注意力,每个头 $\boldsymbol{Q},\boldsymbol{K},\boldsymbol{V}$ 的维度都是 $N\times C$,序列长度 $N=H\times W$,因此,滑动窗口自注意力估计表达式为

$$\text{Attention}(\boldsymbol{Q},\boldsymbol{K},\boldsymbol{V})=\text{Softmax}\left(\frac{\boldsymbol{Q}\boldsymbol{K}^{\text{T}}}{\sqrt{d_{\text{head}}}}\right)\boldsymbol{V} \tag{2}$$

由于浅层阶段处理高分辨率、低语义特征包含大量局部纹理细节,相邻像素高度相似,空间冗余度高,因此采用大缩减比率几乎不丢失信息;由于深层阶段处理低分辨率、高语义特征(如物体类别、整体结构),空间冗余度低,采用小缩减比率避免关键信息丢失.其中,使用缩减比率 R 减少序列的长度,从局部到全局逐步增强特征表达能力,避免高层特征因过度压缩丢失语义信息,序列缩减变换表达式为

$$\hat{\boldsymbol{K}}=\text{Reshape}\left(\frac{N}{R},C\cdot R\right)(\boldsymbol{K}) \tag{3}$$

$$\boldsymbol{K}=\text{Linear}(C\cdot R,C)(\hat{\boldsymbol{K}}) \tag{4}$$

式中:$\boldsymbol{K}$为待缩减的输入序列;$\text{Reshape}\left(\frac{N}{R},C\cdot R\right)(\boldsymbol{K})$为将 $\boldsymbol{K}$ 重塑为形状为 $\frac{N}{R}\times(C\cdot R)$ 的序列;$\text{Linear}(C_{\text{in}},C_{\text{out}})(\cdot)$为线性变换层,将输入 C_{in} 维张量映射为 C_{out} 维张量 $C_{\text{in}}=C\cdot R$,$C_{\text{out}}=C$.因此,输出序列 $\boldsymbol{K}$ 的维度是 $\frac{N}{R}\times C$,使得自注意力机制的复杂度从 $O(N^2)$ 降低到 $O\left(\frac{N^2}{R}\right)$.

通过网络深度或特征分辨率划分处理阶段,根据特征的语义抽象程度和空间冗余度,在几乎不丢失特征信息的情况下实现自适应地选择不同的序列

缩减比率.

第2部分,为进一步减少计算量以适应铁路有限的现场设备,采用线性层统一通道和拼接投影融合的全MLP架构,替代传统注意力与卷积解码器,大幅降低参数量,并利用局部感知注意力提取低层特征的边缘信息,结合全局上下文信息捕捉高层语义关联,通过多层感知网络实现跨尺度特征融合,在有限硬件资源的情况下满足轨道现场的高精度分割需求.

将来自分级编码器的多级特征通过全连接层统一为固定通道数.特征统一变换表达式为

$$\hat{\boldsymbol{F}}_l=\mathrm{GELU}(\boldsymbol{F}_l\boldsymbol{W}_l^{\mathrm{T}}+\boldsymbol{b}_l) \tag{5}$$

通过双线性插值恢复空间细节,确保几何结构的平滑过渡,保留轨道弯道、道岔等局部结构的精细边缘.将所有层级的特征上采样至统一分辨率,沿通道维度拼接后通过线性层压缩通道,实现跨分辨率空间特征融合,双线性插值上采样表达式为

$$\hat{F}_l(x',y')=\sum_{m=0}^{1}\sum_{n=0}^{1}w_{m,n}\times \hat{F}_l\left(\left\lfloor x'\cdot\frac{W_l}{W/4}\right\rfloor+m,\left\lfloor y'\cdot\frac{H_l}{H/4}\right\rfloor+n\right) \tag{6}$$

式中:通过对目标像素周围的4个最近邻像素进行加权平均得到在高分辨率位置(x',y')处的像素值$\hat{F}_l(x',y')$.首先将目标高分辨率坐标映射到低分辨率特征图$\left(x'\cdot\frac{W_l}{W/4},\ y'\cdot\frac{H_l}{H/4}\right)$,根据低分辨率像素网格中的相对位置确定4个邻近像素$\hat{F}_l\left(\left\lfloor x'\cdot\frac{W_l}{W/4}\right\rfloor+m,\left\lfloor y'\cdot\frac{H_l}{H/4}\right\rfloor+n\right)$的贡献,双线性插值的计算权重$w_{m,n}$,最后进行加权求和,对4个最近的像素点计算目标像素值.

将上采样后的特征沿通道维度拼接(通道数扩展为$4C$),再通过线性层压缩至C通道,实现特征拼接与多层次特征加权融合.其中,低分辨率特征捕捉轨道整体走向,高分辨率特征强化道岔、接头等细节,实现全局-局部互补.MLP隐式学习轨道形变敏感区域的权重,提升急转弯、多轨交叉区域的分割鲁棒性.特征加权融合表达式为

$$F(h,w,k)=\boldsymbol{b}(k)+\sum_{l=1}^{4}\sum_{c=1}^{C}\boldsymbol{W}(k,(l-1)C+c)\times \hat{\boldsymbol{F}}_l(h,w,c) \tag{7}$$

式中:$\boldsymbol{F}(h,w,k)$为跨层特征加权融合后的特征图,即在位置(h,w)和第k个通道处的特征值;$\boldsymbol{b}(k)$为第k输出通道的偏置向量;$\boldsymbol{W}(k,(l-1)C+c)$为第$k$通道和第$(l-1)C+c$通道的加权矩阵,用于对不同层的特征进行加权,以控制其在k通道的特征重要性;$\hat{F}_l(h,w,c)$为第l层特征张量在位置(h,w)第c通道处的特征值,每一层的特征图值经过加权后参与融合.

将融合后的特征$F\in\mathfrak{R}^{H\times W\times C}$通过线性层映射至类别数$N_{\mathrm{cls}}$(如轨道、背景、道岔等),分类映射表达式为

$$\boldsymbol{M}'(h,w,k)=\sum_{c=1}^{C}\boldsymbol{W}(k,c)\cdot\boldsymbol{F}(h,w,c)+\boldsymbol{b}(k) \tag{8}$$

式中:$\boldsymbol{M}'(h,w,k)$为分类映射后在空间位置(h,w)处,第k个类别($k\in[1,N_{\mathrm{cls}}]$)的得分值;$\boldsymbol{W}\in\mathfrak{R}^{N_{\mathrm{cls}}\times C}$为权重矩阵;$\boldsymbol{b}\in\mathfrak{R}^{N_{\mathrm{cls}}}$为偏置向量;输出$\boldsymbol{M}'\in\mathfrak{R}^{H\times W\times N_{\mathrm{cls}}}$为映射后最终的类别得分特征图.通过轻量化MLP架构显著降低计算复杂度,满足嵌入式设备实时性需求.

1.2.2 多层次风险区域作业人员检测

为满足铁路现场不同天窗期施工作业需求,按照每次施工需求及安全作业规则调整安全作业区域.其整体流程主要包括两部分:根据层次化安全区域划分规则,基于横向距离度量的参数可配置的轨道线路多层次划分方法,实现轨旁视角下轨道线路图像的差异化风险区域划分;在多层次风险区域划分的基础上提出跨阶段特征耦合的轨道超限实时辨识算法,通过融合区域先验信息与多尺度目标特征,能够同时完成对作业人员安全装备规范(工服、安全帽)判定与超限作业违规行为的检测.

依据文献[20],任何天窗外作业任务若存在与运行线路并行行为,必须保证大于等于3 m的安全间距,且需配置防护员在侧监控运行列车动态.对于存在视觉遮挡、弯道、隧道口等复杂场景,还应加装便携式临时电子围栏或无线避险终端,自动预警接近列车.为保证区域划分的科学性与可解释性,采用物理安全距离作为划分依据,其术语参数化如表1所示.

多层次风险区域作业人员检测主要包括多层次安全作业区域划分与超限作业辨识算法两部分.

第1部分,为保障轨道作业环境下的人员安全,系统首先对作业区域进行差异化风险区域划分.采用适用于铁路复杂环境的轨道分割算法,对图像中的轨道区域进行高精度识别与定位.由表1可知,轨道区域被划分为3层安全区:①核心作业区(A区),指轨道周边及作业人员所在的3 m半径内区域.该区域为高敏感作业区域,仅允许授权作业人员进入,

表 1　参数字典与基线范围

Tab. 1　Parameter dictionary and baseline ranges

参数名	默认基线值	说明依据
核心作业区阈值d_A/m	2.5	依据文献[20]中人员下道避车的最小安全距离设定2.5～3.5 m,是进行主要维修作业的授权安全空间
辅助作业区阈值d_B/m	4.5	在核心区外设置的缓冲预警区域4.0～5.0 m,其宽度用于吸收定位误差并为无意识越界行为提供预警空间
非作业区定义d_C	$>d_B$	定义为超出辅助作业区以外的全域.任何人员进入此区域,系统将触发最高级别报警
作业模式放宽系数k/m	1.0	用于根据不同作业模式动态调整安全区域范围的乘数系数1.0～1.5 m

禁止非工作人员靠近.同时,作业人员不得擅自离开核心工作区域.②辅助作业区(B区),指邻近轨道和作业区的范围.系统需对进入该区域的人员进行安全防护检测,判断其是否佩戴安全帽、工服等防护装备.允许作业人员临时停留辅助作业区域,不可前往非作业区.③在非作业区(C区),作业人员不可离开A和B区域前往非作业区(C区)的行车区域,从而实现对所有违规上道作业人员进行实时预警提醒,提前避让,防范危险发生.

为增强3层安全区域划分方法在真实铁路场景下的适用性,在轨道中心线拟合和像素距离分层的基础上,引入相机标定与透视变换,即通过拍摄已知尺寸的标定板图像来获取相机内部参数及畸变系数等关键参数[21],将图像坐标系下的像素距离映射为实际物理距离,从而保证不同分辨率、不同焦距相机输入时仍能维持较为一致的区域划分精度.在具体实现中,首先利用标定板计算相机的内外参数,并通过透视投影矩阵将轨道图像从原始视角映射至俯视几何平面,再在该俯视平面上依据表1确定的物理距离阈值,执行安全区域的分层划分.多层次安全作业区域划分流程共3个步骤.

步骤1:轨道中心线拟合.提取轨道区域中心线,用作区域划分的几何参考基准.输入语义分割后得到的轨道区域掩码.从图像中获取所有轨道区域的像素坐标点,使用最小乘法拟合直线方程表达式为

$$\begin{bmatrix} x_1 & 1 \\ x_2 & 1 \\ \vdots & \vdots \\ x_n & 1 \end{bmatrix} \cdot \begin{bmatrix} \alpha \\ \beta \end{bmatrix} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} \Rightarrow \left[\alpha, \beta\right]^{\mathrm{T}} = (\boldsymbol{X}^{\mathrm{T}}\boldsymbol{X})^{-1}\boldsymbol{X}^{\mathrm{T}}\boldsymbol{y} \tag{9}$$

式中:$\boldsymbol{X}$为设计矩阵;$\boldsymbol{y}$为观测向量;α和β为直线的斜率与截距;$(\cdot)^{\mathrm{T}}$为矩阵转置;$(\cdot)^{-1}$为矩阵求逆.

步骤2:计算像素点到轨道中心线的垂直距离.以轨道中心线为轴,测量每个像素点的垂直距离.对整张图像中的每个像素点(x,y),计算它到直线$y=ax+b$的垂直距离.具体表达式为

$$D(x,y)=\frac{\left|\alpha x-y+\beta\right|}{\sqrt{\alpha^2+1}} \tag{10}$$

式中:$D(x,y)$为图像中像素点(x,y)到拟合中心线$y=\alpha x+\beta$的垂直距离;$|\cdot|$为绝对值运算;$\sqrt{\cdot}$为平方根运算.

步骤3:按距离分层区域划分.根据预设的距离阈值将每个像素划入A、B、C共3类区域.划分时使用的输入参数包括核心警戒区边界d_A(例如:3 m≈25像素)、预警区边界d_B(例如:6 m≈50像素)、关注区边界d_C(例如:10 m≈80像素).

第2部分,将轨域分割网络划分后的层次化轨道安全作业区划输入到目标识别网络中,提前划定铁路天窗作业区域.结合人员所处位置检测的需求,提出基于跨阶段特征耦合的超限作业辨识算法,结构示意如图3所示.图3中:算法结构主要包括跨阶段特征耦合的特征金字塔Neck;包含作业人员安全装备规范(工服、安全帽)判定与超限作业判断的Head.该算法将区域先验信息输入目标识别网络,通过融合多尺度目标特征,实现基于工服、安全帽等外观特征对作业人员安全装备规范的判定及其超限作业行为的精准检测,从而为后续风险等级评估提供可靠输入.

基于跨阶段特征耦合的超限作业辨识算法共包含3个步骤.

步骤1:目标检测分支.输出每个候选框的类别置信度与定位参数表达式为

$$y_{\mathrm{det}}=\left\{(\boldsymbol{B}_i,\rho_i)\right\}_{i=1}^{N} \tag{11}$$

$$\boldsymbol{B}_i=(x_i,y_i,w_i,h_i) \tag{12}$$

式中:y_{det}为目标检测分支的输出集合;$\boldsymbol{B}_i$为第i个检测目标的边界框张量;ρ_i为第i个检测目标的类别置信度分数,取值区间为$[0,1]$;N为单张图像中检测到的目标总数.

利用分割先验掩膜对候选中心点进行区域筛选,抑制非作业区的误检,先验门控表达式为

$$g_i=\left[\mathrm{center}(\boldsymbol{B}_i)\in(\boldsymbol{M}_A\cup\boldsymbol{M}_B)\right] \tag{13}$$

式中:g_i为第i个检测目标的先验门控值;$[\cdot]$为指示函数(条件成立时取1,否则取0);center$(\boldsymbol{B}_i)$为从边

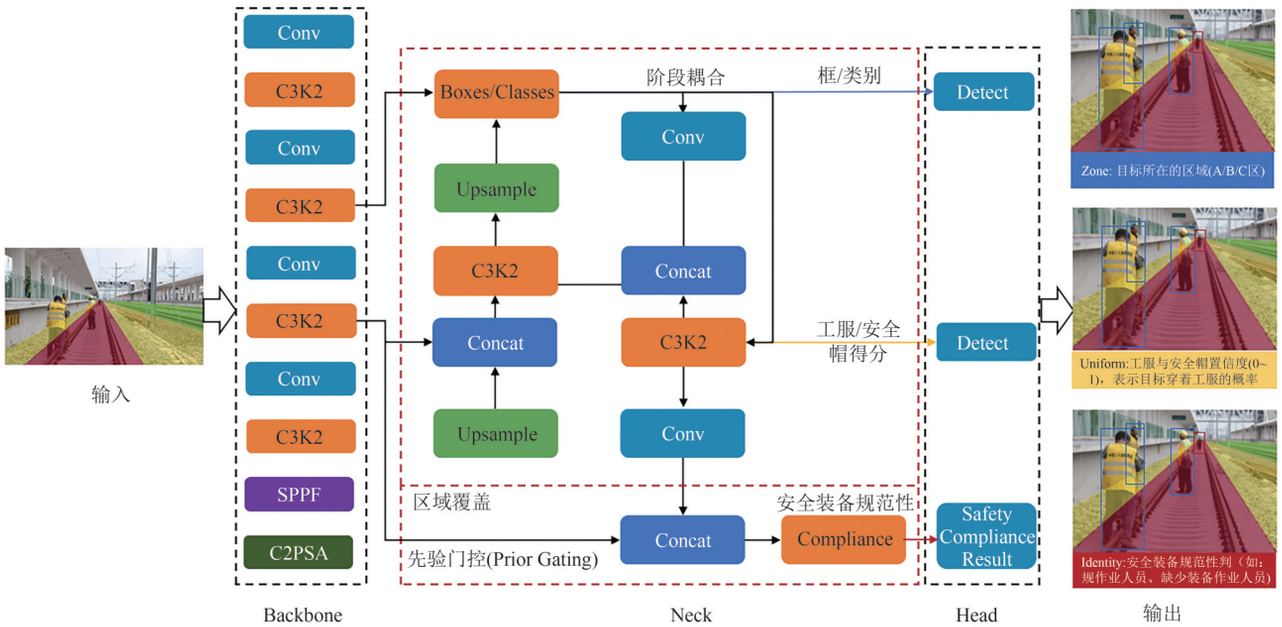


图 3 基于跨阶段特征耦合的超限作业辨识算法结构图

Fig.3 Structural diagram of the boundary-violation identification algorithm based on cross-stage feature coupling

界框 $\boldsymbol{B}_i$ 中提取的中心坐标；$\boldsymbol{M}_{\mathrm{A}}$ 和 $\boldsymbol{M}_{\mathrm{B}}$ 分别为 A 区（核心作业区）和 B 区（辅助作业区）的语义分割掩膜张量；ρ_i 经过门控后仅保留位于允许作业区（A∪B）内的目标置信度，即 $\rho_i \leftarrow g_i \cdot \rho_i$.

步骤 2：安全装备规范识别分支. 在共享骨干特征的基础上并联两路属性头，分别输出工服与安全帽置信度，作为作业人员安全装备规范视觉特征判断依据，其属性输出表达式为

$$y_{\mathrm{attr}} = \left\{ \left(p_i^{\mathrm{uniform}}, p_i^{\mathrm{helmet}} \right) \right\}_{i=1}^{N} \tag{14}$$

式中：y_{attr} 为安全装备属性分支的输出集合；p_i^{uniform} 为第 i 个检测目标穿戴工服的置信度；p_i^{helmet} 为第 i 个检测目标佩戴安全帽的置信度.

将区域类别作为语义先验嵌入，与检测及其属性置信度进行拼接，规范着装得分表达式为

$$s_i = \sigma\left(\boldsymbol{\omega}^{\mathrm{T}} \left[\rho_i, p_i^{\mathrm{uniform}}, p_i^{\mathrm{helmet}}, \boldsymbol{z}_i \right] + \beta' \right) \tag{15}$$

式中：s_i 为第 i 个检测目标的规范着装综合得分；$\sigma(\cdot)$ 为 sigmoid 激活函数；$\boldsymbol{\omega}$ 为可学习权重向量；$\boldsymbol{z}_i$ 为区域类别的语义先验嵌入向量；β' 为偏置项.

步骤 3：输出安全装备状态与超限作业标签. $p_i^{\mathrm{uniform}} \geqslant \tau_u \wedge p_i^{\mathrm{helmet}} \geqslant \tau_h \wedge \mathrm{center}(\boldsymbol{B}_i) \in (\boldsymbol{M}_{\mathrm{A}} \cup \boldsymbol{M}_{\mathrm{B}})$ 表示合规作业人员；$p_i^{\mathrm{helmet}} < \tau_h < \tau_u$、$p_i^{\mathrm{helmet}} < p_i^{\mathrm{uniform}} < \tau_u$ 分别表示未佩戴安全帽与未穿戴工服；$\mathrm{center}(\boldsymbol{B}_i) \in \boldsymbol{M}_{\mathrm{C}}$ 表示进入非作业区. 其中，τ_u 与 τ_h 分别为工服与安全帽的判定阈值；$\boldsymbol{M}_{\mathrm{A}}$、$\boldsymbol{M}_{\mathrm{B}}$ 为允许核心、缓冲作业区，$\boldsymbol{M}_{\mathrm{C}}$ 则为禁止区，即超限作业区.

通过作业区域的划分与识别检测框架，结合轨道区域分割与分级区域规则，系统可根据人员位置所属区域与其作业人员合规状态，完成如“作业人员未安全装备”“作业人员违规越区”等典型高风险行为的实时识别与多等级风险划分，如表 2 所示. 由表 2 可知：该框架将图像识别结果与作业规则深度融合，实现从像素感知到行为理解的跨越，有效支撑风险预警的精准化和分级化处置. 基于前述识别框架与区域先验门控，得到典型超限作业行为与区域判别条件映射，以支撑风险预警的精细化执行.

表 2 典型超限作业行为与区域判别条件映射表

Tab. 2 Mapping of typical boundary-violation behaviors and spatial discrimination conditions

违规行为类型	所属区域	判别条件	预警等级
安全装备未合规人员	A 区或 B 区	未匹配工服或安全帽特征且位于 A 或 B 区	Ⅰ级
越区作业	A 区→A 区界至 B 区	安全装备匹配成功，但跨越所属区域轨迹线	Ⅱ级
进入非作业区	C 区	任何作业人员目标位于 C 区，触发高等级告警	Ⅲ级（最高）

2 数值实验

为验证本文提出算法的有效性，所有的算法都在 NVIDIA GeForce RTX3090 上进行训练和测试，没有压缩和加速. 训练阶段，采用 ADAM 随机梯度下降学习算法训练网络. 训练期间的超参数设置

为:小批量大小为 12,学习率为 0.04,权重衰减为 0.000 5,动量为 0.9,训练轮数为 550. 采用自建 RailScapes 数据集进行训练,包含 1 176 张正常光照条件下的铁路天窗作业现场图像,涵盖直线段、弯道、道岔区等场景,包含天窗作业人员、非作业人员等目标.

2.1　数据集

为提升铁路轨道安全限界区域的识别精度,构建高质量的语义分割数据集至关重要.以往研究多集中于轨道线提取,对限界区域的分割大多较为粗糙,这在很大程度上受限于公开数据集的缺乏.为此,构建一个针对铁路场景的语义分割数据集,以支持相关方法的训练与性能评估.

RailScapes 数据集是一铁路轨道语义分割检测数据集,包含 840 张在低光和夜间环境下拍摄的铁路轨道图像,使用高灵敏度 RGB 传感器在典型运营环境中采集,涵盖从密集交叉枢纽到百公里级狭长带状分布的复杂场景.整个数据集分为训练集、验证集和测试集,数据集分为训练集(500 张)、验证集(140 张)和测试集(200 张).该数据集以轨道细长、交叉弯曲的形态特征为核心,其复杂环境包括:多样的光照与天气,包括日间强光、黄昏及夜间等;复杂的背景干扰,如轨道图像中存在大量的碎石、枕木纹理等背景噪声;严重的遮挡情况,包括轨道被杂草覆盖,人员间的部分遮挡;轨道布局复杂,存在大量多条轨道连接、交错与分叉的情况.但该数据集目前尚未包含雾、雨或极端恶劣天气条件,部分示例如图 4 所示.



(a) 正常光照环境下弯道、道岔铁路轨道示例



(b) 弱光环境下弯道、道岔铁路轨道示例

图 4　RailScapes 数据集部分示例图

Fig.4　Representative samples from the RailScapes dataset

2.2　轨道区域分割算法实验对比

在 RailScapes 数据集上,将轨道区域分割算法与 BiSeNetv1、BiSeNetv2、DDRNet、HRNet、ICNet、OCRNet、SegNeXt 等主流的语义分割方法进行对比,实验结果如表 3 所示.由表 3 可知:轨道区域分割算法在平均交并比和平均像素精度上均取得最优结果,分别为 88.91% 和 93.83%,且十亿次浮点运算数仅为 23.42,表明其在精度和效率上均有显著优势.这是因为它利用轨道邻域信息及空间连续性,对非轨道特征的背景噪声进行抑制,使目标特征与上下文特征高效结合,帮助目标的分割检测;轻量化的结构设计将这些特征调整到相同的空间分辨率,有效减少网络的空间、参数及分辨率冗余,高效地融合全局信息与局部细节.

表 3　轨道区域分割算法在轨道分割任务中的综合性能对比

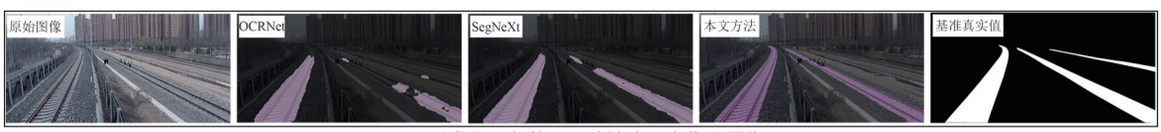
Tab. 3　Comparative performance of track segmentation algorithms in orbit segmentation

方法	尺寸	平均交并比/%	平均像素精度/%	十亿次浮点运算数
BiSeNetv1[3]	1 024×1 024	73.17	79.65	89.01
BiSeNetv2[3]	1 024×1 024	71.13	78.63	74.22
DDRNet[4]	1 024×1 024	72.51	79.16	107.70
HRNet[5]	1 024×1 024	76.59	82.42	109.32
ICNet[7]	1 024×1 024	71.39	81.88	91.67
OCRNet[8]	1 024×1 024	76.97	83.76	90.46
SegNeXt[9]	1 024×1 024	79.80	80.85	65.46
Ours	1 024×1 024	88.91	93.83	23.42

轨道区域分割的部分可视化结果如图5所示.由图5可知,在正常光照与弱光环境下,铁路天窗作业图像中常存在道岔节点处的多轨并行、转弯、交叉等复杂拓扑结构,且轨道局部可能出现形变.在此类场景中,对比其他分割算法,轨道区域分割算法仍能保持轮廓的连续性与分割精度,并有效捕捉远端轨道结构.该性能主要是由于采用层次化特征编码器对轨道邻域上下文信息与空间连续性,通过提取多股弯曲轨道的曲率变化特征,有效抑制背景噪声,从而引导网络准确区分轨道中心线两侧的带状特征区域与背景干扰.因此,即使在细长、深远区域,其他算法易出现分割模糊、边缘重叠或漏分割的情况,本文所提面向层次化语义融合的轨域安全划分网络仍表现出良好的鲁棒性,在复杂轨道图像分割中实现较高的检测性能.



(a) 正常光照条件下铁路天窗作业图像



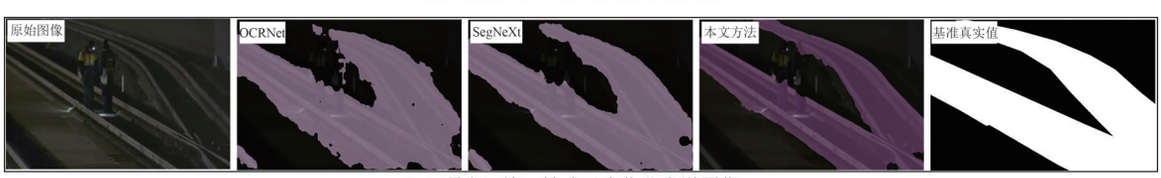
(b) 正常光照条件下远端铁路天窗作业图像



(c) 弱光环境下远端铁路天窗作业图像



(d) 弱光环境下铁路天窗作业图像



(e) 弱光环境下铁路天窗作业弯道图像

图5 铁路轨道提取结果可视化

Fig.5 Visualization of railway track extraction results

2.3 超限作业辨识实验对比

为验证跨阶段特征耦合的超限作业辨识算法在人员检测与安全装备规范任务中的有效性,在RailScapes数据集上补充相关检测实验,对人员、工服与安全帽目标进行识别,实验结果如表4所示.由表4可知:该算法与其他主流检测方法相比,在人员检测任务的综合性能上具有明显优势,其平均精度均值、精确率与召回率3个核心指标分别达到89.1%、90.5%与85.8%,均优于对比方法.

为验证算法对作业人员安全装备规范性进行准确判断的能力,其在安全装备规范对比实验结果如表5所示.由表5可知:所提算法在平均精度均值、工服识别精度、安全帽识别精度及安全装备规范性判断准确率上均取得最优结果,分别为90.3%、

表4 跨阶段特征耦合算法的人员检测性能对比

Tab. 4 Performance comparison of personnel detection using the cross-stage feature coupling algorithm

方法	平均精度均值/%	精确率/%	召回率/%	每秒帧数(Jetson Xavier)
YOLOv8s[22]	83.5	85.1	80.8	19
YOLOv11s[23]	86.2	88.0	83.0	21
RT-DETR[24]	84.8	86.9	81.9	15
Ours	89.1	90.5	85.8	22

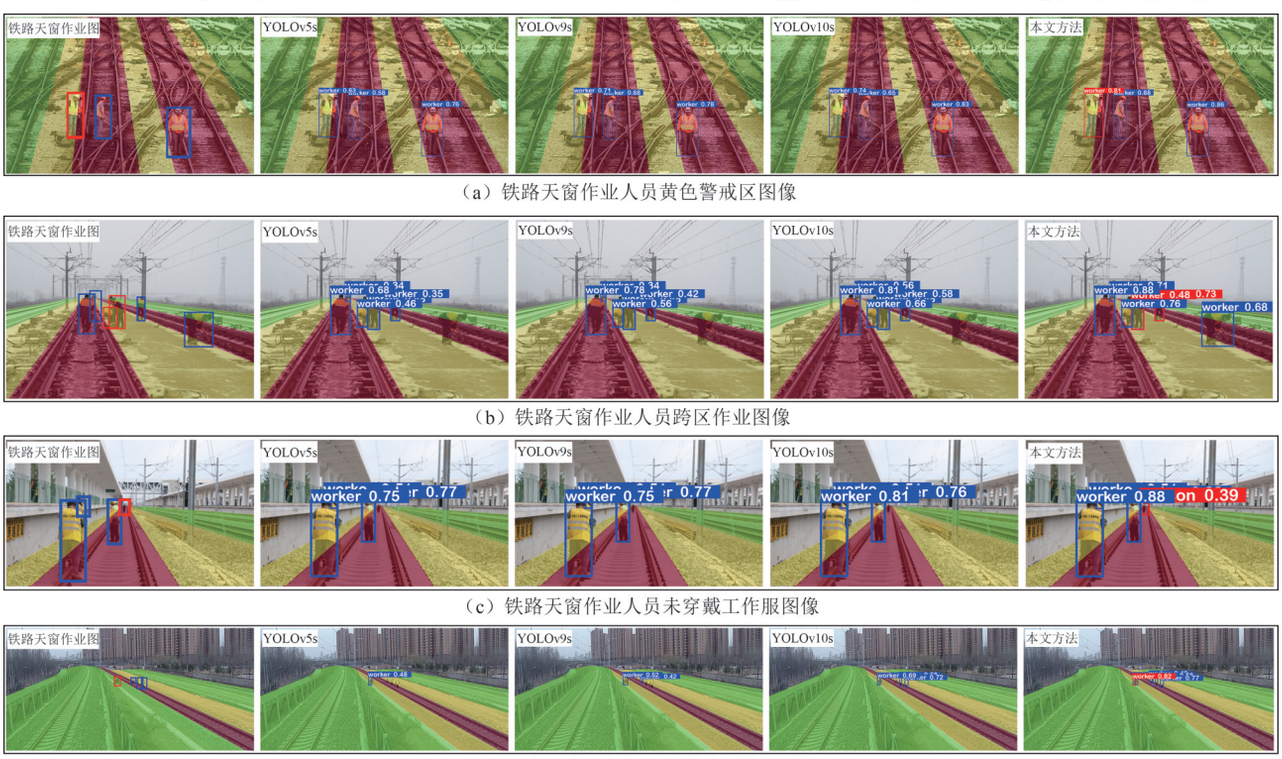
表 5　作业人员安全装备规范性识别性能对比

Tab. 5　Performance comparison of worker safety equipment compliance identification

方法	平均精度均值/%	工服识别精度/%	安全帽识别精度/%	安全装备规范性判断准确率/%	每秒帧数
YOLOv8s[22]	85.2	86.1	84.5	83.2	19
YOLOv11s[23]	87.9	88.3	86.7	85.8	21
RT-DETR[24]	86.5	87.0	85.8	84.1	15
Ours	90.3	92.4	90.1	89.7	22

92.4%、90.1% 与 89.7%,性能显著优于 YOLOv8s、YOLOv11s 及 RT-DETR 等主流检测算法.该优势主要得益于跨阶段特征耦合机制对多尺度语义信息的深度融合,增强对复杂背景下人员目标的辨识能力;引入的区域先验门控有效抑制非作业区的背景误检,从而显著提升检测精确率与召回率.在计算效率方面,算法在 Jetson AGX Xavier 平台上的实时推理速度超过 22 每秒帧数,能够满足铁路现场作业对风险实时响应的需求.

为验证多层次风险区域划分与分级响应机制的有效性,在真实铁路现场图像中模拟未穿戴工作服、跨区作业及进入黄色警戒区等 4 类典型违规行为进行测试,部分可视化对比结果如图 6 所示.由图 6 可知:在铁路天窗作业人员处于黄色警戒区的作业场景中,安全装备规范的作业人员(蓝色框)位于 A 区正常作业,均佩戴安全帽并处于红色核心作业区域内,但左侧 1 名作业人员(红色框)进入黄色辅助作业区域触发警戒;在铁路天窗作业人员未穿戴工作服的场景中,超限作业辨识算法可检测出全部作业人员,其他方法则存在漏检;其中 3 名作业人员在 A 区正常作业,远端 1 名安全装备未合规人员(红色框)进入 A 区,触发Ⅰ级报警.在远端铁路天窗作业人员跨区作业场景中,安全装备未合规人员(红色框)进入 B 区,触发Ⅱ级报警;相较于其他算法出现的漏检与错检,所用目标检测算法能准确识别作业人员的安全装备规范性,结合多层次作业区域划分,可更有效地实现安全预警.



(a) 铁路天窗作业人员黄色警戒区图像

(b) 铁路天窗作业人员跨区作业图像

(c) 铁路天窗作业人员未穿戴工作服图像

(d) 远端铁路天窗作业人员跨区作业图像

图 6　3层风险区域的实际划分检测效果

Fig. 6　Visual detection results for the three-tier hierarchical safety zones

2.4　边缘设备推理效率与实时性验证

为验证基于层次化语义融合的铁路天窗作业安全检测算法在铁路现场边缘计算设备上的可部署性,对算法的推理速度与计算复杂度进行测试.实验分别在高性能 GPU 平台(NVIDIA RTX3090)与边缘计算设备(NVIDIA Jetson AGX Xavier)上进行,评价指标包括:平均交并比、十亿次浮点运算数及每秒帧数.实验结果如表 6 所示.

表6 不同方法在RailScapes数据集上的效率对比

Tab. 6 Efficiency comparison across different methods on the RailScapes dataset

方法	平台	平均交并比/%	十亿次浮点运算数	每秒帧数
HRNet[5]	RTX3090	76.6	109.3	42
OCRNet[8]	RTX3090	77.0	90.5	39
YOLOv11[23]	Jetson Xavier	85.4	65.7	17
Ours	RTX3090	88.9	23.4	61
Ours	Jetson Xavier	88.9	23.4	33

由表6可知：与主流分割或目标检测算法在不同硬件平台上的性能对比，基于层次化语义融合的铁路天窗作业安全检测算法在RTX3090平台上达到88.9%的平均交并比与61每秒帧数，精度与速度均显著优于对比方法；在Jetson Xavier平台上，仍保持33每秒帧数的实时推理速度，能够满足铁路现场视频流检测的实时性需求；十亿次浮点运算数仅为23.4，相比HRNet与OCRNet分别降低约78%与74%，充分体现轻量化设计的优势，不仅具备高精度，同时具备低计算复杂度与嵌入式实时性，能够有效支撑铁路天窗作业场景中的风险响应.

3 结论

1）针对铁路远距离细长轨道区域提取精度易受背景噪声干扰且计算冗余的问题，所提出的轨道区域分割算法在RailScapes数据集上取得了88.91%的平均交并比，十亿次浮点运算数仅为23.4，在保持高精度的同时显著提升了计算效率，满足铁路现场对实时处理性能的要求.

2）在超限作业辨识算法任务中，人员检测与安全装备规范性识别准确率分别达到89.1%和90.3%，有效推动了铁路天窗作业安全防护从“被动响应”向“主动预警”的模式转变，为现场实时监控与智能决策提供了可靠的技术支撑.

3）多层次风险区域划分与分级预警机制，显著增强了复杂场景下的安全防护韧性.相比传统依赖人工双岗制的防护模式，通过实时区域划分与自动违规识别，大幅降低了人力依赖，推动了铁路天窗作业向“技防为主、人防为辅”的智能化防护体系演进.

本文方法在监控视频图像轨行区提取与人员检测中取得较好效果，但仍存在一定局限性：实验数据虽包含部分夜间场景，但对雨雪、雾霾、强光反射、遮挡及小目标等复杂情况缺乏系统验证；基于轨道中心线与像素距离的区域划分在弯道或视角畸变下仍可能偏差，并存在分步流程导致的链式误差传递问题；在跨摄像头协同与长时段多工况稳定检测方面需进一步研究；对比实验集中于通用算法，对铁路专用方法的系统对比仍有待深入，部分原因在于行业数据获取的限制.未来将围绕模型轻量化、复杂环境鲁棒性、多摄像头与视频流检测及行业专用方法对比展开研究，以推动该方法的工程化与实用化.

参考文献(References)：

[1] ZHAO H S, SHI J P, QI X J, et al. Pyramid scene parsing network[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, 2017: 6230－6239.

[2] WANG J Q, CHEN K, XU R, et al. CARAFE: Content-aware ReAssembly of FEatures [C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, 2019: 3007－3016.

[3] YU C Q, WANG J B, PENG C, et al. BiSeNet: Bilateral segmentation network for real-time semantic segmentation [C]//European Conference on Computer Vision (ECCV). Munich, 2018: 334－349.

[4] PAN H H, HONG Y D, SUN W C, et al. Deep dual-resolution networks for real-time and accurate semantic segmentation of traffic scenes[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(3): 3448－3460.

[5] WANG J D, SUN K, CHENG T H, et al. Deep high-resolution representation learning for visual recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 43(10): 3349－3364.

[6] CHEN L W, FU Y, GU L, et al. Frequency-aware feature fusion for dense image prediction[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 46(12): 10763－10780.

[7] ZHAO H S, QI X J, SHEN X Y, et al. ICNet for real-time semantic segmentation on high-resolution images [C]// European Conference on Computer Vision (ECCV). Munich, 2018: 418－434.

[8] YUAN Y, CHEN X, WANG J D. Object-contextual representations for semantic segmentation[C]//European Conference on Computer Vision (ECCV). Cham, 2020: 173－190.

[9] GUO M H, LU C Z, HOU Q B, et al. SegNeXT: Rethinking convolutional attention design for semantic segmentation[C]//Advances in Neural Information Processing Systems. Vancouver, Canada, 2022: 1140－1156.

[10] 冀琪琪. 基于北斗的铁路营业线作业人员安全防护[J]. 卫星应用, 2024(10): 50－54.
JI Qiqi. Safety protection of railway business line opera-

tors based on Beidou[J]. Satellite Application, 2024(10): 50－54. (in Chinese)

[11] BANERJEE S, HEMPEL M, SHARIF H. A survey of railyard worker protection approaches and system design considerations [C]//2017 Joint Rail Conference. Philadelphia, 2017: V001T06A007.

[12] 周瑶, 周石. 基于YOLOv5改进的铁路工人安全帽检测算法研究[J]. 计算机测量与控制, 2024, 32(3): 71－78.
ZHOU Yao, ZHOU Shi. Research on the detection algorithm of railway worker's hard hat based on YOLOv5 improvement [J]. Computer Measurement & Control, 2024, 32(3): 71－78. (in Chinese)

[13] 王勇达, 王硕禾, 朱钰, 等. 基于优化DeepLabv3＋的智能化高速铁路安全区域划分算法研究[J]. 南京信息工程大学学报, 2024, 16(1): 20－29.
WANG Yongda, WANG Shuohe, ZHU Yu, et al. Intelligent high-speed railway safety zone division based on optimized DeepLabv3＋[J]. Journal of Nanjing University of Information Science & Technology, 2024, 16(1): 20－29. (in Chinese)

[14] 吴浩楠, 史宏, 王瑞, 等. 基于改进YOLO v8的铁路人员入侵检测方法研究[J]. 铁道科学与工程学报, 2025, 22(4): 1828－1839.
WU Haonan, SHI Hong, WANG Rui, et al. Research on railway intrusion detection method based on improved YOLO v8[J]. Journal of Railway Science and Engineering, 2025, 22(4): 1828－1839. (in Chinese)

[15] 陈永, 卢晨涛, 王镇. 红外弱光环境下多尺度密集注意力铁路异物检测[J]. 铁道学报, 2022, 44(7): 63－71.
CHEN Yong, LU Chentao, WANG Zhen. Detection of railway foreign object intrusion under infrared low light environment based on multi-scale dense attention network[J]. Journal of the China Railway Society, 2022, 44(7): 63－71. (in Chinese)

[16] ZHANG T Q, CHEN Y, QU J P, et al. Research on obstacle detection method for rail transportation under low-light condition based on infrared image[C]//International Conference on Artificial Intelligence, Automation and High Performance Computing. Zhuhai, 2024: 15－20.

[17] XIE E Z, WANG W H, YU Z D, et al. SegFormer: Simple and efficient design for semantic segmentation with transformers[C]//Advances in Neural Information Processing Systems. Vancouver, 2021: 12077－12090.

[18] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. DeepLab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40(4): 834－848.

[19] WINTER H, WILLERT V, ADAMY J. Increasing accuracy in train localization exploiting track-geometry constraints[C]//2018 21st International Conference on Intelligent Transportation Systems (ITSC). Maui, 2018: 1572－1579.

[20] 国家铁路局. 铁路营业线施工安全管理办法:国铁运输监〔2021〕31号[S]. 北京:中国铁道出版社,2021.
National Railway Administration. Safety management measures for construction on railway operational lines: GT/TJ〔2021〕No. 31[S]. Beijing: China Railway Publishing House, 2021. (in Chinese)

[21] ZHANG Z. A flexible new technique for camera calibration[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(11): 1330－1334.

[22] REIS D, HONG J, KUPEC J, et al. Real-time flying object detection with YOLOv8 [EB/OL]. (2023-05-12)[2025-07-02]. https://arxiv.org/abs/2305.09972.

[23] KHANAM R, HUSSAIN M. YOLOV11: An overview of the key architectural enhancements [EB/OL]. (2024-10-24) [2025-07-02]. https://arxiv. org/abs/2410.17725.

[24] ZHAO Y A, LV W Y, XU S L, et al. DETRs beat YOLOs on real-time object detection[C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, 2024: 16965－16974.