文章编号:1673-0291(2026)02-0165-09 **DOI**:10.11860/j.issn.1673-0291.20250113

基于多层级分解-融合机制的铁路弱光图像增强方法

王 鑫[1],司文斌[2],李 豪[2],秦君鹏[2],张金鑫[2]
(1.国能朔黄铁路发展有限责任公司肃宁分公司,河北 沧州 063250;
2.成都唐源电气股份有限公司,成都 610046)

摘 要:针对铁路夜间场景中弱光图像普遍存在的亮度分布不均、高频细节缺失及跨域特征失配等问题,提出一种基于多层级分解-融合机制的铁路弱光图像增强方法.首先,构建多级残差分解模块与多尺度特征融合机制的协同架构,实现全局光照校正、局部对比度提升与高频细节还原;其次,引入亮度感知注意力机制,构建聚焦亮度调控与细节增强的铁路弱光图像增强框架,通过可学习权重对增强区域进行自适应调节,有效抑制过曝并增强暗区细节;再次,建立融合机制实现跨层特征的动态融合,优化全局结构与局部纹理的协同表达;最后,将提出的模型与多种基线模型进行比较,并通过消融实验验证各个模块的有效性.实验结果表明:本方法可显著提高铁路图像增强效果,在LOLv1数据集上表现出更强的细节复原与曝光控制能力,峰值信噪比(Peak Signal-to-Noise Ratio,PSNR)提升了0.63~9.13 dB,结构相似性指数(Structural Similarity Index Measure,SSIM)提升了0.013~0.325;消融实验验证了所提模块对模型性能的提升作用.此外,通过构建铁路图像弱光数据集RLL,与多种弱光图像增强方法开展对比及可视化分析,进一步验证了本文方法在增强效果上的优越性.

关键词:弱光图像增强;多层级分解;铁路弱光图像处理;多尺度融合
中图分类号:U298 **文献标志码**:A

Railway low-light image enhancement method based on multi-level decomposition-fusion mechanism

WANG Xin[1], *SI Wenbin*[2], *LI Hao*[2], *QIN Junpeng*[2], *ZHANG Jinxin*[2]
(1.CHN Energy Shuohuang Railway Development Co., Ltd. Suning Branch, Cangzhou Hebei 063250, China;
2.Chengdu TangYuan Electric Co.,Ltd., Chengdu 610046, China)

Abstract: To address the prevalent issues of uneven brightness distribution, loss of high-frequency details, and cross-domain feature mismatch in railway low-light images at night, a railway low-light image enhancement method based on a multi-level decomposition - fusion mechanism is proposed. First, a collaborative architecture integrating a multi-level residual decomposition module and a multi-scale feature fusion mechanism is constructed to achieve global illumination correction, local contrast enhancement, and high-frequency detail restoration. Second, a luminance-aware attention mechanism is introduced to establish a railway low-light image enhancement framework focused on brightness regu-

收稿日期:2025-07-17;**修回日期**:2025-11-24
基金项目:国家重点研发计划(2023YFB4302002)
Foundation item: National Key R&D Plan (2023YFB4302002)
第一作者:王鑫(1985—),男,陕西延川人,高级工程师,硕士.研究方向为高电压与绝缘技术.**email**:510313412@qq.com.
通信作者:张金鑫(1993—),男,湖北荆州人,高级工程师,硕士.**email**:609089396@qq.com.

引用格式:王鑫,司文斌,李豪,等.基于多层级分解-融合机制的铁路弱光图像增强方法[J].北京交通大学学报,2026,50(2):165-173.
WANG Xin, SI Wenbin, LI Hao, et al. Railway low-light image enhancement method based on multi-level decomposition-fusion mechanism[J]. Journal of Beijing Jiaotong University, 2026, 50(2): 165-173.(in Chinese)

lation and detail enhancement. By utilizing learnable weights, the enhancement regions are adaptively adjusted, effectively suppressing overexposure while enhancing details in dark areas. Third, the fusion mechanism enables the dynamic integration of cross-level features, optimizing the synergistic representation of global structures and local textures. Finally, the proposed model is compared with various baseline methods, and ablation studies are conducted to validate the effectiveness of each module. Experimental results indicate that the proposed method significantly improves railway image enhancement performance. On the LOLv1 dataset, it exhibits superior detail restoration and exposure control capabilities, with the Peak Signal-to-Noise Ratio (PSNR) improving by 0.63～9.13 dB and the Structural Similarity Index (SSIM) increasing by 0.013～0.325. Ablation experiments further confirm the contribution of the proposed modules to overall model performance. Furthermore, a dedicated railway low-light image dataset (RLL) is constructed. Through comparative and visual analyses against multiple existing low-light image enhancement methods, the superiority of the proposed method is robustly validated.

Keywords: low-light image enhancement; multi-level decomposition; railway low-light image processing; multi-scale fusion

随着计算机视觉技术在铁路安全检测中的深度应用,隧道、夜间及低能见度环境下的图像退化问题日益凸显[1].在夜间、隧道、涵洞、雨雾天气等典型铁路弱光场景中,图像退化主要表现为三方面:第一,亮度与对比度缺失使轨道纹理、信号灯状态、接触网零部件等关键细节难以辨识[2],导致故障漏检率升高[3];第二,为提升图像亮度采用的长曝光或高感光设置,易引入大量电磁噪声与颗粒噪点,掩盖接触网连接处烧蚀、脱落等微小缺陷,进而导致弱光条件下相关检测任务的误报率可达正常光照场景的1.3倍以上[4];第三,接触网定位管、电连接器及吊弦等高频结构,在低照度环境下易出现边缘模糊,导致检测算法特征提取能力下降、识别稳定性降低,这一问题对接触网2C装置的实际部署和运行构成了显著挑战[5].铁路弱光图像增强能够改善图像亮度分布、恢复关键结构细节并抑制噪声干扰,从而提升轨道缺陷检测、接触网部件识别等任务的可靠性,对于保障行车安全、提升检测精度以及实现智能运维具有重要意义[6].

近年来,随着计算机视觉与深度学习的快速发展,铁路弱光图像增强技术逐渐由传统图像处理方法向智能化深度学习方法转变.当前现有的铁路弱光图像增强技术主要分为基于图像处理与物理模型的方法、基于学习优化的增强方法及基于深度学习的端到端增强方法三类[7].

基于图像处理与物理模型的传统方法主要包括直方图均衡化、Retinex理论及暗通道先验等.这类方法通过对图像亮度、对比度及光照分布进行显式建模,实现基础增强效果.例如,文献[8]在文献[9]基础上提出自适应Retinex模型,结合双边滤波与直方图均衡化,可有效改善铁路夜间图像中光照估计不准与过增强问题,并提升轨道纹理及接触网零部件的细节表现能力.文献[10]基于暗通道先验构建单尺度与多尺度Retinex模型,并结合自适应滤波优化光照估计,为低能见度铁路场景(如雨雾、烟尘环境)的图像增强提供了有效支持.然而,此类方法在复杂弱光条件下对噪声抑制与高频细节恢复能力有限.

基于学习优化的增强方法主要通过策略学习或参数自适应优化实现图像增强.文献[11]提出多尺度滤波与伽马变换相结合的方法,并针对局部区域进行增强,有效避免全局处理带来的噪声放大问题,从而提升暗光环境下关键部件的识别精度[12].此外,基于强化学习的单通道增强方法能够动态组合亮度调节与伽马校正等操作,对接触网关键区域(如高灰度区域)进行自适应增强,在提升局部细节的同时抑制背景噪声.此类方法在一定程度上增强了算法的灵活性与场景适应能力.

基于深度学习的端到端增强方法,包括卷积神经网络(Convolutional Neural Network, CNN)、生成对抗网络(Generative Adversarial Network,GAN)[13]以及近年来兴起的Transformer模型等.此类方法通过学习弱光图像与正常光图像之间的映射关系,实现整体图像质量的显著提升.文献[14]提出的改进型图像增强算法显著提高了轨道分割交并比与边缘识别率;文献[15]基于Transformer架构并融合Mamba机制实现了对车载视频的实时增强处理,为高速列车夜间运行提供了高效支持.同时,轻量化卷积网络结合混合空洞结构可有效扩大感受野,满足高速运行场景下的实时处理需求[16];多模态融合

方法则通过引入红外与激光雷达信息,弥补可见光在复杂天气条件下的感知不足[17].随着相关技术的发展,弱光图像增强已逐步从单一图像质量提升,向多模态融合与系统级应用演进,并在铁路巡检、异物检测等任务中发挥重要作用[18].

尽管当前铁路弱光图像增强技术已取得一定进展,但结合铁路场景的特殊性和实际应用需求,仍存在诸多不足,具体可归纳为两类核心问题.第一是架构局限性突出:现有多数通用的深度学习网络未充分考虑铁路场景光照的极端不均匀性,在处理隧道进出口强光与内部弱光交替、夜间轨道与周边环境亮度差异显著等场景时,易出现局部过曝或欠增强现象,无法兼顾全局光照均衡与局部细节保留.第二是任务特性重视不足:铁路弱光图像增强的核心需求是为后续检测任务提供高质量输入,但现有算法缺乏专门针对图像中亮度、对比度、细节等不同成分的解耦与协同优化设计,导致增强后图像细节恢复不足或噪声抑制不彻底,最终影响后续轨道裂纹、接触网缺陷等检测任务的精度,难以满足铁路全天候智能检测的实际需求.

针对上述铁路弱光图像增强技术存在的核心问题,本文提出一种铁路弱光图像增强新方法,通过构建多级残差分解模块与多尺度特征融合的协同架构,引入亮度感知注意力机制,实现全局光照校正、局部细节增强与过曝抑制的协同优化,有效解决铁路场景光照不均、细节丢失、噪声干扰等问题.该方法核心创新在于构建分层特征解耦与动态融合的双向优化机制,可对图像中的光照成分、细节成分与噪声成分进行有效分离,分别实施针对性优化;同时结合自动增强手段,自适应匹配铁路不同弱光场景的退化特性,最终实现高质量的铁路弱光图像增强,为后续智能检测任务提供可靠的图像输入支撑.

1　弱光图像增强方法

本文提出一种基于多层级分解-融合机制的弱光图像增强方法,模型架构如图 1 所示.首先,将原始的铁路弱光图像输入至弱光图像编码器中,提取丰富的层次化深度特征.其次,该特征被分为多个分支:其中一条分支进入多级残差分解模块(Residual Decomposition,RD),将复杂的图像特征解耦为多层级的残差表示[19],并构建代码本;另一条分支输入解码器中进行图像的重建与恢复.为了最大化保留原始图像的空间细节,本方法引入跨尺度融合模块,通过残差连接将编码器提取的浅层特征与解码器输出的深层重建特征进行深度融合.再次,融合后的特征进入亮度感知注意力模块(Brightness-aware Attention,BA),该模块能够自适应感知图像的空间光照分布并动态分配注意力权重,重点增强极暗区域.最后,通过自动增强策略(Auto Augment,AA)对调整后的图像进行自动增强[20].

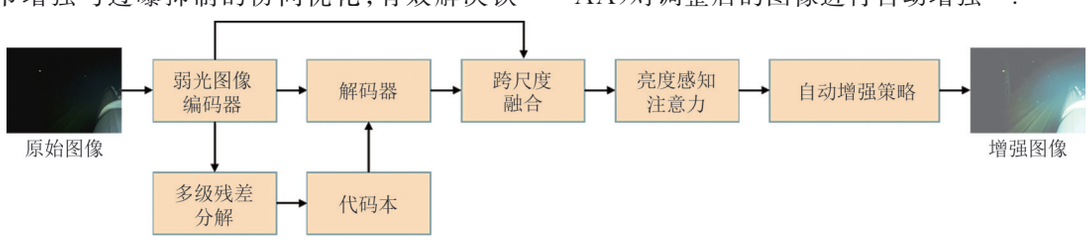


图 1　基于多层级分解-融合机制的弱光图像增强方法架构

Fig.1　Architecture of the low-light image enhancement method based on a multi-level decomposition-fusion mechanism

1.1　多级残差分解模块的特征层次化表示

为还原弱光条件下的图像特征,本文提出多级残差分解,旨在构建层次化且高表达力的正常光代码本,其核心是通过迭代残差分解实像特征的精细化表示.多级残差分解模块如图 2 所示.输入正常光图像 I,通过编码器 E_{L} 提取的第 i 层多尺度特征为 $\{F_i^{\mathrm{L}}\}$.最高层特征 $F_3^{\mathrm{L}}\in\mathbb{R}^{h\times w\times c}$ 被展开为 N 个重叠的特征块 $R_i^{(0)}$,其中 h 和 w 分别表示特征图的高度和宽

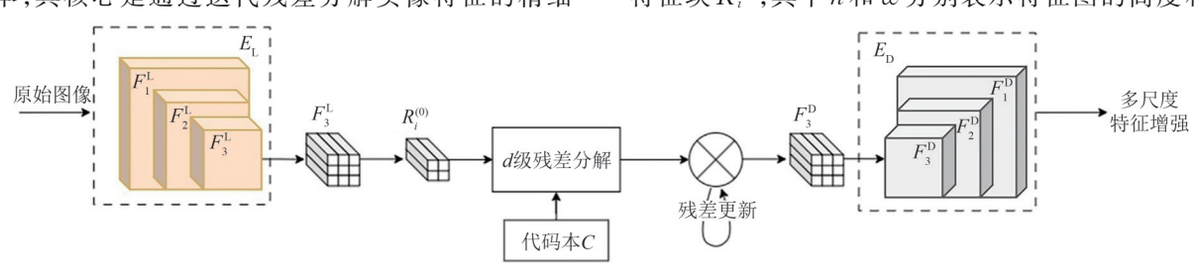


图 2　多级残差分解模块示意图

Fig.2　Illustration of the multi-level residual decomposition model

度，c 表示通道数．每个特征块 $R_i^{(d)}$ 通过残差分解策略逐步逼近代码本 C 中的元素，其迭代过程可形式化为

$$R_i^{(d)} = R_i^{(d-1)} - \Delta F_i^{(d-1)} \tag{1}$$

$$\Delta F_i^{(d)} = \arg\min |R_i^{(d)} - C|_2^2 \tag{2}$$

式中：$R_i^{(0)}$ 为初始残差特征块；$\Delta F_i^{(d)}$ 为第 d 级分解结果．最终分解后的块 R_i^{q} 通过折叠操作重构为特征 F_3^{D}，并输入解码器 E_{D} 得到上采样图像特征 $\{F_i^{\mathrm{D}}\}$．多级残差分解的流程为：首先将输入的特征拆开为特征块，对每一级残差分解，都将当前特征块 $R_i^{(d)}$ 与代码本 C 进行最近邻搜索，主要作用是将连续的高维特征空间离散化为有限语义原型；然后在每次迭代中进行残差更新，通过叠加多级残差保留更精细的特征（如纹理、边缘）．

残差分解利用多阶段迭代逼近，可大幅增强代码本的表征能力，每一个残差特征块 $R_i^{(d)}$ 的产生都是基于前一级的残差和分解误差，进而使后续分解过程可针对性地处理未被充分表征的细节分量．这种层次化的分解方式从数学上等同于把原始特征投影到由代码本张成的子空间，再通过残差项修正投影误差，在有限的代码本容量下达到更高重构精度．

1.2 融合机制的多尺度特征增强

虽然多级残差分解模块可以很好地恢复全局结构，但是由于编码器的下采样操作，不可避免地会丢失一些高频细节．为此，本文设计多尺度融合分支，通过将编码器 E_{L} 的局部细节和解码器 E_{D} 的全局先验结合起来，以达到增强细节和降低噪声的目的．融合机制架构如图 3 所示，编码器通过残差分解模块从代码本 C 中提取与正常光特征对齐的高层语义信息．然后将所有特征统一采样至同一尺度并进行拼接融合，有效结合编码器的细节信息与解码器的语义信息，从而保留多尺度特征[21]．在融合模块中，跨尺度特征拼接后的通道维度通过卷积进行降维，采用 3×3 卷积，保留关键特征信息，该融合过程为

$$F_1^{\mathrm{cat}} = \mathrm{Concat}(F_3^{\mathrm{L}}\uparrow, F_2^{\mathrm{L}}, F_1^{\mathrm{L}}\downarrow, F_2^{\mathrm{D}}, F_1^{\mathrm{D}}\downarrow) \tag{3}$$

式中：F_j^{cat} 为第 j 次拼接融合后的特征图；$\mathrm{Concat}(\cdot)$ 表示沿通道维度拼接特征；$\uparrow$ 与 $\downarrow$ 分别表示 2 倍双线性上采样与平均池化下采样，上采样使用双线性插值，下采样使用步长为 2 的卷积．

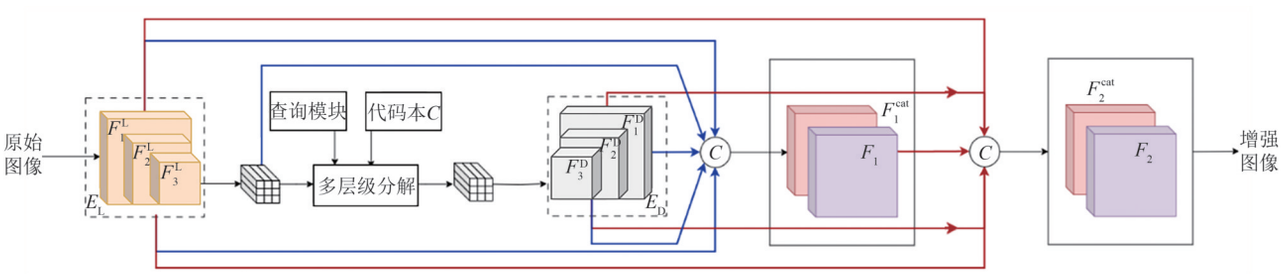


图 3 融合机制架构

Fig.3 Architecture of the fusion mechanism

未经处理的拼接特征因通道堆叠需要通过通道自注意力机制抑制冗余通道，提取跨通道特征关联，增强关键区域的特征表达．融合特征与经过下采样后的亮度感知图 M 进行 j 次调制得到调制特征 $\{F_j\}$．将第一次经过调制的特征 F_1 重新进行上采样，与其他特征对齐后进行二次拼接生成融合特征图 F_2^{cat}，再与亮度感知图 M 进行二次调制得到高分辨率特征 F_2．最后通过 3×3 卷积将得到的特征映射为 RGB 图像．给定编码器的多尺度特征 $\{F_i^{\mathrm{L}}\}$ 与解码器的上采样特征 $\{F_i^{\mathrm{D}}\}$，融合机制在不同尺度上执行特征拼接，得到的 F_2^{cat} 为

$$F_2^{\mathrm{cat}} = \mathrm{Concat}(F_1\uparrow, F_2^{\mathrm{L}}\uparrow, F_1^{\mathrm{L}}, F_2^{\mathrm{D}}\uparrow, F_1^{\mathrm{D}}) \tag{4}$$

1.3 亮度感知注意力模块

亮度感知机制的核心挑战在于构建符合视觉感知特性的动态光照表征模型．传统 Retinex 理论将图像分解为反射分量与光照分量的乘积形式，但其线性假设难以表征复杂场景中的非线性亮度衰减规律．尽管深度学习方法可通过端到端网络学习亮度映射函数，却常因忽略局部亮度分布差异，导致增强结果出现光晕伪影或纹理丢失．本文提出的亮度感知注意力模块通过构建基于残差学习的非线性亮度表征，实现了动态特征调制与梯度敏感性的协同优化，模块结构如图 4 所示．

亮度感知图生成函数 M 蕴含着重要的物理意义，即输入图像 I 与局部卷积特征 $\mathrm{Conv}(I)$ 的残差运算，本质上可模拟人类视网膜神经节细胞对局部对比度的敏感性．ReLU 激活函数在此处起到双重作用：压制负向残差值以免对正常曝光区域进行过

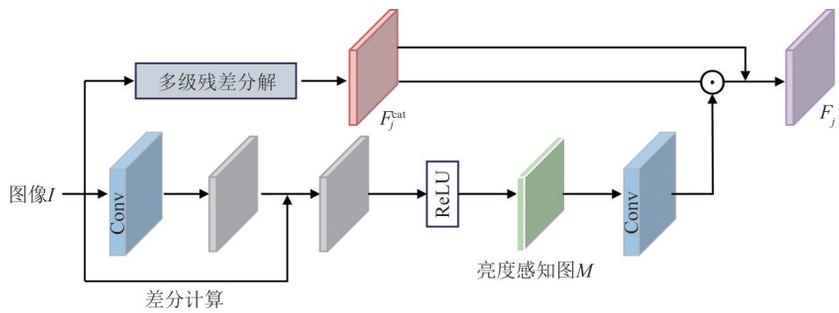


图 4　亮度感知注意力模块图

Fig.4　Brightness-aware attention module

度补偿;通过非线性截断使暗区信号更为凸显.ReLU激活函数冲破了传统伽马校正所存在的全局参数约束,使得亮度感知图M可自动关注低照度区域的细节特性.亮度感知图M通过步长为1的3层3×3卷积逐步提取多尺度亮度特征

$$M=\mathrm{ReLU}\big(I-\mathrm{Conv}(I)\big) \tag{5}$$

在特征调制阶段,亮度感知注意力通过感知公式实现空间自适应的特征增强,即

$$F_j=F_j^{\mathrm{cat}}+F_j^{\mathrm{cat}}\odot\mathrm{Conv}(M) \tag{6}$$

亮度感知注意力模块的实现分为以下3个步骤.

步骤1:对输入的弱光图像I进行卷积操作,输出特征图$\mathrm{Conv}(I)$,通过差分计算得到亮度差异,然后通过ReLU函数激活生成亮度感知图M.该过程通过相应函数保留正差值、抑制负值,从而保留相较于周围更暗的像素,直接定位图像中的弱光照区域,引导模型重点对暗区进行增强.

步骤2:通过3层3×3卷积逐步提取多尺度亮度特征,抑制亮度感知图中的高频噪声,生成全局亮度感知权重图.

步骤3:将输入特征与全局亮度感知权重执行逐元素相乘,并与原始特征进行残差相加,利用哈达玛积实现亮度差异驱动的特征选择性增强,动态调制特征响应,增强暗区细节.

1.4　基于自动增强策略的效率优化

针对弱光增强任务中训练数据分布受限的问题,提出融合自动增强策略的自适应亮度扰动机制.该策略建立了亮度变换操作的概率分布模型,通过强化学习动态优化扰动参数,突破了传统固定参数增强的局限性.定义亮度扰动空间$\mathcal{T}=\{T_k\}_{k=1}^{K}$,其中$K$为扰动变换的总数,$k$为变换索引.每个变换$T_k$对应HSV色彩空间中的三要素调整:色调偏移$\Delta H\sim\mathcal{U}(-0.1,0.1)$,饱和度缩放因子$\Delta S\sim\mathcal{U}(0.8,1.2)$,明度调整$\Delta V\sim\mathcal{U}(0.5,1.5)$.通过引入可学习的概率分布参数$\theta=(\theta_1,\theta_2,\cdots,\theta_K)$,构建扰动策略的优化目标函数[20]为

$$\max_\theta E_{T_k\sim p_\theta}[S(f(T_k(I)),f(I))-\lambda H(T_k(I),I)] \tag{7}$$

式中:$S(\cdot)$为特征相似性度量函数;$H(\cdot)$为图像失真度评估项;$f(\cdot)$为特征提取器;$T_k(\cdot)$为图像扰动增强;λ为权衡系数.该目标函数通过最大化增强样本与原始样本在特征空间的相似性,迫使网络学习对亮度扰动不敏感的特征表示,同时约束图像失真程度以避免过度偏离真实数据分布.在实际中,增强图像首先通过卷积编码器提取特征,随后通过多级残差分解生成层次化特征表示.融合模块和亮度感知注意力模块对特征进行动态调制,最终通过3×3卷积映射生成RGB图像,实现增强图像的端到端生成.

2　实验与分析

为验证本文方法的有效性,设置对比实验和消融实验,并对实验结果进行分析.实验所使用的硬件平台为:NVIDIA RTX 3090 GPU(24 GB显存)+Intel i9-12900K CPU;软件支持为:Python 3.8.0、PyTorch 1.8.0以及所适配的CUDA版本.

2.1　数据集构建

为了能够全面且精准地验证所提方法在铁路弱光环境下的实际应用效果,构建铁路弱光图像数据集RLL,该数据集包含共计约800张图像,部分图像示例如图5所示.图像涵盖多种典型的铁路弱光场景,包含夜晚的铁路轨道、隧道、周边区域以及铁路枢纽处等不同元素组合而成的画面,设计铁路在实际运营中可能面临的各种低光照情况.

本数据集旨在为低光图像增强任务提供高质量的基准数据.数据采集环节在真实的铁路运营环境下进行,利用搭载高精度工业相机的专业采集车,沿既定线路进行系统性的数据采集.为构建精准配对的样本集,采用固定机位、同步拍摄的方式,通过精确控制曝光时间与光圈大小等关键参数,在同一场景下直接获取从低光(欠曝)到正常曝光的不同亮度



（a）铁路场景

（b）隧道场景

（c）高脚架场景

图5 铁路弱光数据集RLL部分示意图

Fig.5 Sample images from the RLL dataset

等级的图像，最终形成了200组严格匹配的低光-正常光图像对.该数据集可有效捕捉铁路场景下的复杂光照变化与丰富的纹理细节，为算法训练与评估提供了可靠的数据基础.

为评估本文方法的泛化性，使用LOLv1数据集进行验证.LOLv1是低照度图像增强领域常用的基准数据集，包含500对真实场景下采集的低照度图像与其对应的正常曝光图像.其中，400对用于训练，100对用于测试.该数据集涵盖了多种照明条件和场景类型，包括室内与室外环境，能够有效评估增强算法在不同场景下的泛化能力.所有图像均经过严格配准，且参考图像通过长曝光方式获得，为有监督学习方法提供了高质量的学习目标.

2.2 对比实验

为验证所提方法的优越性，本文将其与多种主流弱光增强方法进行对比，包括LPNet[22]、DCC-Net[23]、MIR-Net[24]、SNR[25]、Zero-DCE++[26]、KinD[27]和RUAS[28]，所有实验均在LOLv1数据集上开展.为确保公平性，实验采用统一的训练策略对各模型进行训练，并对其增强效果进行量化评估.评估指标统一采用峰值信噪比（Peak Signal-to-Noise Ratio，PSNR）和结构相似性指数（Structure Similarity Index Measure，SSIM）.PSNR属于数字信号保真度评估的关键指标，为信号峰值能量与失真噪声的比率；PSNR数值用分贝（dB）来表示信号失真程度，数值范围与信号质量成正比.当PSNR大于30 dB时，重建信号和原始信号在人类视觉系统（Human Visual System，HVS）中的感知差异基本达到不可分辨的水平.PSNR的物理意义依赖于线性系统假设，在非线性视觉感知特性模型建立方面具有理论上的局限性.而SSIM属于依靠人类视觉感知特性的图像质量评估手段，它通过对亮度、对比度以及结构特征的相似性加以量化，从而有效地评判两幅图像的感知相似度.

实验结果如表1所示.由表1可知：本文方法在PSNR和SSIM两项指标上均优于其他经典方法，展现出更强的图像增强性能与结构保真能力，验证了本文方法的有效性与先进性；Zero-DCE++因噪声抑制能力不足，PSNR和SSIM仅为16.11和0.530；LPNet通过多尺度特征融合对弱光图片进行处理后，PSNR达到21.46、SSIM达到0.802，可能是全局增强策略导致的暗区噪声与高光过曝对结果产生了影响；DCC-Net在铁路场景的细节保留上存在局限，依靠颜色一致性约束将SSIM优化至0.810，PSNR为22.72；MIR-Net通过聚合上下文信息进行优化，PSNR为24.14、SSIM为0.830，局部过曝问题可能对其结果造成了影响；SNR通过动态噪声估计使PSNR和SSIM分别达到24.61和0.842；本文方法通过多级残差分解模块分层处理光照、对比度和细节，结合亮度感知注意力自适应调节增强权重，以PSNR为25.24、SSIM为0.855的性能优于所有对比方法.

表 1　在 LOLv1 数据集上的对比实验结果

Tab.1　Comparative experimental results on the LOLv1 dataset

模型	PSNR / dB	SSIM
Zero-DCE++	16.11	0.530
LPNet	21.46	0.802
KinD	14.616	0.636
DCC-Net	22.72	0.810
MIR-Net	24.14	0.830
RUAS	18.226	0.717
SNR	24.61	0.842
本文方法	**25.24**	**0.855**

为进一步验证所提方法的实际应用效果,将构建数据集 RLL 应用于模型测试,并与主流方法 SNR 的增强效果进行对比,结果如表 2 所示.由表 2 可知,本文方法在 PSNR 和 SSIM 指标上均优于现有模型,进一步验证了所提方法在铁路弱光场景下的有效性与优越性.

表 2　在 RLL 数据集上的对比实验结果

Tab.2　Comparative experimental results on the RLL dataset

模型	PSNR / dB	SSIM
SNR	26.09	0.673
本文方法	**29.01**	**0.781**

为更直观地展示各方法的增强效果,对多种模型的弱光图像增强结果进行可视化,对比效果如图 6 所示.由图 6 可知:Zero-DCE++在噪声抑制方面表现较差,增强后图像中出现明显的雪花状斑点,影响整体视觉质量;MIR-Net 与本文提出的方法在噪声处理方面表现更为出色,有效提升了图像的清晰度与稳定性;进一步对比本文方法与 MIR-Net 的增强结果可以看出,本文方法在图像轮廓的保持上更具优势,结构更加清晰,且 MIR-Net 存在局部过曝现象,影响高亮区域的真实感与可视性.综上所述,相较于 Zero-DCE++等现有方法,所提出的多层级分解与融合的联合优化策略可有效缓解弱光图像增强过程中常见的细节丢失与噪声放大问题,引入的亮度感知注意力模块通过动态亮度掩码引导特征加权,实现了对局部亮度变化的精准适应,同时,自动增强模块利用数据驱动的策略优化模型训练,显著提升了泛化能力.



(a) 输入　(b) Zero-DCE++　(c) MIR-Net　(d) SNR　(e) 本文方法

图 6　多种模型弱光图像增强效果对比

Fig.6　Visual comparison of low-light image enhancement by various models

2.3　消融实验

为验证所提模块的性能提升水平,本文设计消融实验,通过逐步引入各关键模块的方式进行对比分析,以评估其对整体性能的贡献.实验中所涉及的模块包括:多级残差分解模块(RD)、融合模块(Con)、亮度感知注意力模块(BA)以及自动增强策略(AA).所有实验均基于 LOLv1 数据集进行,该数据集包含 485 对高低曝光的训练图像和 15 张测试图像.所有模型的性能表现通过 PSNR 和 SSIM 两个指标进行衡量.

实验结果如表 3 所示.由表 3 可知:引入的 RD、Con、BA 和 AA 模块在 PSNR 指标和 SSIM 指标上均带来了不同程度的提升;添加 RD 模块后,PSNR 提升至 24.43、SSIM 显著提升至 0.802;添加 Con 模块后,SSIM 指标略微下降(下降 0.008),可能原因是在增强图像结构一致性时,融合模块的引入带来了一定干扰;BA 与 AA 模块的协同将两个指标较基线分别提升 1.1 和 0.108.综上,消融实验充分验证了各模块在铁路弱光图像增强中的有效性,能够协同提升图像质量指标并优化增强效果.

表 3　模块消融实验结果

Tab.3　Ablation experiment results on model components

RD	Con	BA	AA	PSNR/dB	SSIM
—	—	—	—	24.14	0.747
√	—	—	—	24.43	0.802
√	√	—	—	24.76	0.794
√	√	√	—	24.92	0.843
√	√	√	√	**25.24**	**0.855**

3 结论

1）针对铁路夜间场景中弱光图像增强面临的亮度分布不均、高频细节缺失及跨域特征失配等关键挑战，本文提出一种结合多级残差分解与亮度感知注意力的弱光增强方法，能够在复杂光照环境下兼顾全局亮度校正与局部细节优化，可为铁路夜间智能检测提供高质量图像支撑.

2）设计的多级残差分解模块通过分层特征投影与动态码本适配，将输入特征解耦为多尺度残差分量：低频层用于全局光照校正，中频层增强局部对比度，高频层专注于细节复原.同时，引入的亮度感知注意力模块突破了传统全局增强的局限性，通过可学习的空间权重实现对局部区域的动态增强调节.在探照灯与环境光共存的复杂照明场景下，该模块能有效增强轨道暗区特征，同时抑制高亮区域响应，从而避免过曝并增强暗部细节的还原度.融合模块通过通道-空间注意力门控机制实现双向信息交互，进一步平衡全局结构与局部细节的优化目标.

3）通过在公开数据集LOLv1以及自建的铁路弱光数据集RLL上开展实验，结果表明，在LOLv1数据集中，该方法在PSNR和SSIM两项指标上均优于现有主流模型，分别平均提高了4.97 dB和0.117.同时，在RLL数据集上的可视化结果显示，本文方法在暗区细节还原与高光压制方面具有显著优势，验证了方法的有效性与实用性.

尽管如此，本文仍存在一定局限性：在极端低照度或严重噪声污染条件下，模型的鲁棒性有待进一步提升；在跨场景迁移时仍可能出现特征适配不足的问题.针对这些不足，未来的研究将围绕铁路弱光图像增强的工程化应用与模型性能的持续升级展开：将现有框架与Transformer架构相结合，借助其建模长距离依赖的优势进一步优化图像的全局光照一致性，并探索在雪雾、沙尘暴等极端复杂环境下的铁路弱光图像增强策略，提升模型在多变天气条件下的鲁棒性与适应性；尝试融合红外与可见光图像信息，以增强模型在极低照度场景下的感知能力，构建一个更具泛化性和实用性的铁路弱光图像增强解决方案，服务于复杂环境下的铁路视觉感知任务.

参考文献(References)：

[1] 袁小军，李晨，刘昕武，等.轨道交通低能见度场景图像增强系统研究[J].图像与信号处理，2023，12(3)：302－316.
YUAN Xiaojun，LI Chen，LIU Xinwu，et al. Research on image enhancement system of low visibility scene in rail transit[J]. Journal of Image and Signal Processing，2023，12(3)：302－316.(in Chinese)

[2] 王银，王立德，邱霁.基于DenseNet结构的轨道暗光环境实时增强算法[J].西南交通大学学报，2022，57(6)：1349－1357.
WANG Yin，WANG Lide，QIU Ji. Real-time enhancement algorithm based on DenseNet structure for railroad low-light environment[J]. Journal of Southwest Jiaotong University，2022，57(6)：1349－1357.(in Chinese)

[3] 刘璐.夜间道路图像增强及车辆检测算法研究[D].长春：吉林大学，2020.
LIU Lu. Research on Nighttime Road Image Enhancement and Vehicle Detection Algorithms [D]. Changchun：Jilin University，2020.(in Chinese)

[4] 周敏飞.低照度图像增强与车辆识别技术研究[D].上海：东华大学，2020.
ZHOU Minfei. Research on Low-Illumination Image Enhancement and Vehicle Recognition Technology[D]. Shanghai：Donghua University，2020.(in Chinese)

[5] 黄辉先，陈凡浩.基于注意力机制和Retinex的低照度图像增强方法[J].激光与光电子学进展，2020，57(20)：201004.
HUANG Huixian，CHEN Fanhao. Low-illumination image enhancement method based on attention mechanism and retinex[J]. Laser & Optoelectronics Progress，2020，57(20)：201004.(in Chinese)

[6] 汪健雄，阎志远，张瀛丹，等.基于多模态信息融合的智能高速铁路旅客运输保障技术研究[J].铁道运输与经济，2023，45(2)：47－53.
WANG Jianxiong，YAN Zhiyuan，ZHANG Yingdan，et al. Intelligent passenger transportation support technology for high speed railway based on multi-modal information fusion[J]. Railway Transport and Economy，2023，45(2)：47－53.(in Chinese)

[7] 李紫薇，刘金龙，杨慧珍，等.基于深度学习的低照度图像增强算法综述[J].应用光学，2024，45(6)：1095－1107.
LI Ziwei，LIU Jinlong，YANG Huizhen，et al. Review of low-illuminance image enhancement algorithm based on deep learning[J]. Journal of Applied Optics，2024，45(6)：1095－1107.(in Chinese)

[8] JOBSON D J，RAHMAN Z，WOODELL G A. A multiscale retinex for bridging the gap between color images and the human observation of scenes[J]. IEEE Transactions on Image Processing，1997，6(7)：965－976.

[9] LAND E H，MCCANN J J. Lightness and retinex theory[J]. Journal of the Optical Society of America，1971，61(1)：1.

[10] JOBSON D J，RAHMAN Z，WOODELL G A. Properties and performance of a center/surround retinex[J].

IEEE Transactions on Image Processing, 1997, 6(3): 451－462.

[11] 梁杰琛, 张鸿铸, 魏宗寿, 等. 基于多尺度SSIF和Gamma变换的低照度图像增强算法[J]. 北京交通大学学报, 2024, 48(5): 107－117.
LIANG Jiechen, ZHANG Hongzhu, WEI Zongshou, et al. Low-light image enhancement algorithm based on multi-scale SSIF and Gamma transformation[J]. Journal of Beijing Jiaotong University, 2024, 48(5): 107－117. (in Chinese)

[12] 王珏, 洪敏轩, 夏叶桐, 等. 基于条件生成对抗网络的低照度彩色图像增强算法[J]. 红外与激光工程, 2024, 53(11): 20240238.
WANG Jue, HONG Minxuan, XIA Yetong, et al. Low-light color image enhancement algorithm based on conditional generative adversarial network[J]. Infrared and Laser Engineering, 2024, 53(11): 20240238. (in Chinese)

[13] JIANG Y F, GONG X Y, LIU D, et al. EnlightenGAN: deep light enhancement without paired supervision [J]. IEEE Transactions on Image Processing, 2021, 30: 2340－2349.

[14] LIU J Y, LIN R J, WU G Y, et al. CoCoNet: coupled contrastive learning network with multi-level feature ensemble for multi-modality image fusion[J]. International Journal of Computer Vision, 2024, 132(5): 1748－1775.

[15] LI J, QIAN J J, TAI Y, et al. MambaLLIE: implicit retinex-aware low light enhancement with global-then-local state space[C]//Advances in Neural Information Processing Systems 37. Vancouver, 2024: 27440－27462.

[16] HUANG L, QIU Q, SAPIRO G. PQ-VAE: learning hierarchical discrete representations with progressive quantization [C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Seattle, 2024: 7550－7558.

[17] 余祖俊, 周杏芳, 郭保青, 等. 面向铁路周界防护的多源图像目标检测研究综述[J]. 北京交通大学学报, 2023, 47(5): 1－15.
YU Zujun, ZHOU Xingfang, GUO Baoqing, et al. Overview of object detection using multi-source images for railway perimeter protection[J]. Journal of Beijing Jiaotong University, 2023, 47(5): 1－15. (in Chinese)

[18] 袁慕策, 姚京川, 简国辉, 等. 基于综合卫星遥感的典型铁路设施提取方法研究[J]. 航天返回与遥感, 2024, 45(1): 29－40.
YUAN Muce, YAO Jingchuan, JIAN Guohui, et al. Research on typical railway facilities extraction method based on comprehensive satellite remote sensing[J]. Spacecraft Recovery & Remote Sensing, 2024, 45(1): 29－40. (in Chinese)

[19] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[C]//Computer Vision-ECCV 2018. Cham: Springer, 2018: 3－19.

[20] CUBUK E D, ZOPH B, MANÉ D, et al. AutoAugment: learning augmentation strategies from data[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Long Beach, 2020: 113－123.

[21] LI J C, FANG F M, MEI K F, et al. Multi-scale residual network for image super-resolution[C]//Computer Vision-ECCV 2018. Cham: Springer International Publishing, 2018: 527－542.

[22] LI J Q, LI J C, FANG F M, et al. Luminance-aware pyramid network for low-light image enhancement[J]. IEEE Transactions on Multimedia, 2021, 23: 3153－3165.

[23] ZHANG Z, ZHENG H, HONG R C, et al. Deep color consistent network for low-light image enhancement[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New Orleans, 2022: 1889－1898.

[24] ZAMIR S W, ARORA A, KHAN S, et al. Learning enriched features for real image restoration and enhancement [C]//Computer Vision-ECCV 2020. Cham: Springer, 2020: 492－511.

[25] XU X G, WANG R X, FU C W, et al. SNR-aware low-light image enhancement [C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New Orleans, 2022: 17693－17703.

[26] LI C Y, GUO C L, LOY C C. Learning to enhance low-light image *via* zero-reference deep curve estimation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(8): 4225－4238.

[27] ZHANG Y H, ZHANG J W, GUO X J. Kindling the darkness: a practical low-light image enhancer[C]//Proceedings of the 27th ACM International Conference on Multimedia. Nice France, 2019: 1632－1640.

[28] LIU R S, MA L, ZHANG J A, et al. Retinex-inspired unrolling with cooperative prior architecture search for low-light image enhancement [C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville, 2021: 10556－10565.