

DOI: 10.19650/j.cnki.cjsi.J2614958

MSSOE-PGMFNet: 面向无透镜编码图像的 钢轨表面缺陷分割方法*

崔泽光¹, 邵星灵¹, 李秀源², 邓瑞祥¹, 闫佳乐²

(1. 中北大学电气与控制工程学院 太原 030051; 2. 中北大学仪器与电子学院 太原 030051)

摘 要: 钢轨表面缺陷分割在复杂现场常受制于成像系统体积大、对焦敏感导致的稳定性问题。无透镜成像技术虽能有效解决此限制,但其先重建后分割算法流程存在计算开销高、误差易累积的问题。针对上述问题,面向无透镜编码图像的钢轨表面缺陷分割方法,设计了一种多尺度可分离光学感知估计器-先验引导调制融合网络(MSSOE-PGMFNet)。首先,搭建无透镜成像采集系统,并基于东北大学钢轨表面缺陷检测增强数据集(NEU RSDDS-AUG)构建其无透镜版本,为编码域分割研究提供基础数据。其次,考虑现有单一尺度建模估算方式难以同时覆盖细小裂纹与大面积缺陷,设计多尺度可分离光学感知估算器以增强不同尺度缺陷的响应能力,进而输出可分割性更强的任务相关表征;然而,显著的缺陷形态变化使特征融合易出现空间响应不一致,为此,设计空间混合先验门控模块,生成稳定可迁移的空间门控信号,并通过门控调制方式对融合信息进行选择性增强与抑制,从而提升缺陷区域聚焦性与边界一致性。最后,在构建的无透镜数据集上进行实验验证。结果表明,所提方法在 U-Net、DeepLabV3+、TransUNet、LOINet、RecSegNet 和 FDTDNet 等对比方法中取得了整体最优性能, F_{β}^w 、MAE、 E_s 、 S_{α} 、Dice 和 IoU 分别达到 0.886、0.057、0.905、0.895、0.903 和 0.842。消融实验进一步验证了 MSSOE 与 PGMFNet 均对性能提升具有积极作用,二者联合使用时效果最佳。该方法无需显式重建,为无透镜编码图像条件下的钢轨表面缺陷分割提供了一种可行方案。

关键词: 无透镜编码成像; 编码域分割; 多尺度建模; 先验引导融合; 钢轨缺陷分割

中图分类号: TH878 TP391.41 U216.3 **文献标识码:** A **国家标准学科分类代码:** 580.30

MSSOE-PGMFNet: Steel rail surface defect segmentation for lensless encoded images

Cui Zeguang¹, Shao Xingling¹, Li Xiuyuan², Deng Ruixiang¹, Yan Jiale²

(1. School of Electrical and Control Engineering, North University of China, Taiyuan 030051, China;

2. School of Instrument and Electronics, North University of China, Taiyuan 030051, China)

Abstract: Steel rail surface defect segmentation in complex environments is often constrained by the bulky size of imaging systems and their sensitivity to focusing, which lead to stability issues. Although lensless imaging technology can effectively address this limitation, its reconstruction-then-segmentation pipeline suffers from high computational cost and error accumulation. To address these issues, this paper focuses on rail surface defect segmentation from lensless encoded images and proposes a multi-scale separable optical-aware estimator prior-guided modulation and fusion network (MSSOE-PGMFNet). Firstly, a lensless imaging acquisition system is constructed, and a lensless version is established based on the Northeastern University rail surface defect detection dataset with augmentation (NEU RSDDS-AUG), providing fundamental data support for encoded-domain segmentation research. Secondly, considering that the existing single-scale modeling estimation methods are difficult to simultaneously cover fine cracks and large-area defects, a multi-scale separable optical-aware estimator is designed to enhance the response ability to defects at different scales, and then output more segmentation-friendly task-related representations. However, significant defect shape variations make feature fusion prone to spatial response inconsistency. Therefore, this paper designs a spatial mixed prior-gated module to generate stable and transferable

收稿日期: 2026-02-15 Received Date: 2026-02-15

* 基金项目: 国家自然科学基金(62173312)、山西省高等学校科技创新计划(2024L174)、山西省基础研究计划青年(202403021222155)、中国博士后科学基金面上(2025M773609)项目资助

spatial gating signals. Through gated modulation, the module selectively enhances and suppresses the fused information, thereby improving the focus and boundary consistency of defect regions. Finally, experimental verification is conducted on the constructed lensless dataset. The results show that the proposed method achieves the best overall performance among comparison methods including U-Net, DeepLabV3+, TransUNet, LOINet, RecSegNet, and FDTDNet. With F_{β}^w , MAE, E_{ε} , S_{α} , Dice, and IoU reaching 0.886, 0.057, 0.905, 0.895, 0.903, and 0.842, respectively. Ablation experiments further verify that both MSSOE and PGMFNet contribute positively to performance improvement, and their combination achieves the best results. This method does not require explicit reconstruction and provides a feasible solution for steel rail surface defect segmentation under lensless encoded imaging conditions.

Keywords: lensless coded imaging; coded-domain segmentation; multi-scale modeling; prior-guided fusion; rail defect segmentation

0 引言

铁路是我国交通运输体系的重要组成部分^[1]。在铁路安全保障体系中,钢轨的服役状态会直接影响运输系统的稳定性与可靠性。由于长期承受列车的高频振动、重载压力和环境因素的共同作用,钢轨表面常常出现裂纹、孔洞等缺陷^[2],严重时可能导致钢轨断裂,进而威胁行车安全。因此,对钢轨表面进行及时、准确的检测与区域分割具有重要意义^[3]。

传统人工巡检由于效率低、速度慢、成本高和主观性强等缺点,已逐步退出主流检测体系^[4]。目前钢轨缺陷检测方法主要分为无损检测技术和机器视觉检测两类。无损检测技术主要包括超声波检测^[5]、电磁检测^[6]、涡流检测^[7]、漏磁检测^[8]等。廖韦韬等^[9]基于激光超声原理提出检测模型,有效检测钢轨内部微小缺陷,相对误差在10%之内。Gong等^[10]提出一种基于梯度导磁结构的磁场集中增强方法,实现了钢轨表面0.2 mm级微裂纹漏磁场的定向强化。超声、涡流等无损检测技术在内部损伤探测方面具有一定优势^[11],但其检测成本较高,操作复杂,在设备形态、作业方式与连续高速巡检等方面往往难以兼顾轻量化与易集成^[12]。

基于镜头成像的机器视觉方法能够获得直观纹理信息,便于对钢轨表面缺陷进行识别、定位与分析^[13]。孙铁强等^[14]提出了一种双模态钢轨表面缺陷检测算法,增强多模态特征表达,实现了检测精度与实时性的协同提升。Meng等^[15]提出一种基于多任务协同学习的钢轨表面裂纹智能检测方法,实现了裂纹区域的快速定位与像素级分割。Wu等^[16]提出一种基于多任务协同架构的轨道组件智能检测方法,实现了定位、缺陷分割及表面损伤识别的同步处理。进一步地,近几年钢轨表面缺陷分割研究逐步由一般监督分割向复杂场景鲁棒分割与增强成像分割方向发展。Ma等^[17]针对实际巡检中训练场景与测试场景外观差异较大导致的性能下降问题,提出了特征解耦重建框架,通过特征解耦与随机化增强模型在未知场景下的分割泛化能力;Si等^[18]面向高速铁路表面缺陷分割任务,提出以改进的编码器—解码器结构增强对

缺陷区域的细粒度表征;Pan等^[19]则结合偏振成像与双流特征融合网络,通过引入偏振信息提高低对比、小尺度缺陷在复杂背景下的可分性。上述研究表明,近年的钢轨表面缺陷分割研究在复杂场景鲁棒性、增强成像辅助分析以及细粒度缺陷表征等方面持续发展。虽然机器视觉方法在钢轨表面缺陷分析中取得了较好效果,但现有研究大多建立在常规镜头成像条件基础之上。对于安装空间受限、前端集成要求较高或成像条件受约束的应用场景,仍有必要进一步探索新的缺陷成像与分割技术路线^[20]。

近年来,无透镜成像^[21]作为一种以掩膜等调制元件替代传统镜头、在传感器平面记录编码图像并通过计算恢复或完成任务的计算成像方式^[22],逐渐受到关注。该技术凭借超薄轻量^[23]、结构紧凑^[24]、成本低^[25]等优势快速发展^[26]。此外,无透镜成像已逐步与深度学习结合,并拓展到目标检测、识别、分割与结构提取等高层视觉任务,表明编码图像中包含可用于后续任务的有效判别信息。

在直接任务推断方面,Zhang等^[27]提出了一种端到端深度神经网络模型,能够在无需中间重建的条件下直接对原始编码图像中的手势进行识别,在数据集上的准确率达到98.59%。陈凯余等^[28]提出一种无重建的目标识别方案,直接在无透镜相机拍摄的编码图像上训练网络识别目标,进一步说明编码域观测能够绕过可视化重建而直接服务于后续任务分析。在分割任务方向,Yin等^[29]提出端到端的无透镜目标推断网络(lensless object inference network, LOINet)网络,首次面向无透镜图像开展像素级目标推断。随后,Yin等^[30]又提出重建-分割联合网络(reconstruction and segmentation network, RecSegNet),将图像重建和分割整合到一个网络中,通过互补信息相互提升性能,体现出无透镜视觉分析由“先重建、后任务”向联合优化发展的趋势。进一步地,近期公开工作特征解耦直接任务网络(feature decoupling direct task network, FDTDNet)则尝试在不依赖中间视觉重建结果的条件下,直接从编码图像中完成目标分割,并通过特征解复用与任务解耦提升对目标轮廓与主体区域的表征能力。除此之外,Yin等^[31]提出区域凝视增强网络

(region-gazing attention network, RGANet), 通过区域凝视模块与区域放大器协同建模目标区域信息, 进一步将无透镜高层视觉任务拓展到区域级目标发现, 表明相关研究正由识别与分割逐步延伸到更丰富的区域推断任务。总体来看, 无透镜研究正由以图像恢复为中心的处理思路, 逐步拓展到面向编码域直接分割的任务驱动思路^[32]。与常规镜头成像结构相比, 无透镜成像由于省去镜头组与对焦操作, 结构上更轻薄、更紧凑、更集成^[33], 也为受限成像条件下的视觉检测提供新的研究思路^[34]。

然而, 将无透镜成像进一步应用于钢轨表面缺陷分割仍面临 3 个关键问题: 1) 尚缺乏面向钢轨表面缺陷分割的无透镜公开数据集, 难以在统一基准下开展对比验证; 2) 无透镜传感器获得的是编码图像而非直观图像, 编码域信息混叠与噪声会削弱缺陷边界与细粒度纹理^[35], 使得面向自然图像设计的分割网络难以直接迁移^[36]; 3) 现有研究中常采用“先重建、后任务分析”的两阶段范式, 通常引入额外计算开销^[37], 并可能造成重建误差向后续任务累积传播^[38]。与此同时, 现有钢轨表面缺陷分割研究主要面向常规视觉或增强成像模态。现有无透镜直接任务工作虽已扩展到目标识别、像素级目标推断以及直接目标分割等方向^[39], 但其任务对象多集中于人物、车辆、动物等自然场景中的通用目标^[40], 对钢轨表面缺陷这类小尺度且边界不规则目标的关注仍相对不足。本文在前人研究的基础上, 将编码域直接分割思路进一步拓展到钢轨表面缺陷场景, 提出直接在编码域完成钢轨表面缺陷分割的方法, 这一方法的主要优势在于避免显式重建过程带来的误差传播, 并提高在钢轨表面缺陷分割的精确度。本文的主要工作概括为:

1) 搭建无透镜成像采集系统, 并基于数据集 NEU RSDDS-AUG 构建无透镜编码图像数据集, 为钢轨表面缺陷编码域分割研究提供数据基础。设计无需显式重建的多尺度可分离光学感知估计器-先验引导调制融合网络 (multi-scale separable optical-aware estimator prior-guided modulation and fusion network, MSSOE-PGMFNet), 直接以编码图像为输入完成缺陷分割。

2) 考虑现有估算方式采用单一的尺度建模难以同时覆盖细小裂纹与大面积缺陷, 提出多尺度可分离光学感知估算器, 以增强不同尺度缺陷的响应能力, 输出可分割性更强的任务相关表征。

3) 针对跨尺度特征融合空间响应不一致与噪声干扰易被放大问题, 设计多尺度空间混合先验门控模块生成稳定可迁移的空间门控信号, 并在解码阶段通过门控调制的特征融合机制对多尺度信息进行选择性增强与抑制, 从而提升缺陷区域聚焦性与边界一致性。

4) 在构建的无透镜数据上开展对比与消融实验。实验结果表明, 本文方法在综合分割指标及细节区域恢复方面均表现较优, 其中加权 F 值 (weighted F -measure, F_{β}^w) 为 0.886、平均绝对误差 (mean absolute error, MAE) 为 0.057、 E 度量 (E -measure, E_s) 为 0.905、 S 度量 (S -measure, S_a) 为 0.895、Dice 系数 (Dice coefficient, Dice) 为 0.903、交并比 (intersection over union, IoU) 为 0.842。上述结果验证了所提方法的有效性。

1 方 法

1.1 整体框架

本文面向无透镜成像条件下的钢轨表面缺陷分割任务, 提出一种直接在编码域进行分割的网络框架。与传统“先重建、后分割”的两阶段流程相比, 该思路避免了重建误差对后续分割的潜在影响, 并简化了整体处理流程, 从而更贴合缺陷分割任务对结构细节与边界一致性的需求。然而, 直接在编码域完成分割也带来了新的挑战: 无透镜编码图像存在纹理混叠与边界弱化, 传统 U 型卷积神经网络 (U-shaped convolutional network, U-Net) 难以稳定提取判别性边界线索, 且钢轨表面缺陷尺度跨度大使简单多尺度融合难以兼顾细小裂纹与大面积缺陷。因此, 本文在 U-Net 编码解码范式基础上提出 MSSOE-PGMFNet。该网络整体采用先验感知与语义引导的协同建模策略: 前端多尺度可分离光学感知估算器用于从编码图像中提取对分割友好的浅层结构线索; 随后主干网络在多尺度语义表征的基础上, 通过先验门控与调制融合机制实现跨尺度信息交互与细节恢复, 最终输出像素级缺陷掩膜, 整体结构如图 1 所示。

原始图像经由无透镜成像系统获取编码图像 $\mathbf{Y} \in \mathbf{R}^{H \times W \times 3}$, 首先通过多尺度可分离光学感知估算器进行任务引导的轻量解码, 得到编码域分割友好的特征 $\mathbf{Z} \in \mathbf{R}^{H \times W \times 32}$ 。随后构建同尺度双分支编码器: 先验分支从编码图像提取多尺度先验特征 $\{\mathbf{F}_y^w\}_{m=1}^5$, 语义分支从分割特征提取多尺度语义特征 $\{\mathbf{F}_{oe}^w\}_{m=1}^5$ 。为实现“先验主导、语义纠偏”的稳健先验注入, 网络在高分辨率尺度 Layer1、2 上采用先验门控模块生成空间门控信号 $\mathbf{A}^m$, 在中低分辨率尺度 Layer3、4、5 上采用引入空间混合的先验门控模块生成更具结构一致性的门控图。解码阶段在每个尺度引入调制特征融合模块, 以 $\mathbf{A}^m$ 对解码状态进行空间调制, 并将语义分支特征作为补偿项与残差主干共同融合, 得到尺度融合特征 $\mathbf{S}^m$, 再通过上采样与拼接节点逐层恢复空间分辨率。训练时采用深度监督在多个尺度输出辅助预测并与全分辨率真值对齐约束, 从而提升梯度传递与多尺度缺陷学习能力; 测试时仅保留最终输出得到缺陷预测 $\hat{\mathbf{M}}$ 。




图1 整体框架

Fig. 1 Overall framework

1.2 多尺度可分离光学感知估算器

无透镜编码图像受编码结构与点扩散影响,普遍存在纹理混叠、边界扩散与低对比度等现象,导致缺陷的结构细节与边界线索不易分离。现有方法通常在网络前端引入浅层结构线索估计模块,在不重建的前提下,从编码图像中获得有利于后续任务的视觉先验,如光学感知估算器(optical-aware estimator, OE),通过可学习的双侧线性投影将混叠观测转换为可分割的浅层结构表示,为后续网络提供稳定的结构线索,如图2所示。




图2 光学感知估算器

Fig. 2 Optical-aware estimator

然而,钢轨表面缺陷形态复杂且尺度跨度大,现有估算方式多采用单一的尺度建模,难以同时覆盖细小裂纹

与大面积缺陷,易出现对小缺陷响应不足或对背景伪纹理过敏的问题,从而限制编码域分割性能的进一步提升。为此,本文在保留浅层结构线索估计思想的基础上,针对轨道缺陷的多尺度特性引入多尺度可分离建模,增强对细小裂纹与大面积块状缺陷等不同尺度缺陷的响应能力,提出多尺度可分离光学感知估算器(multi-scale separable optical-aware estimator, MSSOE),输出可分割性更强的任务相关表征,如图3所示。

为统一表达,定义标准卷积块: Conv、GroupNorm、ReLU 为 CGR 模块:

$$\text{CGR}_{(u \times v)}^{a \rightarrow b}(X) = \text{ReLU}(\text{GN}(\text{Conv}_{u \times v}^{a \rightarrow b}(X))) \quad (1)$$

其中, $\text{Conv}_{u \times v}^{a \rightarrow b}(\cdot)$ 表示卷积核尺寸为 $u \times v$, 输入通道数为 a 、输出通道数为 b 的卷积算子; $\text{GN}(\cdot)$ 为 Group Normalization, $\text{ReLU}(\cdot)$ 为激活函数。

为抑制 RGB 观测在真实采集条件下的颜色响应差异, MSSOE 首先采用 1×1 卷积实现像素级可学习颜色融合,将输入从 3 通道映射到紧凑的 16 通道特征空间:

$$F_0 = \text{CGR}_{(1 \times 1)}^{3 \rightarrow 16}(Y), \quad F_0 \in \mathbf{R}^{H \times W \times 16} \quad (2)$$

该过程视作在每个像素位置学习从 $[R, G, B]$ 到 16 维特征的线性组合,并通过归一化与非线性增强特征稳




图3 多尺度可分离光学感知估算器模块

Fig. 3 Multi-scale separable optical-aware estimator

定性,从而降低颜色链路不确定性对后续任务导向解码的影响。

钢轨表面缺陷形态多样,既包含细长裂纹等小尺度结构,也包含剥落、孔洞等大尺度块状区域。为增强对尺度变化的鲁棒性,本文并联3条多尺度可分离分支,尺度集合定义为:

$$k = \{7, 15, 31\} \quad (3)$$

较小核长($k=7$)强调局部细节与高频边缘信息,适于捕获细小裂纹等小尺度缺陷;中等核长($k=15$)在局部细节与区域结构间取得平衡,适于中尺度缺陷的形状建模;较大核长($k=31$)提供更大的空间聚合范围,有助于表征剥落、孔洞等大尺度块状缺陷及其上下文背景。

对任意尺度 $k \in K$,分支采用“横向 $1 \times k$ +纵向 $k \times 1$ ”的可分离卷积结构提取解码特征:

$$\begin{cases} \mathbf{G}_k = \text{CGR}_{(1 \times k)}^{16 \rightarrow 16}(\mathbf{F}_0) \\ \mathbf{F}_k = \text{CGR}_{(k \times 1)}^{16 \rightarrow 16}(\mathbf{G}_k) \\ \mathbf{F}_k \in \mathbf{R}^{H \times W \times 16} \end{cases} \quad (4)$$

该设计在扩大有效感受野的同时避免直接采用 $k \times k$ 大核卷积带来的高计算开销,能够在不同空间聚合范围内形成互补特征表示。

三尺度分支输出在通道维度拼接得到多尺度联合特征:

$$\mathbf{F}_{\text{cat}} = \text{Concat}(\mathbf{F}_7, \mathbf{F}_{15}, \mathbf{F}_{31}) \in \mathbf{R}^{H \times W \times 48} \quad (5)$$

随后通过 1×1 卷积进行通道混合与降维,得到融合特征:

$$\mathbf{F}_{\text{fuse}} = \text{CGR}_{(1 \times 1)}^{48 \rightarrow 32}(\mathbf{F}_{\text{cat}}) \in \mathbf{R}^{H \times W \times 32} \quad (6)$$

为提升训练稳定性并保留颜色融合后的基础表征,引入投影残差支路将 $\mathbf{F}_0$ 投影到相同通道数:

$$\begin{cases} \mathbf{F}_{\text{skip}} = \text{Conv}_{1 \times 1}^{16 \rightarrow 32}(\mathbf{F}_0) \in \mathbf{R}^{H \times W \times 32} \\ \mathbf{Z} = \mathbf{F}_{\text{fuse}} + \mathbf{F}_{\text{skip}} \end{cases} \quad (7)$$

MSSOE最终输出 $\mathbf{Z}$ 作为语义分支输入,同时保留原始编码图像 $\mathbf{Y}$ 作为先验分支输入。两分支采用同尺度金字塔结构提取特征:

$$\begin{cases} \mathbf{F}_y^m = \varepsilon_y^m(\mathbf{Y}) \\ \mathbf{F}_{oe}^m = \varepsilon_{oe}^m(\mathbf{Z}) \\ m = 1, \dots, 5 \end{cases} \quad (8)$$

其中, $\varepsilon_y^m(\cdot)$ 、 $\varepsilon_{oe}^m(\cdot)$ 表示尺度 m 的编码变换。为便于后续门控融合,网络仅要求两分支在空间尺度 H_m 与 W_m 一致,通道数可不同,由后续 1×1 投影进行对齐。

1.3 空间混合先验门控模块

在所提的多尺度编码解码框架中,跨尺度信息交互是恢复缺陷边界与细节的关键环节。然而,浅层特征与深层特征在信息侧重点上存在差异:浅层特征更偏向局部细节与纹理响应,深层特征更偏向语义判别与全局一致性。若在融合过程中采用直接拼接或逐元素相加等简单策略,容易将无关响应一并引入并被放大,表现为缺陷响应不够聚焦、边界漂移、细长裂纹断裂以及小目标被淹没等问题。对于轨道表面缺陷而言,细长裂纹与块状缺陷共存、形态变化显著,这类空间响应不一致会加剧融合过程的选择性不足,从而限制分割质量。

为缓解上述问题,已有研究表明引入注意力或门控机制能够对融合过程施加选择性约束,通过空间权重突出目标区域、抑制背景干扰。但许多门控策略仍主要依赖局部建模生成空间权重,难以稳定刻画细长结构所需的长程空间依赖;同时若门控权重仅由单一路径特征产

生,也可能在多尺度交互中出现约束失衡,无法持续稳定地指导跨尺度融合。基于此,本文提出空间混合先验门控模块(spatial mixed prior-gated module, SM-PGM),其目标是在编码端的各尺度特征上生成可靠的空间门控信号 A^m ,为后续跨尺度融合提供空间先验约束。

具体而言,SM-PGM 在空间维度引入混合建模机制以增强全局空间关系与长程依赖的刻画能力,并通过

先验与语义协同生成空间门控分布,使得到的 A^m 具有更好的稳定性与可迁移性。生成的 A^m 随尺度传递至解码侧,在融合阶段由调制特征融合模块(modulated feature integration block, MFIB)引入,对解码特征的空间响应进行选择性地增强与抑制,从而提升缺陷区域响应的聚焦性与边界一致性。SM-PGM 的整体结构如图4所示。




图4 空间混合先验门控模块

Fig. 4 Spatial mixed prior-gated module

SM-PGM 分为空间混合块和先验门控模块。在高分辨率尺度 Layer1、2 上只采用先验门控模块 (prior gating module, PGM), 主要承担细粒度结构筛选与噪声抑制, 由先验特征直接生成空间门控图, 输入为先验特征 F_y^m , 则:

$$h_y^m = \text{ReLU}(\text{GN}(\text{DWConv}_{3 \times 3}(F_y^m))) \quad (9)$$

$$\begin{cases} a_y^m = \text{PWConv}_{1 \times 1}(h_y^m) \in \mathbb{R}^{H_m \times W_m \times 1} \\ A^m = \sigma(a_y^m) \\ m \in \{1, 2\} \end{cases} \quad (10)$$

其中, $\text{DWConv}_{3 \times 3}$ 为逐通道卷积, $\text{PWConv}_{1 \times 1}$ 为点卷积投影到单通道, $\sigma(\cdot)$ 为 Sigmoid。

在中低分辨率尺度 Layer3、4、5 上, SM-PGM 从先验混合特征与语义混合特征中产生单通道的空间门控信号

$A^m \in \mathbb{R}^{H_m \times W_m \times 1}$, 用于后续 MFIB 对解码状态进行空间调制。为保证门控以先验为主导, 同时允许语义分支提供轻量纠偏, 引入空间混合块 (spatial mixing block, SMB) 分别对先验与语义两路特征进行混合, 特征对齐后在 logit 空间进行加性融合: 由先验分支得到主门控 logit a_y^m , 与由语义分支得到纠偏 logit a_{oe}^m 进行相加, 最后经 Sigmoid 输出 A^m 。首先对先验与语义两路特征分别进行空间混合:

$$\begin{cases} F_{y, mix}^m = \text{SMB}_y(F_y^m) \\ F_{oe, mix}^m = \text{SMB}_{oe}(F_{oe}^m) \end{cases} \quad (11)$$

先验分支的空间混合特征 $F_{y, mix}^m$, 首先使用 1×1 卷积进行通道投影得到中间特征 G_y^m , 随后通过深度卷积提

取局部响应,并结合归一化与非线性增强稳定性,最后投影到单通道得到主门控 logit:

$$\mathbf{G}_y^m = \text{Conv}_{1 \times 1}(\mathbf{F}_{y,\text{mix}}^m) \quad (12)$$

$$\mathbf{h}_y^m = \text{ReLU}(\text{GN}(\text{DWConv}_{3 \times 3}(\mathbf{G}_y^m))) \quad (13)$$

$$\mathbf{a}_y^m = \text{PWConv}_{1 \times 1}(\mathbf{h}_y^m) \in \mathbf{R}^{H_m \times W_m \times 1} \quad (14)$$

语义分支的空间混合特征为 $\mathbf{F}_{\text{mix}}^m$, 为避免门控分支反向牵引语义编码器导致塌缩, 本文在语义纠偏门控路径中, 将语义对齐特征在进入深度卷积前施加停止梯度, 使纠偏头仅在门控空间对齐域内学习修正, 而不改变语义编码器的表示分布。最后采用与先验侧一致的轻量提取路径得到纠偏 logit:

$$\mathbf{G}_{oe}^m = \text{Conv}_{1 \times 1}(\mathbf{F}_{oe,\text{mix}}^m) \quad (15)$$

$$\mathbf{h}_{oe}^m = \text{ReLU}(\text{GN}(\text{DWConv}_{3 \times 3}(\text{stopgrad}(\mathbf{G}_{oe}^m)))) \quad (16)$$

$$\mathbf{a}_{oe}^m = \text{PWConv}_{1 \times 1}(\mathbf{h}_{oe}^m) \in \mathbf{R}^{H_m \times W_m \times 1} \quad (17)$$

其中, $\text{stopgrad}(\cdot)$ 为阻断函数, $\text{DWConv}_{3 \times 3}$ 为逐通道卷积, $\text{PWConv}_{1 \times 1}$ 为点卷积投影到单通道。在 logit 空间将主门控与纠偏项进行加性融合, 并经 Sigmoid 压缩到 $(0,1)$ 得到最终空间门控图:

$$\mathbf{A}^m = \sigma(\mathbf{a}_y^m + \lambda_m \mathbf{a}_{oe}^m), \quad m \in \{3, 4, 5\} \quad (18)$$

其中, λ_m 为语义残差权重系数, 控制语义残差门控的贡献幅度, $\sigma(\cdot)$ 为 Sigmoid。由此得到的 $\mathbf{A}^m$ 为单通道空间控制信号, 其本质是“哪里需要增强/抑制”的权重图, 而非可供拼接的内容特征。

1.4 调制特征融合模块

在多尺度解码过程中, 网络需要同时利用解码特征 $\mathbf{U}^m$ 的语义判别能力与来自先验分支的结构/语义线索, 以恢复缺陷边界并提升区域一致性。然而, 两类特征在通道维度、响应幅值与信息语义层级上存在差异: 解码特征更偏高层语义且定位逐步恢复, 先验特征更偏结构提示但表征分布不同。若采用直接拼接或简单相加的融合方式, 容易出现信息互相掩盖的现象: 例如语义特征主导导致边界被平滑, 或结构提示过强导致局部细节被放大而破坏区域一致性; 同时, 不同尺度下两类特征的贡献并非恒定, 固定融合策略难以适配细小裂纹与大面积缺陷的差异需求。

为此, 本文提出调制特征融合模块, 其结构如图 5 所示, 用于在 m 尺度上实现对齐、调制、自适应融合的一体化设计: 首先对先验特征进行通道对齐以消除维度不匹配, 其次利用 SM-PGM 生成的空间门控信号对解码特征进行调制, 使融合更聚焦于先验提示的关键区域, 最后通过可学习的融合系数对两路信息进行尺度自适应加权并生成融合特征。从而在不同尺度下协调“语义判别”与“结构细节”的互补关系, 提升边界恢复质量与整体分割稳定性。




图5 调制特征融合模块

Fig. 5 Modulated feature integration block

将门控信号直接作用于解码特征:

$$\mathbf{U}_w^m = \mathbf{U}^m \odot \mathbf{A}^m, \quad \mathbf{U}_w^m \in \mathbf{R}^{H_m \times W_m \times C_U^m} \quad (19)$$

其中, $\odot$ 表示逐元素相乘, $\mathbf{A}^m$ 在通道维度上自动广播到 C_U^m , 需要强调的是 $\mathbf{A}^m$ 被视为控制信号而非内容特征。

考虑到解码特征在深层尺度可能存在语义信息不足, MFIB 引入语义特征 $\mathbf{F}_{oe}^m$ 作为补偿项。为匹配解码通道, 采用 1×1 卷积进行通道对齐:

$$\tilde{\mathbf{F}}_{oe}^m = \text{Conv}_{1 \times 1}(\mathbf{F}_{oe}^m) \in \mathbf{R}^{H_m \times W_m \times C_U^m} \quad (20)$$

最后以残差方式融合原解码状态、门控调制项与语义补偿项, 并经过 CGR 模块进行轻量整合得到尺度融合特征:

$$\mathbf{S}^m = \text{CGR}(\mathbf{U}^m + \alpha \mathbf{U}_w^m + \beta \tilde{\mathbf{F}}_{oe}^m) \quad (21)$$

其中, α, β 为门控调制项与语义补偿项的权重系数 (可学习)。残差主项 $\mathbf{U}^m$ 保证信息主干的稳定传递, $\alpha \mathbf{U}_w^m$ 提供基于先验门控的空间强化与抑制, 而 $\beta \tilde{\mathbf{F}}_{oe}^m$ 用于补偿语义线索以降低漏检与断裂。MFIB 的输出 $\mathbf{S}^m$ 与 $\mathbf{U}^m$ 在空间分辨率与通道数上保持一致, 作为上采样拼接节点与深度监督预测头的输入。

1.5 解码阶段与多尺度监督

在各尺度上, MFIB 输出融合特征 $\mathbf{S}^m$ 作为解码阶段输入。为逐级恢复空间分辨率并融合跨层信息, 本文在尺度 m 处引入上采样与拼接组合节点 (up-sampling and concatenation, UC), 并通过解码卷积块得到解码特征 $\mathbf{U}^m$, 最终输出像素级缺陷预测。

为在解码过程中同时利用深层上下文与当前尺度的跳接信息, 组合节点 UC 由尺度 $m+1$ 的融合特征 $\mathbf{S}^{m+1}$ 先上采样, 再与对应尺度的跳接特征拼接形成下层解码输入:

$$\mathbf{X}^m = \text{UC}(\mathbf{S}^{m+1}, \mathbf{F}_{oe}^m) = \text{Concat}(\text{Up}(\mathbf{S}^{m+1}), \mathbf{F}_{oe}^m) \quad (22)$$

其中, $\text{Up}(\cdot)$ 表示上采样算子, $\text{Concat}(\cdot)$ 表示通道

维度拼接。随后经解码器对 $\mathbf{X}^m$ 进行特征细化得到解码状态:

$$\mathbf{U}^m = D^m(\mathbf{X}^m) \quad (23)$$

其中, $D^m(\cdot)$ 表示尺度 m 的解码卷积块。解码卷积块输出 $\mathbf{U}^m$, 随后经 MFIB 融合得到 $\mathbf{S}^m$, 并递推至更高分辨率尺度。

为提升多尺度收敛稳定性并强化浅层边界学习, 本文在每个尺度 m 的融合特征 $\mathbf{S}^m$ 上引入深度监督预测头 (deep supervision, DS), 得到辅助预测 $\hat{\mathbf{M}}^m$, 并上采样到原图大小与真值对齐计算损失:

$$\hat{\mathbf{M}}^m = \sigma(\text{Up}_{\times 2^{m-1}}(\text{Conv}_{1 \times 1}(\mathbf{S}^m))), m = 1, \dots, 5 \quad (24)$$

其中, $\text{Up}_{\times 2^{m-1}}$ 表示将 $H_m \times W_m$ 上采样回到 $H \times W$ 。最终预测 $\hat{\mathbf{M}}$ 取最高分辨率尺度的输出:

$$\hat{\mathbf{M}} = \sigma(\text{Conv}_{1 \times 1}(\mathbf{S}^1)) \quad (25)$$

推理阶段仅保留 $\hat{\mathbf{M}}$ 作为最终结果, DS 分支仅用于训练期的梯度引导。

设真值掩膜为 $\mathbf{M} \in \{0, 1\}^{H \times W}$, 尺度 m 的预测为 $\hat{\mathbf{M}}^m \in \{0, 1\}^{H \times W}$ 。采用二值交叉熵损失 (binary cross-entropy, BCE) 与 Dice 损失 (Dice Loss) 的组合形式, BCE 从像素层面约束背景分类, 能够稳定优化概率输出; Dice 则从集合重叠角度直接度量预测与真值的区域一致性, 对类别不平衡较鲁棒, 尤其有利于细裂纹、边缘缺陷等小目标结构的学习:

$$\mathcal{L}_{\text{BCE}}^m = \frac{\sum_{i=1}^H \sum_{j=1}^W [M_{ij} \log(\hat{M}_{ij}^m + \varepsilon) + (1 - M_{ij}) \log(1 - \hat{M}_{ij}^m) + \varepsilon]}{HW} \quad (26)$$

其中, ε 为防止 $\log(0)$ 的极小常数。

$$\mathcal{L}_{\text{Dice}}^m = 1 - \frac{2 \sum_{i,j} \hat{M}_{ij}^m M_{ij} + \varepsilon}{\sum_{i,j} \hat{M}_{ij}^m + \sum_{i,j} M_{ij} + \varepsilon} \quad (27)$$

$$\mathcal{L}_{\text{seg}}^m = \mathcal{L}_{\text{BCE}}^m + \lambda_d \mathcal{L}_{\text{Dice}}^m \quad (28)$$

其中, λ_d 为 Dice 损失权重。

为了提高多尺度特征的可分性并缓解深层梯度衰减, 本文采用全监督训练策略: 在各尺度融合特征上引入深度监督头, 并将各尺度的分割损失按权重 ω_m 加权求和得到总损失:

$$\mathcal{L} = \sum_{m=1}^M \omega_m \mathcal{L}_{\text{seg}}^m \quad (29)$$

其中, $M=5$ 。为强调高分辨率输出对边界与细粒度缺陷的贡献, 采用递减权重:

$$\left\{ \begin{aligned} \omega_m &= 2^{-(m-1)} \\ (\omega_1, \omega_2, \omega_3, \omega_4, \omega_5) &= \left(1, \frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{16}\right) \end{aligned} \right. \quad (30)$$

该设置使高分辨率监督占主导, 同时保留低分辨率预测对全局形状与上下文一致性的约束, 而提升整体训练稳定性与泛化性能。

2 实验结果与分析

2.1 无透镜成像系统搭建

由于目前尚缺乏面向钢轨表面缺陷分割任务的公开无透镜编码图像数据集, 本文搭建了一套无透镜成像采集系统, 如图 6 所示, 并在固定系统结构下开展钢轨表面缺陷编码图像采集。该系统主要由显示器、掩膜、图像传感器及固定支架等组成。




图6 无透镜编码成像系统及其搭建流程

Fig. 6 Lensless encoded imaging system and setup flow

采集端选用 Teledyne FLIR BlackflyS 系列的 BFS-U3-200S6C-C 彩色工业相机, 搭载 Sony IMX183 传感器, 最大分辨率为 5472×3648 , 像元尺寸 $2.4 \mu\text{m}$, 最高帧率约为 18 fps, 曝光时间范围 $67 \mu\text{s} \sim 30 \text{s}$, ADC 支持 10/12 bit, 系统搭建时拆除原有光学镜组, 仅保留传感器作为无透镜成像器件。掩膜采用基于最大长度伪随机序列 (maximum-length sequence, M 序列) 构造的二值幅度掩膜。具体地, 将由线性反馈移位寄存器生成的一维 M 序列与其自身进行外积, 构造二维编码图案, 并二值化得到尺寸为 256×256 的二值幅度掩膜, 其中 1 表示透过, 0 表示遮挡。该掩膜的透过像素比例在统计上接近 50%, 具有较好的可复现性与实验可比性。实验中将其固定安装于距传感器感光面 5 mm 处。显示器使用 ARZOPA 品牌的 G1 Game MAX 型便携式显示屏, 屏幕尺寸为 16.1 英寸, 16:9 IPS 面板, 并固定放置于距传感器约 300 mm 处, 用于标准条件下的数据采集。

为验证装调状态是否合理、系统响应是否稳定, 并为

参考点扩散函数测量及后续数据采集提供统一依据,本文采用点光源对系统工作状态进行测试与标定。具体标定过程中,按照先确定亮度、后确定孔径的策略确定点光源参数。图7给出若干具有代表性的点扩散函数(point spread function, PSF)响应结果,用于说明点光源亮度和等效孔径变化对系统点扩散响应的影响趋势。实际实验中,本文在一定参数范围内对点光源亮度与孔径进行了分档测试,并结合响应强度、背景噪声及局部饱和情况进行综合分析,最终确定了所采用的标准工作点。




图7 固定孔径条件下不同点光源亮度的PSF响应对比

Fig. 7 Comparison of PSF responses under different point-source brightness levels at a fixed aperture diameter

本文采用LED灯与针孔片构造近似点光源,针孔孔径直径记为 D ,单位为 μm 。为保证不同测试条件下采集结果的一致性,点光源测试过程中相机统一采用 2×2 binning整幅读出方式,并以8-bit位深输出。

图7给出了固定孔径条件下,不同点光源亮度对应的PSF响应结果。可以看出,随着点光源亮度的增加,系统响应逐渐增强,PSF图案结构也更加清晰。当亮度较低时,系统输出响应较弱,图案细节不明显,容易受到背景噪声影响;随着亮度提高,系统响应强度逐步增加,结构信息表现更为清楚。但当亮度继续增大时,虽响应应进一步增强,但局部区域也更容易接近饱和,不利于后续参考PSF测量及统一采集条件控制。

为进一步定量分析点光源亮度对系统响应质量的影响,本文统计了不同点光源亮度条件下系统响应的信噪比(signal-to-noise ratio, SNR)与信号背景比(signal-to-background ratio, SBR)的变化情况,如图8所示,SBR表示信号背景比,SNR表示信噪比。可以看出,随着亮度增加,SBR整体持续上升,说明响应与背景之间的区分程度逐步提高;而SNR在亮度增加至50附近时达到最大值,之后反而逐渐下降。该结果表明,过高亮度虽然可以提升响应幅值,但同时也会带来噪声增强和局部接近饱和等问题,从而降低有效信号质量。综合考虑,本文最终选取亮度50作为后续参考PSF测量与编码图像采集的标准亮度条件。

在确定标准亮度条件后,本文进一步在固定亮度50条件下比较不同孔径直径对应的PSF响应结果,如图9




图8 不同点光源亮度下系统响应的SBR与SNR变化曲线

Fig. 8 Variation curves of SBR and SNR under different point-source brightness levels

所示。可以看出,不同孔径直径会对系统点扩散响应的空间分布范围和局部能量分布产生明显影响。当孔径较小时,系统响应整体较弱;随着孔径增大,响应强度有所增强,但过大的孔径也可能削弱点源近似条件,从而影响参考PSF测量的一致性与代表性。综合比较不同孔径条件下的响应表现,本文最终选取孔径直径 $100 \mu\text{m}$ 作为标准孔径条件。




图9 固定亮度50条件下不同孔径直径的PSF响应对比

Fig. 9 Comparison of PSF responses under different aperture diameters at a fixed point-source brightness of 50

由此最终确定了标准工作点光源参数,即点光源亮度为50、孔径直径为 $100 \mu\text{m}$ 。该标定过程为系统装调状态验证、参考PSF测量及统一实验参数设置提供了依据,并在一定程度上减小了因工作状态波动带来的附加影响。

2.2 数据集构建

数据集采用“显示屏—掩膜—传感器”的固定几何配置,对原始钢轨表面缺陷图像进行显示端再采集,在实验室受控条件下构建编码图像—真值配对样本。类似方式在无透镜与计算成像相关研究中常用于原型系统验证,具有输入目标标准、采集流程可控、样本对应关系明确等特点。需要指出的是,该方式与铁路现场直接采集条件下获得的无透镜图像存在一定差异。相较于现场采

集,显示端再采集过程可能引入颜色响应偏差以及显示端附加噪声等因素,因此两者在输入方式与采集条件上仍存在一定差异。不过,在系统几何关系、采集参数和实验环境均保持固定的条件下,该方式可视为对无透镜编码采集过程的一种受控近似模拟,可用于验证本文方法在编码域分割任务中的有效性。

此外,为减小显示端再采集过程中亮度波动、对齐偏差及显示端附加误差带来的影响,本文对关键采集条件进行了统一控制,包括固定显示屏、掩膜与传感器之间的相对位置与距离,统一显示亮度、曝光时间、增益及采集模式,并尽量在稳定环境条件下完成数据采集。所有样本均在同一显示设备、同一显示模式及相同显示区域下完成再采集,以尽量减小显示屏亮度空间不均匀性及像素阵列差异带来的附加影响;本文以支架固定掩膜与传感器相对位置,并在系统装配过程中使掩膜与传感器感光面相对平行,以减小安装偏移和倾斜带来的对齐误差。由于本文数据集均在统一设备与统一参数条件下获取,显示端颜色响应偏差及附加噪声主要表现为数据集内部相对一致的系统性偏差,因此仍可满足本文在受控条件下对无透镜编码图像分割方法进行验证的需求。

本文基于轨道表面缺陷 RGB-D 数据集 NEU RSDDS-AUG 构建钢轨表面缺陷无透镜编码图像数据集。具体地,将原始缺陷图像显示于系统显示端,在固定几何配置下完成编码图像采集,从而获得与原始标注相对应的无透镜编码图像。

为避免显示端非等比缩放导致缺陷形态失真,本文在显示屏上采用等比缩放策略保持原始图像纵横比。当原始图像比例与屏幕比例不一致时,以边界填充的形式居中显示并在边缘填充背景。本文采用二值分割设置,真值图为黑白二值标注。显示端对原始图像及其对应真值图采用相同的缩放与居中参数进行显示,从而保证采集得到的编码图像与真值图在空间上的一致性。

由于无透镜采集得到的编码图像分辨率与网络输入尺度不一致,本文在进入网络前对编码图像与真值图执行一致的几何预处理。首先,按比例缩放使编码图像完整落入 256×256 画布,随后通过等比缩放与边界填充统一至 256×256 。其中,编码图像采用双线性插值,真值图采用最近邻插值,并以 0 填充背景。考虑到编码图像具有明显的全局混叠特性,本文避免对采集编码图像进行裁剪,以减少观测信息丢失,因此采用等比缩放与边界填充完成尺寸统一。

基于上述采集与预处理流程,最终形成编码图像与真值图配对样本。图 10 展示了所构建数据集中的部分样本示例,包含原始图像、对应编码图像及真值图。



图 10 所构建数据集的部分样本展示

Fig. 10 Selected samples from the constructed dataset

可以看出,与原始图像相比,无透镜编码图像中的缺陷区域不再以直观纹理和清晰边界形式呈现,而表现出更明显的纹理混叠、结构耦合和边界弱化特征。原始图像中较清晰的缺陷轮廓、局部灰度差异及形态连续性,在编码图像中均受到不同程度影响;尤其对于细长条带、小尺度孔洞及不规则缺陷区域,其局部结构更易与背景发生混叠,导致缺陷区域与背景之间的区分难度进一步增大。这些特点说明钢轨表面缺陷在无透镜编码图像条件下的表征方式与自然图像存在明显差异,也进一步增加了像素级分割任务的难度。

2.3 评价指标

为全面评价模型在编码域缺陷分割任务中的性能,本文从区域重叠、像素误差与结构一致性 3 个维度选取 6 个评价指标: $\text{IoU}^{[41]}$ 、 $\text{Dice}^{[42]}$ 、 F_{β}^{ω} 、 MAE 、 $E_{\varepsilon}^{[44]}$ 与 S_{α} 。网络输出为 Sigmoid 归一化后的像素级概率图。对于 IoU 、 Dice 与 F_{β}^{ω} 需要二值输入的指标,本文统一采用阈值 0.5 将概率图二值化得到预测图像; MAE 、 E_{ε} 与 S_{α} 则在未二值化的概率图上计算,以反映像素级误差与结构一致性。

IoU 用于衡量预测缺陷区域与真值区域的重叠程度:

$$\text{IoU} = \frac{\text{TP}}{\text{TP} + \text{FP} + \text{FN}} \quad (31)$$

其中,TP 表示被正确预测为缺陷的像素数,FP 表示

被错误预测为缺陷的像素数, FN 表示漏检为背景的缺陷像素数。

Dice 用于衡量预测与真值的一致性, 对小目标更敏感:

$$\text{Dice} = \frac{2TP}{2TP + FP + FN} \tag{32}$$

F_{β}^w 根据预测结果中像素的位置及其邻近区域对误差进行加权, 用于衡量预测掩膜的准确性与结构质量。

MAE 用于衡量预测图与真实标注之间的像素级误差:

$$\text{MAE} = \frac{1}{HW} \sum_{i=1}^H \sum_{j=1}^W |P_{ij} - M_{ij}| \tag{33}$$

其中, P_{ij} 表示像素 (i, j) 的预测概率, M_{ij} 表示对应真值标注。

E_e 基于人类视觉系统的认知特性, 同时衡量局部像素级误差和全局图像级误差。 S_{α} 侧重于测量结构相似性, 它同时考虑区域感知和对象感知的结构相似性。

2.4 训练设置

本研究所有实验均在统一的硬件与软件环境下进行, 具体配置如表 1 所述。

表 1 实验环境配置

Table 1 Experimental environment configuration	
配置类别	具体参数
GPU	NVIDIA GeForce RTX 3090
CPU	AMD Ryzen 9 9800X3D
内存	128 GB
操作系统	Windows 11
深度学习框架	PyTorch 2.4
CUDA 版本	12.1

网络输入为无透镜采集的编码图像, 按 2.2 节所述流程对输入图像进行等比缩放与边界填充预处理, 同时将像素值归一化至 $[0, 1]$; 对应真值为二值标注, 在尺寸对齐时采用最近邻插值以保持边界一致性。为提升模型泛化能力, 训练阶段对编码图像与其对应的真值图同步实施几何数据增强, 包括随机水平/垂直翻转以及随机 90° 旋转。

模型采用 AdamW 优化器进行训练, 初始学习率设为 1×10^{-4} , 权重衰减为 1×10^{-2} , 批大小为 8, 训练轮数为 200; 学习率采用余弦退火策略逐步衰减, 训练过程中启用混合精度以提高训练效率。损失函数与深度监督策略见网络结构章节; 各尺度输出采用 BCE 与 Dice 的组合损失, 并按尺度递减权重加权求和。模型输出首先经

Sigmoid 激活得到概率图, 并以阈值 0.5 二值化得到预测图像; 性能评估采用 2.3 节所述指标。

2.5 实验结果与分析

1) 与现有方法对比

为验证本文方法在无透镜编码域钢轨表面缺陷分割任务中的有效性, 本文选取 6 种具有代表性的分割方法作为对比对象, 包括 U-Net、DeepLabV3+ 语义分割网络 (DeepLabV3+)、Transformer 与 U-Net 结合网络 (TransUNet)、LOINet、RecSegNet 和 FDTDNet。其中, U-Net、DeepLabV3+ 与 TransUNet 代表常用的通用分割网络, 分别对应经典编码—解码结构、多尺度上下文建模结构以及卷积与 Transformer 结合的分割框架; LOINet、RecSegNet 与 FDTDNet 则更贴近无透镜或编码域视觉任务建模思路, 能够从不同技术路线反映现有相关方法在该类任务中的表现。

为保证对比实验的公平性, 所有方法均在相同的数据划分下进行训练与测试, 并采用统一的训练设置与评测脚本, 最终使用 2.3 节所述 6 项指标进行评价。基于上述设置, 得到图 11 所示的可视化对比结果以及表 2 所示的定量对比结果。

表 2 各方法定量对比结果

Table 2 Comparative results of quantitative methods						
模型	F_{β}^w	MAE	E_e	S_{α}	Dice	IoU
U-Net	0.755	0.104	0.808	0.810	0.812	0.703
DeepLabV3+	0.838	0.082	0.861	0.852	0.856	0.741
TransUNet	0.812	0.095	0.843	0.815	0.803	0.729
LOINet	0.857	0.071	0.885	0.873	0.877	0.781
RecSegNet	0.863	0.065	0.889	0.887	0.881	0.817
FDTDNet	0.880	0.059	0.899	0.893	0.896	0.840
本文方法	0.886	0.057	0.905	0.895	0.903	0.842

从图 11 可以看出, 各对比方法均能够在一定程度上完成钢轨表面缺陷前景提取, 但在不同形态样本上仍表现出较明显差异。对于细长条带类缺陷, U-Net 与 DeepLabV3+ 在部分样本中存在不同程度的边界收缩和局部断裂现象, 预测结果相较真值更细或更短; TransUNet 虽能保留主体结构, 但在细节位置仍存在局部粘连或轮廓偏移。对于交叉结构和复杂连通区域, 部分方法容易出现交叉节点附近的局部缺失、结构变形或连通关系不稳定等问题。对于小尺度孔洞和离散缺陷样本, 个别方法存在漏检、误检或形态不规则等现象, 导致缺陷区域完整性不足。对于大面积缺陷区域, 虽然多数方法能够恢复主体范围, 但在边缘位置仍存在不同程度的轮廓偏差与局部缺损。




图 11 不同形态钢轨表面缺陷样本的分割结果对比

Fig. 11 Comparison of segmentation results for rail surface defect samples with different morphological patterns

相比之下,本文方法在不同形态样本上均表现出更稳定的分割结果。对于细长条带类缺陷,本文方法能够较好保持裂纹主体的连续性,减少局部断裂与边界过度收缩现象;对于交叉结构及复杂连通区域,本文方法在结构保持和区域完整性方面更接近真值;对于小尺度孔洞和离散目标,能够较好抑制背景干扰,同时保持缺陷形态的相对完整;对于大面积缺陷区域,其边界恢复更加自然,区域轮廓更完整。整体来看,本文方法在缺陷区域连通性、边界一致性以及复杂结构保持方面均表现出较好的综合性能。

表 2 的定量结果进一步验证了上述分析。本文方法在综合指标上取得最优结果: $F_{\beta}^w=0.886$ 、 $MAE=0.057$ 、 $E_e=0.905$ 、 $S_{\alpha}=0.895$ 、 $Dice=0.903$ 、 $IoU=0.842$ 表明其在区域重叠、结构一致性与像素误差这 3 方面实现了更均衡的提升。

从各对比方法的结果来看,U-Net、DeepLabV3+与 TransUNet 虽然能够完成基本前景提取,但整体指标相对较低,说明通用分割网络在无透镜编码图像条件下对缺陷区域的判别能力仍然有限。其中,DeepLabV3+的整体表现优于 TransUNet,表明在本文任务中,基于卷积的多尺度上下文建模方式较基于 Transformer 的结构具有更稳定的分割效果。与这 3 类通用分割网络相比,LOINet、RecSegNet 和 FDTDNet 的结果整体更优,说明面向无透镜或编码域任务设计的网络结构更适合该类分割问题。

在 3 种更贴近无透镜任务建模范式的方法中,FDTDNet 的表现最接近本文方法,其 F_{β}^w 、 MAE 、 E_e 、 S_{α} 、Dice 和 IoU 分别达到 0.880、0.059、0.899、0.893、0.896 和 0.840。这说明本文方法在保持整体区域完整性的同时,对缺陷边界和结构细节的恢复更加稳定。综合来看,本文方法在不同形态钢轨表面缺陷样本上均表现出较好

的适应性,验证了所提网络在无透镜编码域钢轨表面缺陷分割任务中的有效性。

2) 失败案例分析

为进一步分析各方法在复杂样本上的局限性,本节给出误检与漏检两类失败案例,如图 12 和 13 所示,并选取表现相对较强的 RecSegNet 和 FDTDNet 作为对比。




图 12 误检失败案例对比

Fig. 12 Comparison of failure cases with false positives




图 13 漏检失败案例对比

Fig. 13 Comparison of failure cases with false negatives

图 12 展示了误检类失败案例。可以看出,这类样本的共同特点是背景纹理复杂,局部区域存在与真实缺陷相似的条带、斑块或边缘过渡结构,在无透镜编码图像条件下容易与缺陷响应发生混淆。对于这类样本,RecSegNet 与 FDTDNet 均会在非缺陷区域产生不同程度的误分,本文方法虽然在误检范围控制和真实缺陷主体保持方面相对较优,但仍未能完全抑制背景误分。这说明在复杂背景条件下,编码图像中的纹理混叠与结构耦合仍会显著干扰缺陷区域判别。

图 13 展示了漏检类失败案例。与误检样本不同,这类样本通常具有缺陷区域面积较小、局部对比度较弱或边界不明显等特点,导致编码图像中的有效缺陷响应不足。可以看出,RecSegNet 与 FDTDNet 在这类样本上更

容易出现局部缺失甚至完全漏检,本文方法虽然通常能够保留更多主体区域,但对于极小目标和弱响应缺陷仍存在漏检现象。这表明当前方法在小尺度缺陷感知和弱边界恢复方面仍有进一步提升空间。

综合来看,当前失败案例主要集中在两类情形:一类是复杂背景引起的误检;另一类是弱小缺陷导致的漏检。其主要原因在于无透镜编码图像中缺陷信息往往伴随纹理混叠、边界弱化和结构耦合等现象,使得背景抑制与弱目标保持难以同时兼顾。虽然本文方法相较对比方法表现更稳定,但在复杂背景误分抑制和极小目标保持方面仍有待进一步改进。

3) 消融实验

为验证本文关键组件对性能提升的独立贡献,围绕两项核心设计开展消融实验:输入适配模块 OE 与 MSSOE、分割主干网络 U-Net 与 PGMFNet。构建了 4 种组合配置:(1) OE+U-Net;(2) MSSOE+U-Net;(3) OE+PGMFNet;(4) MSSOE+PGMFNet(即本文方法)。所有实验在相同数据划分与训练策略下进行。

消融结果如表 3 所示。首先,在固定后端为 U-Net 的情况下,引入 MSSOE 可显著提升性能: F_{β}^w 从 0.861 提升至 0.866,Dice 从 0.879 提升至 0.882,IoU 从 0.783 提升至 0.800,同时 MAE 从 0.071 下降至 0.067,表明 MSSOE 能有效增强编码域输入的可分割性并降低误检与漏检带来的像素误差。其次,在固定输入适配为 OE 的情况下,将主干由 U-Net 替换为本文提出的 PGMFNet,检测结果也明显提高,IoU 从 0.783 提升至 0.817,Dice 从 0.879 提升至 0.889, S_{α} 从 0.872 提升至 0.892,说明 PGMFNet 在特征表达与结构保持方面更具优势。最后,当同时采用 MSSOE 与 PGMFNet 时取得最佳结果: $F_{\beta}^w = 0.886$ 、 $MAE = 0.057$ 、 $E_{\varepsilon} = 0.905$ 、 $S_{\alpha} = 0.895$ 、 $Dice = 0.903$ 、 $IoU = 0.842$,相较于 OE+PGMFNet 仍有进一步提升 IoU 提升到 0.842、MAE 下降至 0.057,表明输入适配改进与主干结构优化具有互补性,可共同提升整体分割性能。

表 3 消融实验结果

Table 3 Ablation experiment results

实验配置	F_{β}^w	MAE	E_{ε}	S_{α}	Dice	IoU
OE+U-Net	0.861	0.071	0.881	0.872	0.879	0.783
MSSOE+U-Net	0.866	0.067	0.890	0.879	0.882	0.800
OE+PGMFNet	0.874	0.063	0.893	0.892	0.889	0.817
本文方法	0.886	0.057	0.905	0.895	0.903	0.842

为进一步说明前端模块在编码域缺陷表征中的具体作用,本文补充了中间结果可视化分析,如图 14 所示。考虑到 OE 和 MSSOE 的输出均属于前端模块产生的多通道浅层结构表征,本文在网络前向传播过程中提取对

应位置的特征张量,并采用通道响应平均方式,得到单通道响应图;随后对其进行归一化,并以灰度图形式进行可视化展示。为保证不同前端输出之间的可比性,OE 与 MSSOE 均采用相同的聚合与归一化方式进行处理。该灰度图仅用于反映前端模块在不同空间位置上的响应强

弱分布,其中亮度较高区域表示该位置具有更强的特征响应,可能包含更丰富的缺陷相关结构线索;亮度较低区域则表示响应较弱。该中间可视化结果并不表示最终分割结果,而是用于分析前端模块对缺陷相关区域的表征能力。




图 14 OE 与 MSSOE 中间响应及最终分割结果可视化对比

Fig. 14 Visual comparison of OE and MSSOE intermediate responses and corresponding final segmentation results

从图 14 可以看出,OE 模块已能够在缺陷相关区域形成一定程度的初步响应,其高响应位置与缺陷主体区域具有一定空间对应关系,但整体响应仍较为分散,对不同形态缺陷的主体区域聚焦能力和局部结构表达仍显不足。相比之下,MSSOE 输出在缺陷主体区域表现出更为集中的亮度响应,背景区域的无关弱响应有所减弱,并能够在一定程度上增强细长条带区域、块状缺陷区域以及复杂边界区域的结构线索。与之对应,基于 MSSOE 的最终分割结果在区域完整性和边界贴合程度上也更接近真值图。上述结果表明,MSSOE 并非直接输出分割结果,而是通过增强编码图像中的缺陷相关结构响应,为后续分割网络提供更有效的浅层结构表征,这与后续分割结果在区域完整性和边界贴合程度上的改善趋势基本一致。

3 结 论

本文面向钢轨表面缺陷的无透镜编码域分割任务,搭建了无透镜成像采集系统,并基于 NEU RSDDS-AUG 构建了钢轨表面缺陷无透镜编码图像数据集;在此基础上,提出了一种无需显式重建的分割网络 MSSOE-PGMFNet。在统一训练与测试设置下的实验结果验证了所提方法的有效性。

定量结果表明,与 U-Net、DeepLabV3+、TransUNet、LOINet、RecSegNet 和 FDTDNet 等代表性方法相比,本文

方法取得了整体最优的分割性能, $\text{IoU} = 0.842$ 、 $\text{Dice} = 0.903$ 、 $\text{MAE} = 0.057$,并表现出更均衡的区域重叠、结构一致性与像素误差优势。消融实验结果进一步验证了所提模块的性能,在 U-Net 前端引入 MSSOE 后, IoU 由 0.783 提升至 0.800, MAE 由 0.071 降至 0.067;将主干替换为 PGMFNet 可获得更显著的性能提升: IoU 由 0.783 提升至 0.817。在此基础上,结合 MSSOE 与 PGMFNet 可进一步达到最优结果: $\text{IoU} = 0.842$ 、 $\text{Dice} = 0.903$ 、 $\text{MAE} = 0.057$,说明输入适配增强与主干结构优化在性能提升上具有互补作用。

本文提出的方法为无透镜编码图像条件下的钢轨表面缺陷分割提供了一种可行的技术方案,也为复杂编码观测条件下的细粒度工业缺陷分割研究提供了参考。对于更贴近实际工况的系统部署与应用,仍有待在后续工作中结合更真实的采集场景与更丰富的数据条件进一步研究。

参考文献

- [1] YAN Y H, JIA X J, SONG K CH, et al. Specificity autocorrelation integration network for surface defect detection of no-service rail [J]. Optics and Lasers in Engineering, 2024, 172: 107862.
- [2] XIA Y W, HAN S W, KWON H J. Image generation and recognition for railway surface defect detection [J]. Sensors, 2023, 23(10): 4793.

- [3] 赵海丽, 狄子隆, 景文博, 等. 融合动态卷积与可变形注意力的钢材缺陷检测[J]. 仪器仪表学报, 2025, 46(12): 75-86.
- ZHAO H L, DI Z L, JING W B, et al. Steel defect detection integrating dynamic convolution and deformable attention[J]. Chinese Journal of Scientific Instrument, 2025, 46(12): 75-86.
- [4] 罗晖, 章硕生, 曾伟, 等. 基于改进 Retinex 与双 CNNs 的钢轨表面缺陷图像增强算法研究[J]. 电子测量技术, 2025, 48(13): 189-198.
- LUO H, ZHANG SH SH, ZENG W, et al. Research on rail surface defect image enhancement algorithm based on improved Retinex and dual CNNs [J]. Electronic Measurement Technology, 2025, 48(13): 189-198.
- [5] 魏新园, 周京欢, 张楠, 等. 基于深度迁移学习的超声缺陷识别方法研究[J]. 仪器仪表学报, 2024, 45(12): 256-263.
- WEI X Y, ZHOU J H, ZHANG N, et al. Research on ultrasonic defect recognition method based on deep transfer learning [J]. Chinese Journal of Scientific Instrument, 2024, 45(12): 256-263.
- [6] 李秀艳, 夏琦琦, 王琦, 等. 基于深度学习与多频电磁阵列检测的金属板材表面和内部缺陷识别方法[J]. 电子测量技术, 2021, 44(4): 118-125.
- LI X Y, XIA Q Q, WANG Q, et al. Surface and internal defect recognition method for metal plates based on deep learning and multi-frequency electromagnetic array detection [J]. Electronic Measurement Technology, 2021, 44(4): 118-125.
- [7] 熊龙辉, 张玉华, 马运忠, 等. 基于涡流检测和神经网络的钢轨表面滚动接触疲劳裂纹特征评估[J]. 中国铁道科学, 2021, 42(5): 69-75.
- XIONG L H, ZHANG Y H, MA Y ZH, et al. Evaluation of rolling contact fatigue crack characteristics on steel rail surface based on eddy current detection and neural network[J]. China Railway Science, 2021, 42(5): 69-75.
- [8] 许宇帆, 贾银亮, 张润华, 等. 基于相关性的钢轨缺陷漏磁检测提高干扰抑制[J]. 电子测量技术, 2022, 45(4): 147-152.
- XU Y F, JIA Y L, ZHANG R H, et al. Suppression of induction detection distortion due to magnetic leakage from rail defects based on correlation [J]. Electronic Measurement Technology, 2022, 45(4): 147-152.
- [9] 廖韦韬, 王海涛, 江奕, 等. 基于激光超声体波的轨头内部缺陷检测方法研究[J]. 仪器仪表学报, 2021, 42(10): 221-229.
- LIAO W T, WANG H T, JIANG Y, et al. Research on track head internal defect detection method based on laser ultrasonic body waves [J]. Chinese Journal of Scientific Instrument, 2021, 42(10): 221-229.
- [10] GONG W D, AKBAR M F, JAWAD G N, et al. A magnetic field concentration method for magnetic flux leakage detection of rail-top surface cracks [J]. IEEE Access, 2024, 12: 43245-43254.
- [11] XUE ZH Q, XU Y D, HU M, et al. Systematic review: Ultrasonic technology for detecting rail defects [J]. Construction and Building Materials, 2023, 368: 130409.
- [12] ZENG Z Y, WU J, ZHENG M F, et al. Rail flaw detection via Kolmogorov entropy of chaotic oscillator based on ultrasonic guided waves [J]. Sensors, 2024, 24(9): 2730.
- [13] 赵亚凤, 宋文华, 刘晓璐, 等. 基于改进 YOLOv7 的钢轨缺陷检测方法 [J]. 电子测量技术, 2025, 47(20): 177-185.
- ZHAO Y F, SONG W H, LIU X L, et al. Rail defect detection method based on improved YOLOv7 [J]. Electronic Measurement Technology, 2025, 47(20): 177-185.
- [14] 孙铁强, 魏光辉, 宋超, 等. 基于 YOLO 的多模态钢轨表面缺陷检测方法 [J]. 电子测量技术, 2025, 47(21): 72-81.
- SUN T Q, WEI G H, SONG CH, et al. YOLO-based multimodal rail surface defect detection method [J]. Electronic Measurement Technology, 2025, 47(21): 72-81.
- [15] MENG SH J, KUANG S Y, MA ZH, et al. MtlrNet: An effective deep multitask learning architecture for rail crack detection [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 3181940.
- [16] WU Y P, CHEN P, QIN Y, et al. Automatic railroad track components inspection using hybrid deep learning framework [J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 3265636.
- [17] MA SH, SONG K CH, NIU M H, et al. Feature-based domain disentanglement and randomization: A generalized framework for rail surface defect segmentation in unseen scenarios [J]. Advanced Engineering Informatics, 2024, 59: 102274.
- [18] SI CH H, LUO H, HAN Y L, et al. Rail-STrans: A rail surface defect segmentation method based on improved Swin Transformer [J]. Applied Sciences, 2024, 14(9): 3629.
- [19] PAN Y CH, CHEN J S, WU P W, et al. Enhanced rail

- surface defect segmentation using polarization imaging and dual-stream feature fusion [J]. *Sensors*, 2025, 25(11):3546.
- [20] MIN Y ZH, LI J F, LI Y X. Rail surface defect detection based on improved UPerNet and connected component analysis [J]. *Computers, Materials & Continua*, 2023, 77(1):941-962.
- [21] CHEN X Y, SHA H, CHEN CH Y, et al. Adaptive lensless microscopic imaging with unknown phase modulation [J]. *Biomedical Optics Express*, 2025, 16(3):1160-1171.
- [22] 顿雄, 付强, 李浩天, 等. 计算成像前沿进展[J]. *中国图象图形学报*, 2022, 27(6):1840-1876.
- DUN X, FU Q, LI H T, et al. Advances in computational imaging [J]. *Journal of Image and Graphics*, 2022, 27(6):1840-1876.
- [23] CHEN Y, WU X J, LU L P, et al. Pixel-super-resolved lens-free quantitative phase microscopy with partially coherent illumination[J]. *NPJ Nanophotonics*, 2024(6):1-9.
- [24] YANG L M, WANG R H, ZHAO Q H, et al. Lensless polarimetric coded ptychography for high-resolution, high-throughput gigapixel birefringence imaging on a chip[J]. *Photonics Research*, 2023, 11(12):2242-2255.
- [25] TIAN ZH Q, LI L N, MA J SH, et al. CFZA camera: A high-resolution lensless imaging technique based on compound Fresnel zone aperture [J]. *Optics Letters*, 2024, 49(12):3532-3535.
- [26] 邓煜豪, 许新宇, 陈念, 等. 细胞成像电学双模探测系统设计[J]. *电子测量与仪器学报*, 2025, 39(7):23-31.
- DENG Y H, XU X Y, CHEN N, et al. Design of electrical bimodal detection system for cell imaging[J]. *Journal of Electronic Measurement and Instrumentation*, 2025, 39(7):23-31.
- [27] ZHANG Y ER, WU ZH Y, LIN P Y, et al. Hand gestures recognition in videos taken with a lensless camera [J]. *Optics Express*, 2022, 30(22):39520-39533.
- [28] 陈凯余, 李颖, 李政岱, 等. 无透镜成像系统中的无重建目标识别技术[J]. *激光与光电子学进展*, 2024, 61(8):155-161.
- CHEN K Y, LI Y, LI ZH D, et al. Target recognition technology without reconstruction in lensless imaging systems[J]. *Laser & Optoelectronics Progress*, 2024, 61(8):155-161.
- [29] YIN X J, YUE H J, ZHANG M X, et al. Inferring objects from lensless imaging measurements [J]. *IEEE Transactions on Computational Imaging*, 2023, 8:1265-1276.
- [30] YIN X J, YUE H J, YUE H H, et al. A multi-task deep learning framework integrating segmentation and reconstruction for lensless imaging [J]. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2024, 8(6):3834-3847.
- [31] YIN X J, YUE H H. Reveal object in lensless photography via region gaze and amplification [C]. *International Conference on Learning Representations*, 2025.
- [32] SILVA NETO J R C S A V, KAWACHI H, YAGI Y, et al. Self-supervised neural reconstructions for lensless imaging[J]. *Optical Review*, 2025, 32(4):664-668.
- [33] SUN M J, JING X T, MA Y X, et al. Lensless imaging via LED array based computational ghost imaging [J]. *Optics & Laser Technology*, 2025, 180:111401.
- [34] BEZZAM E, PERRON Y, VETTERLI M. Towards robust and generalizable lensless imaging with modular learned reconstruction[J]. *IEEE Transactions on Computational Imaging*, 2025, 11:213-227.
- [35] LEE K C, BAE J, BAEK N, et al. Design and single-shot fabrication of lensless cameras with arbitrary point spread functions[J]. *Optica*, 2023, 10(1):72-80.
- [36] LIU R B, LIU ZH, WOLF M G A, et al. Physics-informed generative real-time lens-free imaging[J]. *Cell Reports Physical Science*, 2025, 6(9):102792.
- [37] ZHANG Q H, LIU Y R, XU ZH C, et al. Reconstruction of lensless images using multi-scale attention block [C]. *Ninth Symposium on Novel Photoelectronic Detection Technology and Applications*, 2023: 2666589.
- [38] KHAN S S, SUNDAR V, BOOMINATHAN V, et al. FlatNet: Towards photorealistic scene reconstruction from lensless measurements[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, 44(4):1934-1948.
- [39] PAN X X, NAKAMURA T, CHEN X, et al. Lensless inference camera: Incoherent object recognition through a thin mask with LBP map generation[J]. *Optics Express*, 2021, 29(7):9758-9771.
- [40] LI Y, LI ZH D, CHEN K Y, et al. MWDNS: Reconstruction in multi-scale feature spaces for lensless imaging [J]. *Optics Express*, 2023, 31(23):39088-39101.
- [41] NI X F, FIEGUTH P W, MA Z J, et al. Defect detection on multi-type rail surfaces via IoU decoupling

and multi-information alignment [J]. Advanced Engineering Informatics, 2024, 62:102717.

[42] LI AO H, LI D CH, WANG AN J. A two-stage YOLOv5s-U-Net framework for defect localization and segmentation in overhead transmission lines [J]. Sensors, 2025, 25(9):2903.

[43] WEN G CH, CHENG L, YUAN H W, et al. Surface defect detection based on adaptive multi-scale feature fusion [J]. Sensors, 2025, 25(6):1720.

[44] SUN Y G, GENG S Y, GUO H P, et al. A strip steel surface defect salient object detection based on channel, spatial and self-attention mechanisms [J]. Electronics, 2024, 13(21):4277.

[45] CUI W Q, SONG K CH, JIA X J, et al. An efficient targeted design for real-time defect detection of surface defects [J]. Optics and Lasers in Engineering, 2024, 178:108174.

作者简介



崔泽光,2023 年于晋中学院获得学士学位,现为中北大学硕士研究生,主要研究方向为钢轨缺陷检测。
E-mail:cuizeguang845@gmail.com

Cui Zeguang received his B.Sc. degree from Jinzhong University in 2023. He is currently a master’s student at North University of China. His main research interest is steel rail defect detection.



邵星灵(通信作者),2009 年于中北大学获得学士学位,2012 年于中北大学获得硕士学位,2016 年于北京航空航天大学获得博士学位,现为中北大学电气与控制工程学院教授/副院长,主要研究方向为无人系统集群智能与协同控制。
E-mail:shaoxl@nuc.edu.cn

Shao Xingling (Corresponding author) received his B.Sc. and M.Sc. degrees both from North University of China in 2009 and 2012, respectively, his Ph.D. degree from Beihang University in 2016. He is currently a professor and vice dean at

the School of Electrical and Control Engineering of North University. His main research interests include unmanned system cluster intelligence and collaborative control.




李秀源,2012 年于西北农林科技大学获得学士学位,2017 年于西安交通大学获得博士学位,现为中北大学仪器与电子学院讲师,主要研究方向为视觉测量与智能仪器。
E-mail:lixuyuannuc@126.com

Li Xiuyuan received his B.Sc. degree from Northwest A&F University in 2012, and received his Ph.D. degree from Xi’an Jiaotong University in 2017. He is currently a lecturer at the Instrument and Electronics College of North University. His main research interests include Visual measurement and intelligent instruments.



邓瑞祥,2016 年于沈阳工业大学获得学士学位,2023 年于东北大学获得博士学位,现为中北大学电气与控制工程学院讲师,主要研究方向为故障诊断与健康管理。
E-mail:20230102@nuc.edu.cn

Deng Ruixiang received his B.Sc. degree from Shenyang University of Technology in 2016, and received his Ph.D. degree from Northeastern University in 2023. He is currently a lecturer at the School of Electrical and Control Engineering of North University of China. His main research interests include fault diagnosis and health management.



闫佳乐,2019 年于湖北汽车工业学院获得学士学位,2023 年于合肥大学(原合肥学院)获得硕士学位,现为中北大学仪器与电子学院博士,主要研究方向为智能低光照图像增强。
E-mail:yanjl2025@163.com

Yan Jiale received his B.Sc. degree from Hubei University of Automotive Technology in 2019, and received his M.Sc. degree from Hefei University in 2023. He is currently a doctoral student at the Instrument and Electronics College of North University. His main research interest is intelligent low-light image enhancement.