文章编号：1003-1421(2026)07-0204-13
引用格式：张叶，李俊波，尤田，等. 普速铁路低光照环境的自适应目标检测方法研究[J]. 铁道运输与经济，2026，48(7)：204-216.
ZHANG Ye，LI Junbo，YOU Tian，et al. Research on Adaptive Object Detection Method for Low-Light Environments on Conventional Railways[J]. Railway Transport and Economy，2026，48(7)：204-216.

普速铁路低光照环境的自适应目标检测方法研究

张 叶[1]，李俊波[2]，尤 田[3]，王东妍[2]

(1.中国铁道科学研究院 研究生部，北京 100081；2.中国铁道科学研究院集团有限公司 电子计算技术研究所，北京 100081；3.华北理工大学 人工智能学院，河北 唐山 063210)

摘 要：普速铁路汛期异物侵限导致的行车安全事件时有发生，面对逐年严峻的防洪防汛工作形势，传统的人工巡查方式存在人员投入多、工作强度大等不利因素。由于普速铁路所处地形地貌多样、环境复杂、线路背景差异大，夜间普速铁路线路异物侵限事件常有发生。在普速铁路低光照条件下，现场数据呈现出高保真但低质量的特性，同时这类数据与通用特征处理范式之间存在适配性不足的问题。针对以上问题，提出一种基于深度学习的自适应低光照异常检测框架——DedarkDet，该框架能够基于输入数据自适应地学习数据增强策略以提高低光照场景下的异物检测性能。DedarkDet包括可微的轻量级图像自适应增强网络和改进的目标检测框架2部分。通过实验对DedarkDet的性能进行了全面分析，结果表明，DedarkDet在低光照场景中能够有效地提升检测性能。

关键词：深度学习；普速铁路；低光照；图像增强；异常检测
中图分类号：U298 **文献标识码**：A **DOI**：10.16668/j.cnki.issn.1003-1421.20251014006

Research on Adaptive Object Detection Method for Low-Light Environments on Conventional Railways

ZHANG Ye[1]，LI Junbo[2]，YOU Tian[3]，WANG Dongyan[2]

(1. Postgraduate Department, China Academy of Railway Sciences, Beijing 100081, China; 2. Institute of Computing Technologies, China Academy of Railway Sciences Corporation Limited, Beijing 100081, China; 3. College of Artificial Intelligence, North China University of Science and Technology, Tangshan 063210, Hebei, China)

Abstract: Train safety incidents caused by foreign object intrusion (FOI) on conventional railways during flood seasons occur frequently. Faced with the increasingly severe situation of flood prevention and control year by year, traditional manual inspection methods have disadvantages such as high labor input and high work intensity. Due to diverse terrain, complex environments, and significant line background variations of conventional railways, nighttime FOI incidents occur frequently. Under low-light conditions on conventional railways, field data exhibits high fidelity but low quality characteristics, while insufficient compatibility exists between such data and general feature processing paradigms. To address these issues, this paper proposed an adaptive low-light anomaly detection framework based on deep learning, namely DedarkDet, which could adaptively

收稿日期：2025-10-14
通信作者：李俊波(1979—)，男，黑龙江绥化人，中国铁道科学研究院集团有限公司电子计算技术研究所正高级工程师。
基金项目：中国国家铁路集团有限公司科技研究开发计划课题(N2025T007-A(JB))；中国铁道科学研究院集团有限公司科研项目(2024YJ389)

learn data augmentation strategies based on input data to improve FOI detection performance in low-light scenarios. DedarkDet comprises two components: a differentiable lightweight image adaptive enhancement network and an improved object detection framework. This paper analyzed DedarkDet's performance through experiments, and results demonstrate that DedarkDet effectively improves detection performance in low-light scenarios.

Keywords: Deep Learning; Conventional Railway; Low Light; Image Augmentation; Anomaly Detection

0　引言

伴随AI技术的发展，基于目标检测的机器视觉技术逐渐应用于铁路行业当中[1-3]，我国普速铁路地形地貌环境复杂、线路背景差异大，尤以西南山区铁路更为突出。从视觉图像中准确提取异物侵限目标并应用于铁路防洪防汛业务场景，能有效降低人工巡查带来的人员投入、工作强度等问题。目前主流的视觉分类网络[4-6]、目标检测网络[7-9]和语义分割网络[10-12]能够有效提取数据特征并优异地执行相应视觉任务，但高质量的数据驱动依然是深度学习模型得以发展与应用的前提。然而，在现实世界中捕获的数据往往存在各种干扰，用高质量图像训练的通用模型在特定的场景条件下往往只能取得次优的效果。普速铁路夜间侵限事件往往具有突发性强、隐蔽性高的特点，一旦发生将对行车安全造成严重威胁，因此建立高效的夜间预警机制至关重要。普速铁路低光照危情场景示例如图1所示，边坡场景是普速铁路沿线最为复杂和危险的区域之一，其地质条件不稳定、环境因素多变，该场景下的夜间泥石流、落石和行人检测面临较大挑战。由于捕获的图像数据大多具有高保真性和低质量性，图片的前景信息被大量掩盖，后续的视觉任务无法获得图像中具有判别性的信息。针对类似低光照的目标检测场景，目前有效的解决方案之一是利用低光照图像增强技术(Low Light Image Enhance，LLIE)[13-15]实现图像的预处理以确保后续任务的效果，提高低光照数据的被感知性或可解释性[16]。

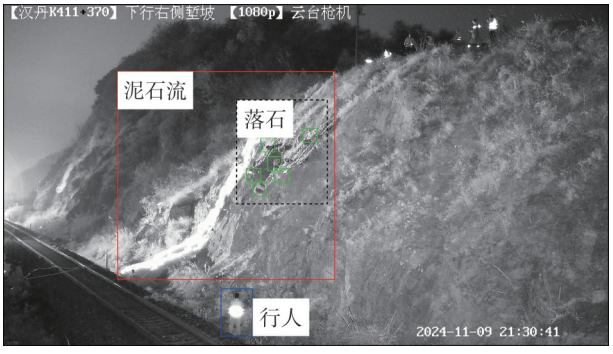

图1　普速铁路低光照危情场景示例

Fig.1　Example of low-light emergency scenario for conventional speed railways

现有端到端低光照目标检测方法主要分为两阶段检测方法和单阶段联合训练2类。两阶段方法[17-18]先用独立增强网络恢复亮图像，再送入检测器，该类方法虽效果稳定，但存在误差累积、无法针对检测任务优化增强过程的问题。单阶段方法尝试将如Retinexformer[19]、LLFlow[20]结合YOLO等增强模块嵌入检测器主干，但多采用重型Retinex分解网络，参数量大、速度慢。对现有方法的限制总结为以下2个方面。①当前的LLIE方法旨在将低光条件成像的数据信息转化成视觉上更容易的表示，但这些方法往往包含一个甚至几个复杂的图像恢复网络，这些网络均为像素级监督，采用了精细的手动标注，这种方案导致额外的计算复杂度和资源的浪费[21]；②当前的LLIE方法[18]需要设计增强图像的损失函数来优化网络，这使网络对目标的关注缺乏判别性，即对具体物体姿态和形状变化的学习无法实现最优的效果。在普速铁路低光照条件下的异常检测任务中，异物通常以非刚体形态出现，这导致目标外形变化更加显著，并对检测效果造成影响[22-23]。目前大多数方法通过一组高质量的数据来驱动模型学习，并实现了不错的性能表现，但由于自然条件下捕获的图片具有高保真低质量的属性[24]，使线路背景下的异常检测面临困难。

为解决上述问题，提出一种联合轻量级可微增强与检测任务驱动的端到端低光照目标检测框架DedarkDet。本研究与传统方法的核心差异在于：增强模块完全由传统可微图像处理操作构成，具有可解释性，并创新地和深度学习算法结合实现端到

端的训练流程；引入轻量辅助监督头，实现检测任务反向引导图像增强，使增强策略用于检测目标。DedarkDet是以端到端的方式实现自适应LLIE的级联式优化解决方案，该框架将低质量图像分别输入至由可微分的传统图像处理方法组成的DedarkNet模块，以及轻量级神经网络构成的辅助监督模块。利用后者的辅助监督，引导可微分传统方法以数据驱动方式学习最佳增强策略，从而恢复高质量的判别性信息，并基于DedarkNet增强后的数据，使用改进的检测器对其进行实例级定位和分类。本研究试验结果表明DedarkDet方法能有效提升低光照图像质量并精准定位暗弱目标，高置信度的检测结果验证了该方法在铁路夜间安全监控场景中的实用价值。

本研究贡献主要包括：①提出了一个可应用于普速铁路低光照条件下的异常检测新框架DedarkDet；②提出了一个可以端到端训练的完全可微的LLIE网络，其不需要高质量数据驱动，有效解决了线路异物侵限检测任务中存在的低光照数据与通用特征处理范式的不匹配问题。

1　研究方法

DedarkDet总体结构如图2所示，DedarkDet由2部分组成，分别是负责LLIE任务的自适应图像增强网络和基于其输出进行检测的改进检测器。其中，卷积-批量归一化-激活函数(Convolution-BatchNorm-SiLU，CBS)模块是由卷积操作、批量归一化操作和Sigmoid线性单元(Sigmoid Linear Unit，SiLU)激活函数串联而成，自适应空间特征融合(Adaptively Spatial Feature Fusion，ASFF)则表示自适应空间特征融合单元。

针对普速铁路夜间低光照场景下的异物侵限检测任务，本研究提出的模型总体框架主要由3个核心模块协同构成：①负责图像去暗与质量提升的低光照图片自适应增强网络；②用于预测图像处理最优超参数的辅助监督轻量级卷积网络；③为解决多尺度目标分配冲突而重新设计的基于ASFF的目标检测头。

1.1　自适应增强网络

能自适应进行LLIE任务的自适应增强网络由2个子网络组成，分别为负责图像处理的Dedark模块和负责辅助监督其训练的轻量级神经网络。其中，Dedark模块由3个具有可微性质的传统图像处理模块串联而成，即图像去暗模块、像素滤波模块和图像锐化模块。通过自适应的Dedark模块，可以增强低光照条件下的图像照度信息、像素级细粒度信息和纹理信息。

(1) 图像去暗模块[25]。通常实现低照度图像恢复为高照度图像的过程可以由公式(1)表示。

$$I(x)=J(x)t(x)+A\left(1-t(x)\right) \tag{1}$$

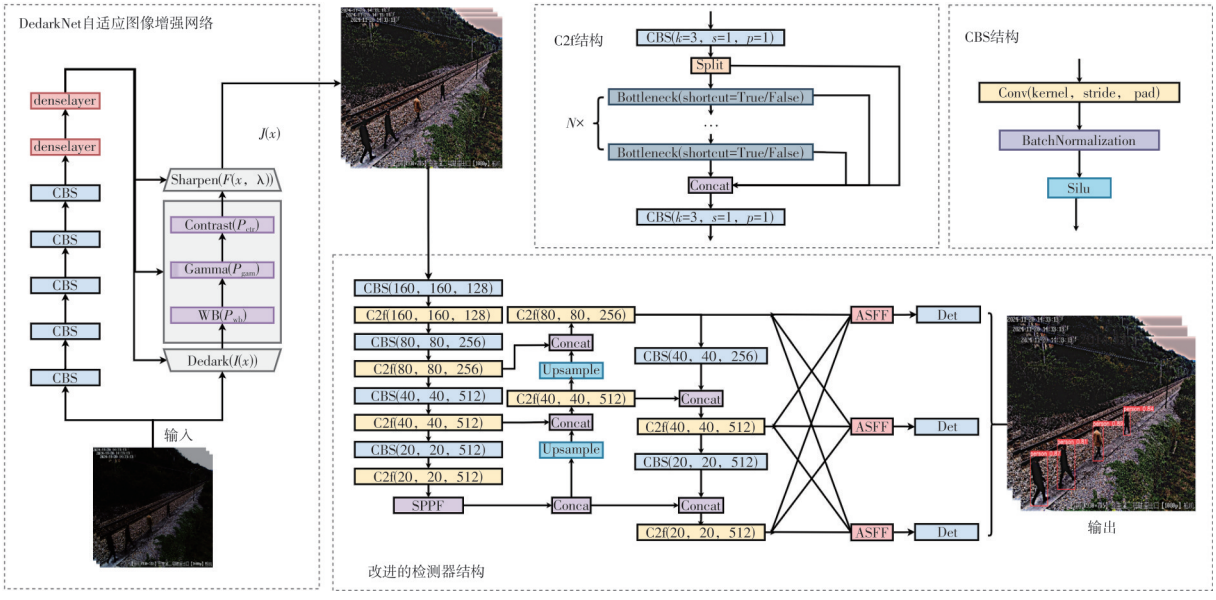

图2　DedarkDet总体结构

Fig.2　DedarkDet's overall architecture

式中：$I(x)$为低照度图像；$J(x)$为需要恢复的高照度图像；$\boldsymbol{A}$为大气中的光成分；$t(x)$为非散射光到达相机部分的介质传输，增强低照度图像就是利用$I(x)$中的信息将其恢复为清晰图像$J(x)$。

为了实现图像去暗，需要依据暗通道先验估计大气光$\boldsymbol{A}$。从输入低照度图像$I(x)$计算其暗通道映射，并从中选取亮度最高的1 200个像素取平均以获得稳定的大气光估计值$\boldsymbol{A}$。对于传输图$t(x)$，直接采用文献[25]提出的暗通道估计方式。利用估计的大气光$\boldsymbol{A}$，传输图的计算可由公式(2)表示。

$$t(x) = 1 - \min_{y \in \Omega(x)} \left(\min_{c} \frac{I^c(y)}{A^c} \right) \tag{2}$$

式中：$\Omega(x)$为以像素x为中心的局部邻域；c为颜色通道索引；$I^c(\mathrm{y})$为输入的低照度图像在通道c上坐标y处的像素值；$\boldsymbol{A}^c$为通道c对应的大气光照值；y为属于局部邻域$\Omega(x)$内的具体像素索引。

将估计的$\boldsymbol{A}$和计算得到的$t(x)$代入公式(1)，即可完成图像去暗过程，并获得增强后的高照度信息。

（2）像素滤波模块。基于图像去暗模块所得到的高照度信息$J(x)$对其进行像素滤波模块处理得到像素级细粒度信息。具体而言，$J(x)$的像素三通道表示为$(\boldsymbol{r}_j,\ \boldsymbol{g}_j,\ \boldsymbol{b}_j)$，基于$(\boldsymbol{r}_j,\ \boldsymbol{g}_j,\ \boldsymbol{b}_j)$进行像素级的白平衡计算得到$\boldsymbol{P}_{wb} = (\boldsymbol{W}_r \cdot \boldsymbol{r}_j,\ \boldsymbol{W}_g \cdot \boldsymbol{g}_j,\ \boldsymbol{W}_b \cdot \boldsymbol{b}_j)$，其中，$\boldsymbol{W}_r$，$\boldsymbol{W}_g$，$\boldsymbol{W}_b$为可优化的参数，并且该过程可微。接下来，基于白平衡$\boldsymbol{P}_{wb}$进行伽马变换，得到$\boldsymbol{P}_{gam} = (\boldsymbol{r}_{wb}^{\gamma},\ \boldsymbol{g}_{wb}^{\gamma},\ \boldsymbol{b}_{wb}^{\gamma})$，其中，$\gamma$为可优化参数，该过程可微。同理，由公式(3)可得到可微的对比度变换结果$\boldsymbol{P}_{ctr}$。

$$\boldsymbol{P}_{ctr} = \alpha \cdot En(\boldsymbol{P}_{gam}) + (1 - \alpha) \cdot \boldsymbol{P}_{gam} \tag{3}$$

式中：α为权衡原始图像和增强之后的图像之间的线性关系的可优化参数；$En(\boldsymbol{P}_{gam})$为对输入像素$En(\boldsymbol{P}_{gam})$通过增强像素的亮度和对比度来揭示更多的细节和信息。$En(\boldsymbol{P}_{gam})$可由公式(4)—(6)表示。

$$Lum(\boldsymbol{P}_{gam}) = 0.27 \cdot \boldsymbol{r}_{gam} + 0.67 \cdot \boldsymbol{g}_{gam} + 0.06 \cdot \boldsymbol{b}_{gam} \tag{4}$$

$$EnLum(\boldsymbol{P}_{gam}) = \frac{1}{2}\left(1 - \cos\left(\pi \cdot Lum(\boldsymbol{P}_{gam})\right)\right) \tag{5}$$

$$En(\boldsymbol{P}_{gam}) = \boldsymbol{P}_{gam} \cdot \frac{EnLum(\boldsymbol{P}_{gam})}{Lum(\boldsymbol{P}_{gam})} \tag{6}$$

式中：$\boldsymbol{P}_{gam}$为经过伽玛变换的输入像素值；$\boldsymbol{r}_{gam}$，$\boldsymbol{g}_{gam}$，$\boldsymbol{b}_{gam}$分别为该像素在红、绿、蓝3个通道上的分量值；$Lum(\cdot)$为亮度计算函数；$EnLum(\cdot)$为亮度增强映射函数；$En(\cdot)$为最终的对比度增强输出变量。

通过加权组合红、绿、蓝通道来计算像素亮度值$Lum(\boldsymbol{P}_{gam})$，其根据人眼对不同颜色的敏感度先验来设置。此外，使用一个基于余弦函数的转换来增强亮度，通过余弦函数的周期性变化，增强像素的亮度对比，得到$EnLum(\boldsymbol{P}_{gam})$。最后，将增强后的亮度值应用回原始像素，得到$En(\boldsymbol{P}_{gam})$。经过像素级滤波模块处理可以得到像素级细粒度信息$\boldsymbol{P}_{ctr}$。

（3）图像锐化模块。基于像素级细粒度信息$\boldsymbol{P}_{ctr}$，继续对其进行图像锐化处理以突出显示图像的细节，丰富图像的纹理信息，为后续的检测任务提供更具判别性的监督信号。锐化的过程可由公式(7)表示

$$\boldsymbol{P}_{sha} = \boldsymbol{P}_{ctr} + \lambda\left(\boldsymbol{P}_{ctr} - Gau(\boldsymbol{P}_{ctr})\right) \tag{7}$$

式中：$Gau(\boldsymbol{P}_{ctr})$为基于像素级滤波模块输出的对输入图像应用高斯滤波；λ为一个正的缩放因子。这个锐化操作相对于输入图像和参数均可微。

通过研究发现，常规LLIE网络中的超参数设置依赖于先验知识，这不利于端到端的优化检测任务。Dedark图像处理模块主要由5组可学习的超参数组成，分别对应去暗、白平衡、伽马系数、对比度和锐化部分，为了解决超参数调整问题，使用一个轻量级神经网络，对Dedark图像处理模块进行自适应的超参数预测。图2中Dedark自适应图像增强网络为实现自适应超参数调节的轻量级网络，其结构由CBS模块组成，C表示卷积操作，B表示批量归一化层，S表示SiLU激活函数，其接受输入的铁路低光照图像，经过5层卷积和2层全连接层，将输出特征作为各图像处理部分模块超参数的弱监督信号，参与整个过程的学习，进而实现自适应调参的功能。

综上所述，通过自适应增强网络可以实现有效的LLIE任务，并且由于DedarkNet的可微性，使其

容易与一个主流的目标检测器级联，进行端到端的训练，实现普速铁路场景下低光照异常检测任务。

1.2　改进的目标检测框架

为了实现普速铁路低光照异常检测效果，选择YOLOv8模型作为检测器基准，并针对普速铁路复杂的场景，对YOLOv8模型进行改进以适配夜间复杂的铁路场景，实现更高的检测精度。采用自适应空间特征融合结构(Adaptively Spatial Feature Fusion，ASFF)，重新对YOLOv8检测头进行设计。改进后的检测器可以高效地融合不同尺度的判别性特征，更适合普速铁路这种困难场景下的目标检测。

首先，基于YOLOv8的颈部结构对骨干网络提取到的特征进行融合，可以分别得到负责小目标预测的$\boldsymbol{P}_1$特征、负责中等目标预测的$\boldsymbol{P}_2$特征和负责大目标预测的$\boldsymbol{P}_3$特征，然而，不同尺度特征之间存在不一致性：当一个正样本被某一尺度的特征负责后，其他尺度特征的相应区域将被视为背景信息。因此，当普速铁路低光照图像中同时存在大、小目标时，训练过程就会产生冲突，加剧层级特征的不一致，进而导致模型总体性能下降。

为了解决这一问题，将ASFF结构用于YOLOv8的改进[8]，2种不同尺寸的特征进行自适应空间特征融合如图3所示。首先，基于输入特征1对其使用步长为2、卷积核尺寸为3的卷积操作，得到下采样特征$\boldsymbol{F}_1$。接下来，基于$\boldsymbol{F}_1$特征对其进行降维处理，得到$\boldsymbol{F}_2$特征。将$\boldsymbol{F}_2$特征与基于输入特征2得到的$\boldsymbol{F}_3$特征进行通道维度的拼接。再次经过卷积操作得到$\boldsymbol{F}_4$特征。其次，基于$\boldsymbol{F}_4$特征对其进行空间上的软最大值变换，得到一个空间特征映射关系$\mathrm{M}\in\mathbb{R}^{h\times w\times c}$，图中$h$，$w$和$c$分别为40，40和2。最后，基于$\boldsymbol{F}_1$和输入特征2对其使用映射M过滤掉非判别性信息，以实现最具判别性的特征融合，经过卷积层后得到最终输出。

同理，可对YOLOv8中的3个不同尺度的特征进行空间特征的融合。以$\boldsymbol{P}_2$为例。首先，将来自高层的语义特征$\boldsymbol{P}_3$和来自底层的细粒度信息$\boldsymbol{P}_1$分别进行上采样和下采样，以对齐尺寸。接下来，进行后续方法的融合。其过程可由公式(8)表示。

$$Y_{(i,\,j)}^{l}=\boldsymbol{\alpha}_{(i,\,j)}^{l}\cdot P_{(i,\,j)}^{1\to l}+\boldsymbol{\beta}_{(i,\,j)}^{l}\cdot P_{(i,\,j)}^{2\to l}+\boldsymbol{\gamma}_{(i,\,j)}^{l}\cdot P_{(i,\,j)}^{3\to l}\tag{8}$$

式中：$Y_{(i,\,j)}^{l}$为通过ASFF结构得到的第1层的映射关系；$P_{(i,\,j)}^{n\to l}$为n层级上的位于$(i,\,j)$的像素点向l层级上的像素点对齐所形成的映射关系；$\boldsymbol{\alpha}_{(i,\,j)}^{l}$，$\boldsymbol{\beta}_{(i,\,j)}^{l}$，$\boldsymbol{\gamma}_{(i,\,j)}^{l}$为网络自适应学习到的$l$层的3个不同层次的空间重要性权值矩阵，且$\boldsymbol{\alpha}_{(i,\,j)}^{l}$，$\boldsymbol{\beta}_{(i,\,j)}^{l}$，$\boldsymbol{\gamma}_{(i,\,j)}^{l}$在所有通道中共享，为了区分不同的贡献度，设置$\boldsymbol{\alpha}_{(i,\,j)}^{l}+\boldsymbol{\beta}_{(i,\,j)}^{l}+\boldsymbol{\gamma}_{(i,\,j)}^{l}=1$，并且$\boldsymbol{\alpha}_{(i,\,j)}^{l}$，$\boldsymbol{\beta}_{(i,\,j)}^{l}$，$\boldsymbol{\gamma}_{(i,\,j)}^{l}\in[0,\,1]$，其中以$\boldsymbol{\alpha}_{(i,\,j)}^{l}$为例，由公式(9)表示。

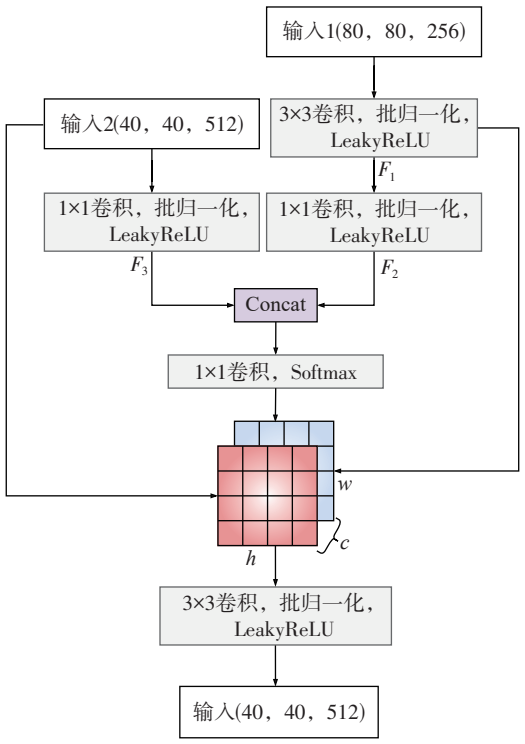

图3　2种不同尺寸的特征进行自适应空间特征融合

Fig.3　Adaptive spatial feature fusion of two features of different sizes

$$\alpha_{(i,\,j)}^{l}=\frac{e^{\lambda_{\alpha(i,\,j)}^{l}}}{e^{\lambda_{\alpha(i,\,j)}^{l}}+e^{\lambda_{\beta(i,\,j)}^{l}}+e^{\lambda_{\gamma(i,\,j)}^{l}}}\tag{9}$$

其中，空间重要性权重参数$\boldsymbol{\alpha}_{(i,\,j)}^{l}$，$\boldsymbol{\beta}_{(i,\,j)}^{l}$和$\boldsymbol{\gamma}_{(i,\,j)}^{l}$由softmax函数定义。具体而言，网络使用1×1卷积层从对应的特征图$P^{1\to l}$，$P^{2\to l}$和$P^{3\to l}$中计算出控制参数λ_{α}^{l}，λ_{β}^{l}和λ_{γ}^{l}，进而生成3个权重标量图。这一设计使得所有的权重参数均可以通过标准的反向传播算法进行端到端的自适应学习。图3中，YOLOv8检测器部分给出了ASFF的使用位置。首先，基于检测器颈部得到的小尺度特征$\boldsymbol{P}_1$、中尺度特征$\boldsymbol{P}_2$和大尺度特征$\boldsymbol{P}_3$，将其与ASFF结构进行全连接。其次，基于以上特征进行空间自适应融合，得到最终的小尺度目标特征$\boldsymbol{pt}_1$、中等尺度预测特征$\boldsymbol{pt}_2$和大尺度预测特征$\boldsymbol{pt}_3$。此过程可由公式(10)表示。

$$\begin{cases} \boldsymbol{pt}_1 = \mathrm{Det}\left(Y^1_{(i,\ j)}\left(\boldsymbol{P}_1,\ \boldsymbol{P}_2,\ \boldsymbol{P}_3\right)\right) \\ \boldsymbol{pt}_2 = \mathrm{Det}\left(Y^2_{(i,\ j)}\left(\boldsymbol{P}_1,\ \boldsymbol{P}_2,\ \boldsymbol{P}_3\right)\right) \\ \boldsymbol{pt}_3 = \mathrm{Det}\left(Y^3_{(i,\ j)}\left(\boldsymbol{P}_1,\ \boldsymbol{P}_2,\ \boldsymbol{P}_3\right)\right) \end{cases} \tag{10}$$

式中：$Y^1_{(i,\ j)}$，$Y^2_{(i,\ j)}$和$Y^3_{(i,\ j)}$分别为针对3种不同尺度的输入的自适应空间特征融合映射函数；Det为YOLOv8的检测头。

综上，将以上的ASFF结构与密集检测器YOLOv8结合，可以有效解决层级特征的不一致性，ASFF使网络能在其他层级上进行空间特征过滤。具体而言，在每个具体的空间位置，不同层级的特征被自适应地融合，使携带矛盾信息的像素被过滤掉，使更具有辨别力的特征在训练时能占据主导地位，从而在训练过程中找到最佳特征。这更适合普速铁路场景下的复杂检测任务。

1.3　损失设计

为实现高精度低光照环境下的目标检测任务，DedarkDet的损失设计主要由2部分组成，分别是检测器损失和DedarkNet的图像恢复损失，检测器损失由边界框回归L_{box}、分类预测L_{cls}和分布式边界回归L_{dfl}3部分组成。图像恢复损失L_{re}采用均方差实现，总体损失由公式(11)表示。

$$L = \lambda_{\mathrm{box}} L_{\mathrm{box}} + \lambda_{\mathrm{cls}} L_{\mathrm{cls}} + \lambda_{\mathrm{dfl}} L_{\mathrm{dfl}} + \lambda_{\mathrm{re}} L_{\mathrm{re}} \tag{11}$$

式中：λ_{box}，λ_{cls}，λ_{dfl}，λ_{re}为4项损失的平衡系数，结合YOLOv8的默认配置与任务特性，取值为λ_{box} = 7.5，λ_{cls} = 0.5，λ_{dfl} = 1.5，λ_{re} = 4.0。

采用YOLOv8默认的CIoU损失，CIoU能显著提升边界框回归稳定性，对落石等小目标的定位精度更友好。主要用于提升预测框在重叠程度、中心位置和长宽比3个方面的回归精度。对于预测框b=(x，y，w，h)和真实框b^{gt}，CIoU损失定义可由公式(12)表示。

$$L_{\mathrm{box}} = 1 - \mathrm{IoU}\left(b,\ b^{\mathrm{gt}}\right) + \frac{\rho^2\left(c,\ c^{\mathrm{gt}}\right)}{c^2_{\mathrm{diag}}} + \alpha\nu \tag{12}$$

式中：$\rho(c,\ c^{\mathrm{gt}})$为中心点欧氏距离；$c_{\mathrm{diag}}$为最小包围框对角线长度，长宽比一致性度量，可由公式(13)和(14)表示。

$$\nu = \frac{4}{\pi^2}\left(\arctan\frac{w^{\mathrm{gt}}}{h^{\mathrm{gt}}} - \arctan\frac{w}{h}\right)^2 \tag{13}$$

$$a = \frac{v}{\left(1 - \mathrm{IoU}\left(b,\ b^{\mathrm{gt}}\right)\right) + \nu} \tag{14}$$

式中：ν为长宽比的一致性影响因子；α为用于平衡重叠面积与长宽比的权重函数；w^{gt}和h^{gt}分别为真实目标边界框的宽度和高度；w和h分别为网络预测边界框的宽度和高度；IoU为预测框与真实框的交并比。

YOLOv8采用无锚框的任务对齐分配器分配正样本。对于每个正样本，其类别预测采用二值交叉熵损失计算，可由公式(15)表示。

$$L_{\mathrm{cls}} = -\left[y\ln\sigma(s) + (1 - y)\ln\left(1 - \sigma(s)\right)\right] \tag{15}$$

式中：s为预测的类别；$\sigma(\cdot)$为Sigmoid函数。

该设计有效提升了分类的稳定性，并降低了类别不平衡带来的优化偏差。

为进一步提高边界框的回归精度，YOLOv8采用分布焦点损失回归每个边界的离散分布，而非直接回归连续数值，在小目标检测中能更敏锐地感知微小偏移，提高落石场景的定位质量。对于目标边界的连续距离d，将其离散化为K个区间。设i为d的向下取整，且δ=d − i。构造软标签分布t_j，从而得到损失函数L_{dfl}，这个过程可由公式(16)得到。

$$L_{\mathrm{dfl}} = -\sum_{j=0}^{K-1} t_j \log p_j \qquad t_j \begin{cases} 1 - \delta & j = i \\ \delta & j = i + 1 \\ 0 & \text{other} \end{cases} \tag{16}$$

式中：预测分布$P_j = \dfrac{e^{z_j}}{\sum_k e^{z_k}}$由softmax函数得到。

为使DedarkNet生成的增强图像在像素层面接近干净图像，在总损失中加入基于均方误差的恢复项。令I_{re}为恢复模块输出的增强图像，I_{gt}为对应的干净参考图像。则像素域的恢复损失定义为像素均方误差，可由公式(17)表示。

$$L_{\mathrm{re}} = \frac{1}{N}\left\| I_{\mathrm{re}} - I_{\mathrm{gt}} \right\|^2_2 \tag{17}$$

式中：N为像素总数。

1.4　算法流程

基于DedarkNet图像去暗结构和改进的检测器进行级联设计，提出了一种端到端的低光照检测器。训练流程如下。

算法训练流程图如图4所示。首先，基于低光照环境下的图像$I(x)$对其进行去暗处理，得到干净的图像$J(x)$。接下来，使用YOLOv8的骨干网络对$J(x)$进行特征提取，得到底层的细粒度特征$\boldsymbol{H}_1$，中层上下特征$\boldsymbol{H}_2$和高层语意特征$\boldsymbol{H}_3$。其次，基于$\boldsymbol{H}_1$，$\boldsymbol{H}_2$和$\boldsymbol{H}_3$对其进行特征融合，分别得到小尺度特征

P_1、中尺度特征 P_2 和大尺度特征 P_3。最后，基于 P_1，P_2 和 P_3 特征对其进行自适应的空间特征融合操作，得到更具判别性的小尺度特征 pt_1、中尺度特征 pt_2 和大尺度特征 pt_3。

2　实验与分析

2.1　数据集与实验设置

针对普速铁路低光照条件下异物侵限领域缺乏高质量标注数据集的关键问题，构建一个涵盖多场景危情识别的专用数据集–TieLu2089 数据集。该数据集的构建填补了普速铁路安全监测领域的数据空白，为相关算法研究提供了重要的基础支撑，具有一定的工程应用意义。数据集总计包含 2 089 张图像，采集设备的感光元件为 1/1.8 英寸 CMOS 镜头，镜头焦距具备 40 倍光学变焦，曝光时间可通过自动曝光功能自适应调节，其照度性能达到彩色 0.000 1 Lux，黑白 0.000 05 Lux 的超低光水平。普速铁路危情图像和超过 3 000 个精确标注实例，涵盖了普速铁路运营中最常见且危险性最高的 3 类安全隐患，即行人入侵、泥石流灾害和边坡落石。图像采集覆盖了不同时段、不同天气条件以及不同地理位置的普速铁路沿线场景，确保了数据的多样性和代表性。为深入分析算法对不同尺度目标的检测能力，采用实例级精细化标注方式，根据边界框面积将所有标注实例划分为 3 种场景。TieLu2089 数据集部分数据如图 5 所示，边坡场景以地形起伏和植被覆盖为主要特征；轨面场景线路平直、视野开阔，反映了平原地区铁路的典型运营环境；隧道场景则以封闭空间和人工照明系统构成了区别于其他场景的独特特征。这 3 种场景的多样性充分体现了铁路系统运营环境的复杂性，为后续性能评估提供了全面的应用基础。

训练集如表 1 所示，验证集和测试集如表 2 所示。行人多为小尺寸目标，满足远距离预警需求；泥石流以大尺寸实例为主，准确反映泥石流灾害覆盖范围广、影响区域大的典型特征；边坡落石图像数量较少但实例密度高(5.34 个/张)且全为小尺寸目标，体现此类灾害早期检测和密集分布的重要特点。验证集与训练集数据分布保持一致，以保障实验结果的可靠性。按照 COCO 标准以目标区域的像素数量作为基准，其中小目标面积小于 32^2 像素，中目标 32^2 ~ 96^2 像素，大目标大于 96^2 像素。

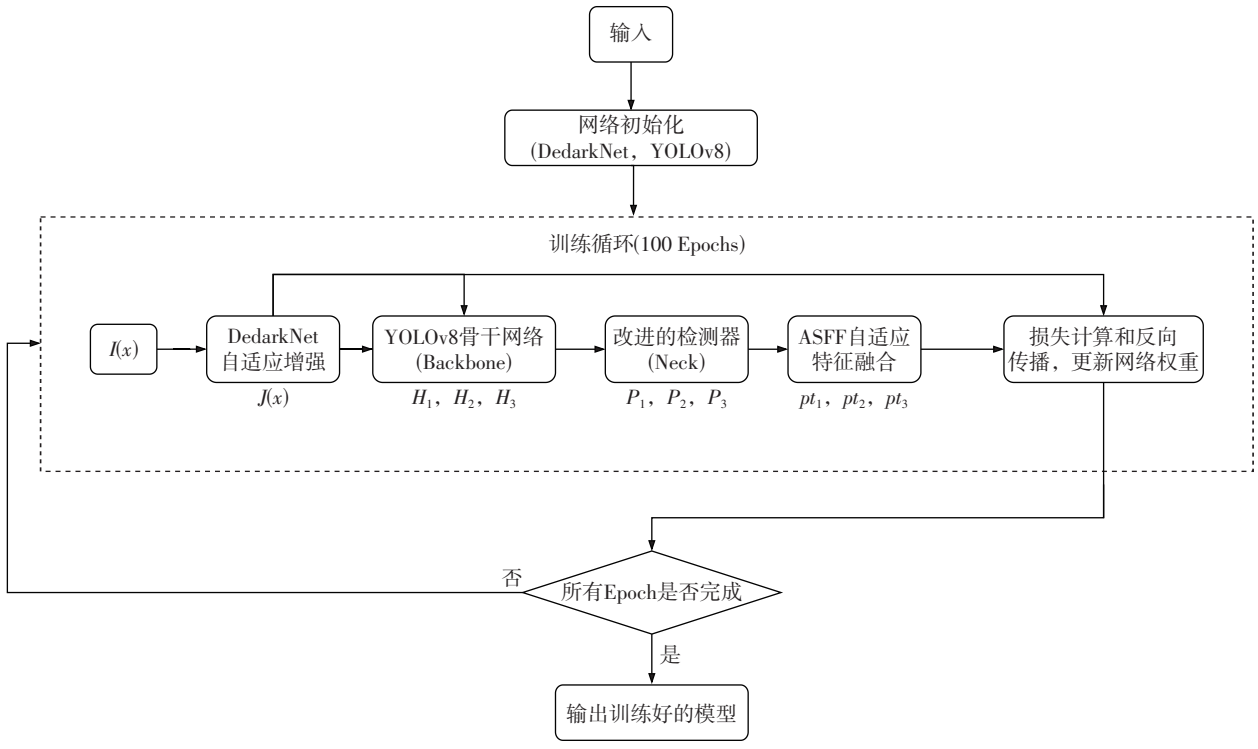

图 4　算法训练流程图

Fig.4　Algorithm training flowchart

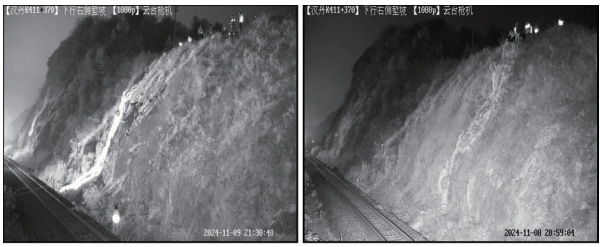

a　边坡场景
a　Scene of slope

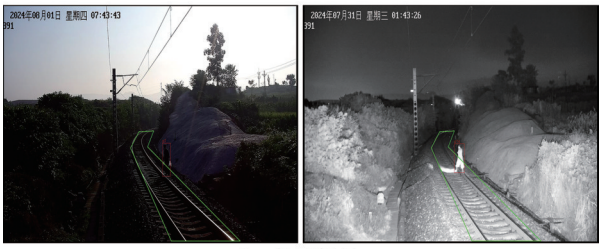

b　轨面场景
b　Scene of track surface



c　隧道场景
c　Scene of tunnel entrance

图5　TieLu2089数据集部分数据
Fig.5　Part of TieLu2089 dataset

表1　训练集
Tab.1　Training set

类别	图片数量	实例数	大尺寸实例数	中尺寸实例数	小尺寸实例数
行人	1 195	1 628	—	508	1 120
泥石流	559	584	488	96	—
边坡落石	70	374	—	—	374

表2　验证集和测试集
Tab.2　Validation set and test set

类别	图片数量	实例数	大尺寸实例数	中尺寸实例数	小尺寸实例数
行人	291	384	—	107	277
泥石流	140	146	122	24	—
边坡落石	17	91	—	—	91

在训练设置方面，使用离线的Mosaic数据增强技术提升模型的泛化能力和鲁棒性。Mosaic增强通过将4张不同的训练图像智能拼接为一张复合图像，有效增加小目标的训练样本数量，提升模型对复杂多变场景的适应能力，这对于普速铁路多样化的环境条件具有重要意义。在优化策略方面，本实验采用Adam优化器，初始学习率0.01并引入余弦退火策略以实现更好的收敛效果。训练参数设置如下：训练过程设置100个epoch、批量大小32；RT-DETR因Transformer算法特性调整为500个epoch、批量大小24。所有模型均采用早停机制以抑制过拟合。在实验环境方面，选用Intel i9-10900K CPU与2块NVIDIA GeForce RTX 3090 GPU作为核心硬件配置，为模型训练与推理提供算力支持。

在评估体系方面，通过5个指标评估模型性能：精确率(P)、召回率(R)、平均精确率均值(mAP)、F1分数和漏检率(DR)。结合假阳性(FP)、真阳性(TP)、假阴性(FN)和真阴性(TN)，P和R定义如公式(18)和(19)所示。

$$R = DR = \frac{TP}{TP + FN} \tag{18}$$

$$P = \frac{TP}{TP + TF} \tag{19}$$

IoU阈值设置为0.5。mAP定义为所有目标的AP的平均值。定义如公式(20)和(21)所示。

$$AP = \int_0^1 P(R)\mathrm{d}R \tag{20}$$

$$mAP = \frac{\sum_{i=1}^{N_{\mathrm{cls}}} AP}{N_{\mathrm{cls}}} \tag{21}$$

式中：N_{cls}表示类别数量。

同理，检出率的公式和召回率相同，但召回率反映模型在不同置信度阈值下的理论检测能力，检出率则反映模型在固定部署阈值下的实际应用性能。在计算检出率时，使用的固定阈值是0.25。此外，相对较高的$F1$分数表明检测模型具有鲁棒性，定义如公式(22)所示。

$$F1 = 2 \times \frac{P \times R}{P + R} \tag{22}$$

2.2　实验结果定性分析

为了直观展示DedarkDet算法在普速铁路低光照场景下的检测性能，进行详细的对比实验。DedarkDet与基线模型检测效果比较如图6所示，该对比实验涵盖了行人入侵、泥石流和边坡落石等典型危情场景。其中，每行代表一个测试样本，从左到右依次为：a列展示输入模型的原始低光照图像，这些图像呈现出典型的低照度特征，目标轮廓模糊、细节信息缺失、整体亮度偏低；b列为人工标

注的真实目标位置，即 Ground Truth，边界框准确标识了各类危情目标的实际位置和范围；c 列为基线算法 YOLOv8 的检测结果；d 列为 DedarkDet 算法的检测结果。

通过对比分析发现，基线算法 YOLOv8 在低光照条件下表现出明显的性能局限性。如图 6c 列所示，YOLOv8 存在多种检测缺陷：首先，白色虚线圆圈标识的区域显示了明显的漏检现象，即算法未能检测到真实存在的危情目标，这在普速铁路安全监控中可能导致严重的安全隐患；其次，白色实线圆圈框出的区域表明算法产生了误检和虚警，即将非目标区域错误识别为危情目标，这种误判会增加系统的虚警率，影响监控系统的实用性和可靠性。

相比之下，DedarkDet 算法在相同测试条件下展现出显著的性能优势。如图 6d 列所示，DedarkDet 成功检测到所有真实目标，实现了与 Ground Truth 的一致性，有效避免了漏检问题的发生。同时，算法的检测结果未出现误检和虚警现象，检测框准确定位目标位置，置信度分数稳定。

2.3　实验结果定量分析

为了全面评估 DedarkDet 算法在普速铁路低光照异常检测任务中的性能表现，选择当前主流的基于卷积的目标检测算法和基于 Transformer 的检测算法进行对比实验。对比实验为 YOLOv8 和 RT-DETR。同时引入低光照恢复的主流算法 RetinexNet 作为图像增强算法，并结合 YOLOv8 和 RT-DETR 进行目标检测实验。各模型算法结果对比分析如表 3 所示。

对比实验表明，DedarkDet 在各项主要指标上均展现出绝对优势。其中，$F1$ 分数的显著提高验证了自适应增强策略在复杂低光照场景下的有效性。mAP50 的提升反映了模型对异物目标检测能力的增强；同时，mAP75 指标大幅领先，进一步证明了该方法在目标边界回归上的高精准度。这表明 DedarkDet 不仅能够检测到目标，而且定位精度更高，边界框预测更加准确。

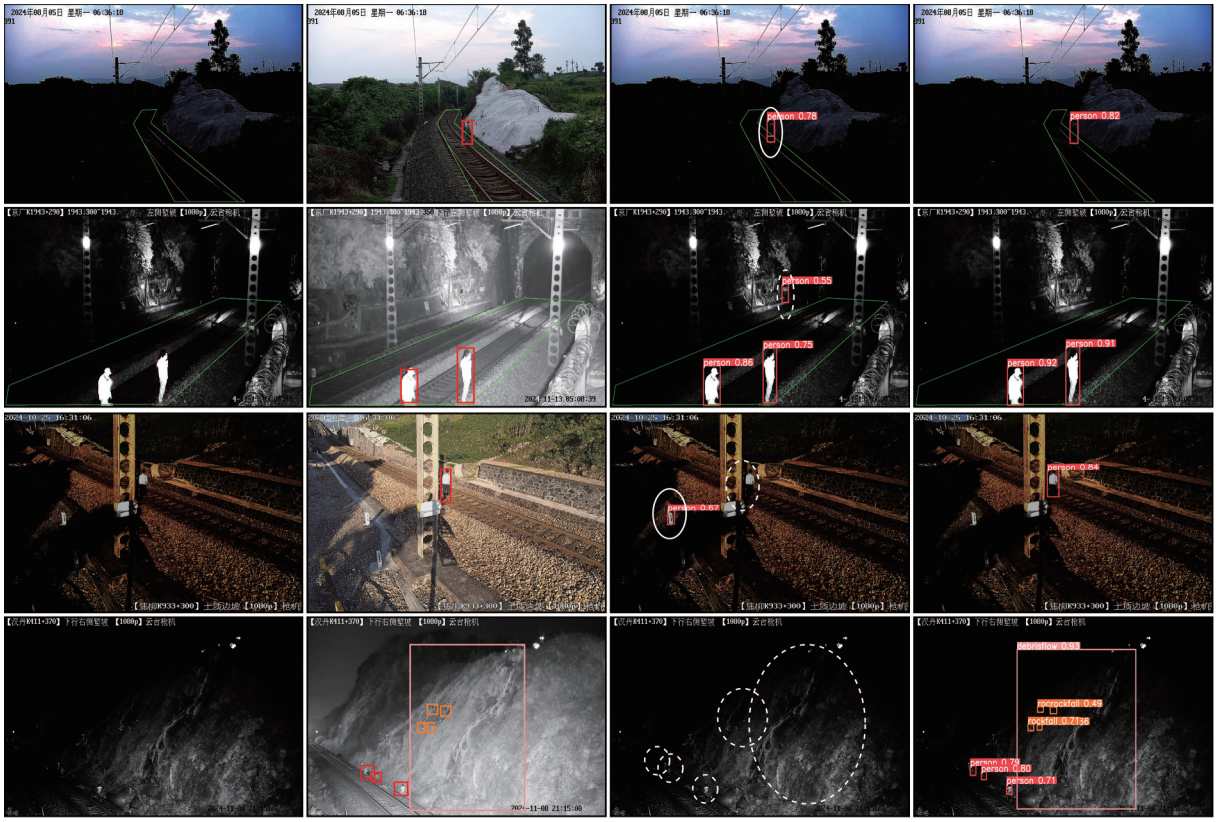

a　低光照输入　b　真实目标位置　c　YOLOv8检测效果　d　DedarkDet检测效果
a　Low-light input　b　True target location　c　YOLOv8 detection effect　d　DedarkDet detection effect

图 6　DedarkDet 与基线模型检测效果比较
Fig.6　Comparison of detection performance between DedarkDet and baseline models

表3　各模型算法结果对比分析　%

Tab.3　Comparative analysis of algorithm results of each model

算法方案	精确率	召回率	*F*1	mAP50	mAP75	检出率
YOLOv8	59.3	28.9	34.8	46.2	39.8	46.4
行人	78.0	67.4	72.4	78.9	63.8	67.7
泥石流	100	19.2	32.2	59.6	55.7	19.2
边坡落石	0	0	0	0	0	0
RT-DETR	89.9	27.5	37.0	32.5	16.6	36.7
行人	79.2	38.7	52.0	42.5	9.7	41.7
泥石流	90.2	43.8	59.0	55.0	40.1	46.6
边坡落石	100	0	0	0	0	0
Retinex+RT-DETR	65.2	54.7	57.0	56.3	27.8	67.9
行人	68.0	71.9	69.9	72.5	10.36	75.0
泥石流	86.5	80.8	83.6	84.5	73.0	81.5
边坡落石	41.2	11.6	17.7	11.8	0	16.5
Retinex+YOLOv8	81.1	71.7	72.8	79.2	59.2	72.9
行人	80.3	89.2	84.5	92.9	77.2	90.8
泥石流	94.8	90.4	92.5	94.9	91.6	90.4
边坡落石	68.2	35.4	41.5	50.0	8.8	37.4
DedarkDet	87.5	77.5	**81.1**	**84.0**	**62.1**	**87.3**
行人	93.9	92.4	**93.2**	**95.6**	**74.9**	**93.0**
泥石流	97.3	99.3	**98.3**	**99.4**	**99.1**	**99.3**
边坡落石	71.2	40.7	**51.8**	**57.0**	**12.3**	**43.9**

在对比实验中，将低光照增强算法RetinexNet与检测器结合，进一步评估图像恢复对检测性能的影响。从表3实验结果可以看出，RetinexNet的引入在一定程度上提升了基线模型的检测效果，但整体性能仍显著低于DedarkDet。Retinex+RT-DETR在3类场景下的检测性能提升有限，其整体*F*1分数与检测精度方面改善幅度有限，无法有效兼顾检测的查准率与查全率。尤为关键的是，在更严格的mAP75指标下其表现依然低迷，说明单纯的图像增强无法有效弥补RT-DETR在特征提取和定位精度方面的不足。

对于Retinex+YOLOv8，该组合在整体性能上较YOLOv8有显著提升，然而，相比DedarkDet在各项指标上的大幅领先，Retinex+YOLOv8仍存在明显差距，尤其在检出率方面仅为72.9%，远低于DedarkDet的87.3%，这表明传统图像增强方法虽能改善YOLOv8的检测能力，但对复杂噪声环境与小目标场景的适应性依然有限。

RetinexNet与2类检测器的结合虽然在一定程度上改善了低光照环境下的检测性能，但由于其增强策略未针对普速铁路场景的复杂特征进行优化，整体提升幅度有限。此外，RetinexNet并非端到端的联合优化框架，其图像增强过程与后续的检测器相互独立，导致增强结果无法针对检测任务进行自适应优化。

在具体的检测类别上，DedarkDet在行人入侵检测和泥石流检测任务中表现较好，*F*1分数相比基线算法YOLOv8和RT-DETR实现了大幅性能提升，特别是召回率提升幅度达到100%以上。在最具挑战性的边坡落石检测任务中，DedarkDet成功突破了基线算法完全检测失败的困境，实现了40.7%的召回率和51.8%的F1分数，为小目标密集分布的复杂场景检测提供了有效解决方案。

为验证DedarkDet模型在推理阶段的实时性与计算代价，对比分析各算法在参数量、计算复杂度(FLOPs)，以及不同硬件平台RTX 3090与CPU下的推理速度。DedarkNet的参数对比结果如表4所示。

从整体模型规模来看，DedarkDet的参数量略高于YOLOv8和RT-DETR，这一增加主要来源于研究设计的自适应增强模块与ASFF结构。尽管参数量有所增加，DedarkDet仍保持了可接受的模型规模，与主流轻量级检测器处于同一数量级。

表4　DedarkNet的参数对比结果
Tab.4　DedarkNet parameter comparison results

	参数量/M	FLOPs/G	GPU/FPS	CPU/FPS
YOLOv8	43.7	165.2	83	3
RT-DETR	42	136.0	55	2.4
DedarkDet	46.2	193.0	56	2.6

在计算量方面，DedarkDet的FLOPs同样略高于YOLOv8和RT-DETR。但计算量的提升并未导致推理速度大幅下降。

在GPU硬件平台上，DedarkDet的推理速度虽低于YOLOv8但快于RT-DETR，保持了实时检测能力。在CPU平台上，DedarkDet与YOLOv8和RT-DETR的FPS接近，能够满足铁路场景中对低光照场景安全监测的实时性要求。

综上所述，尽管DedarkDet在参数量和计算量上略有增加，但其推理速度依然保持良好水平，并在检测精度上取得了大幅提升，充分证明了研究提出的结构设计在精度与效率之间实现了良好的平衡。

2.4　消融实验

为了验证图像去暗模块、像素滤波模块和图像锐化模块的有效性，对DedarkNet结构进行了消融研究并对结果进行了定性分析。针对DedarkNet结构，设计了3种结构进行消融实验，DedarkNet中各部分的消融实验如表5所示。

表5　DedarkNet中各部分的消融实验
Tab.5　Ablation experiments of various parts in DedarkNet

算法方案	图像去暗模块	像素滤波模块	图像锐化模块	mAP50/%
Baseline	×	×	×	44.1
Dedark-A	√	×	√	79.9
Dedark-B	√	√	×	81.6
Dedark-C	×	√	√	82.7
Dedark-D	√	√	√	84.0

Dedark图像处理模块是DedarkNet的重要组成部分，主要负责实现LLIE任务以提升网络检测能力。为了验证Dedark图像处理模块各部分的有效性，设计多种Dedark图像处理模块。这里主要列举4种结构。①仅使用图像去暗模块和图像锐化模块，记为Dedark-A；②仅使用图像去暗模块和像素级滤波模块，记为Dedark-B；③仅使用像素级滤波模块和图像锐化模块，记为Dedark-C；④将3种结构同时使用，记为Dedark-D。从表5中前4组实验可以看出，相比基线模型，DedarkNet的图像去暗模块、像素滤波模块和图像锐化模块是有效的，尤其是像素滤波模块对检测性能的贡献最大。对比后4个实验可以清晰地看出，3种模块组合是最优设计。

YOLOv8中ASFF的消融实验如表6所示，为进一步验证ASFF模块对低光照目标检测性能的贡献，特别是对小目标(落石类)的提升作用，在TieLu2089测试集上设计了3组ASFF消融实验。DedarkA为不使用ASFF的基线DedarkDet，直接沿用YOLOv8原始检测头，DedarkB采用固定权重融合，DedarkC为研究完整的自适应ASFF方案。

表6　YOLOv8中ASFF的消融实验
Tab.6　Ablation experiments of ASFF in YOLOv8

算法方案	行人检出率/%	泥石流检出率/%	落石检出率/%
Dedark-A	90.9	94.2	38.2
Dedark-B	89.1	95.6	39.0
Dedark-C	93.0	99.3	43.9

相较于不使用ASFF的DedarkA，自适应ASFF将整体检出率从72.6%提升至84.0%，行人检出率从90.9%提升至93.0%，泥石流检出率从94.2%提升至99.3%。尤其在最具挑战性的落石类上，自适应ASFF使检出率从38.2%提升至43.9%，而固定权重融合提升并不明显，说明空间自适应权重学习对抑制尺度冲突、保留小目标细节信息至关重要。即使在大目标泥石流类上，自适应ASFF相对于固定权重的ASFF仍实现3.7个百分点的检出率增益，体现出其对多尺度目标检测的全面提升能力。上述结果充分证明，ASFF模块尤其是其自适应权重机制，是DedarkDet在低光照复杂铁路场景中实现小目标检测性能突破的核心组件之一。

3　结束语

结合普速铁路防洪防汛工程技术应用需要，主要针对低光照条件下的异物检测问题，提出了一种基于深度学习的异常检测算法框架。DedarkDet在自建TieLu2089低光照数据集上mAP50，较YOLOv8基线提升81.8%，在GPU上推理速度56 FPS，落石类小目标mAP75较基线提升246%，实现了精度与速度的优异平衡，具备铁路现场部署价值。该算法通过级联自适应LLIE网络和改进的检测器，显著

提升算法在光照不足条件下的异物检测性能。其中DedarkNet通过采用自适应增强网络，使用带标注的低质量图像监督，可以自适应调整图像的亮度、对比度和色调。此外，通过在检测器中引入自适应空间特征融合结构，进一步优化目标检测器，提高了对不同尺寸目标的检测准确性。构建一个普速铁路低光照场景下的人员入侵检测数据集，测试结果表明，DedarkDet的检测性能优异，能显著降低误检率和漏检率，通过消融实验进一步证实了算法中各个组件的有效性。当前DedarkDet在极端弱光条件以及强阴影干扰场景中仍会出现一定的漏检现象，且在落石类小目标任务上的检出率与实际工程部署需求仍存在差距。为进一步提升模型在复杂环境下的稳健性与小目标检测能力，未来的研究方向包括2个方面。①为克服单一模态的局限性，拟引入多模态特征，结合红外、深度图或事件相机等多源信息，以缓解极暗环境下可见光特征不足的问题；②针对小目标落石，拟引入Deformable Transformer的小目标注意力机制，利用可变形注意力增强对稀疏细粒度特征的建模，从而提升对尺度极小、形态不规则目标的检测性能。

参考文献：

[1] 劳武略，徐　威，张清华，等. 基于计算机视觉的钢桥螺栓松动检测方法[J]. 铁道学报，2024，46(1)：91-102.
LAO Wulüe，XU Wei，ZHANG Qinghua，et al. Computer Vision-Based Detection Method for Steel Bridge Bolt-Looseness[J]. Journal of the China Railway Society，2024，46(1)：91-102.

[2] 杨　文，胡　昊，李凌志，等. 基于机器视觉的铁路限界入侵检测方法[J]. 铁道科学与工程学报，2025，22(3)：1328-1343.
YANG Wen，HU Hao，LI Lingzhi，et al. Railway Boundary Foreign Object Intrusion Detection Method Based on Machine Vision[J]. Journal of Railway Science and Engineering，2025，22(3)：1328-1343.

[3] 郭心全，李俊波，沈　鹃，等. 普速铁路桥梁设备缺陷文本分类模型研究[J]. 铁路计算机应用，2024，33(12)：14-18.
GUO Xinquan，LI Junbo，SHEN Kun，et al. Text Classification Model for Bridge Equipment Defect of Ordinary Railway[J]. Railway Computer Application，2024，33(12)：14-18.

[4] HE K M，ZHANG X Y，REN S Q，et al. Deep Residual Learning for Image Recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). June 27-30，2016. Las Vegas，NV，USA. IEEE，2016：770-778.

[5] LIU Z，HU H，LIN Y T，et al. Swin Transformer V2：Scaling up Capacity and Resolution[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New Orleans，LA，USA：IEEE，2022.

[6] GAO S H，CHENG M M，ZHAO K，et al. Res2Net：A New Multi-Scale Backbone Architecture[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence，2021，43(2)：652-662.

[7] SUN P Z，ZHANG R F，JIANG Y，et al. Sparse R-CNN：End-to-End Object Detection with Learnable Proposals[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville，TN，USA：IEEE，2021.

[8] LIU S T，HUANG D，WANG Y H. Learning Spatial Fusion for Single-Shot Object Detection[EB/OL]. (2019-11-21)[2025-09-30]. https：//arxiv. org/abs/1911. 09516

[9] ZHANG H，LI F，LIU S L，et al. DINO：DETR with Improved DeNoising Anchor Boxes for End-to-End Object Detection[EB/OL]. (2022-03-07)[2025-09-30]. https：//arxiv. org/abs/2203. 03605

[10] LV F F，LI Y，LU F. Attention Guided Low-Light Image Enhancement with a Large Scale Low-Light Simulation Dataset[J]. International Journal of Computer Vision，2021，129(7)：2175-2193.

[11] STRUDEL R，GARCIA R，LAPTEV I，et al. Segmenter：Transformer for Semantic Segmentation[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV). Montreal，QC，Canada：IEEE，2021.

[12] XIE E Z，WANG W H，YU Z D，et al. SegFormer：Simple and Efficient Design for Semantic Segmentation with Transformers [EB/OL]. (2021-05-31)[2025-09-30]. https：//arxiv. org/abs/2105. 15203

[13] 王祥朗. 针对低光照光场图像的渐进式自适应增强方法研究[D]. 北京：北京交通大学，2023.

[14] 王满利，张　航，张长森. 基于深度学习的低光照目标检测算法[J]. 北京邮电大学学报，2024，47(5)：59-65.
WANG Manli，ZHANG Hang，ZHANG Changsen. A Low Light Target Detection Algorithm Based on Deep Learning[J]. Journal of Beijing University of Posts and Telecommunications，

2024，47(5)：59-65.

[15] 唐华鹏．面向低光照环境的室内视觉定位技术研究[D]．哈尔滨：黑龙江大学，2024.

[16] LI C Y，GUO C L，HAN L H，et al. Low-Light Image and Video Enhancement Using Deep Learning：A Survey[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence，2022，44(12)：9396-9416.

[17] CAI W H，CHEN Y J，QIU X Y，et al. LLD-YOLO：A Low-Light Object Detection Algorithm Based on Dynamic Weighted Fusion of Shallow and Deep Features[J]. IEEE Access，2025，13：69967-69979.

[18] WU W H，WENG J，ZHANG P P，et al. URetinex-Net：Retinex-Based Deep Unfolding Network for Low-Light Image Enhancement[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). June 18-24，2022，New Orleans，LA，USA. IEEE，2022：5891-5900.

[19] CAI Y H，BIAN H，LIN J，et al. Retinexformer：One-Stage Retinex-Based Transformer for Low-Light Image Enhancement[C]//2023 IEEE/CVF International Conference on Computer Vision (ICCV). October 1-6，2023，Paris，France. IEEE，2024：12470-12479.

[20] WANG Y F，WAN R J，YANG W H，et al. Low-Light Image Enhancement with Normalizing Flow[J]. Proceedings of the AAAI Conference on Artificial Intelligence，2022，36(3)：2604-2612.

[21] 何银银．低光照场景下的煤岩图像增强与检测算法研究[D]．太原：太原科技大学，2024.

[22] 刘欣然．基于多源数据融合的滑坡智能检测[D]．北京：北京邮电大学，2022.

[23] 傅宇浩，郭　沛，刘鹏宇，等．基于计算机视觉的公路边坡裂缝检测方法[J]．测控技术，2021，40(5)：62-66.
FU Yuhao，GUO Pei，LIU Pengyu，et al. Highway Slope Crack Detection Method Based on Computer Vision[J]. Measurement & Control Technology，2021，40(5)：62-66.

[24] 辛绍强，张海辉，于太伏．道路桥梁智能检测技术研究现状与应用综述[J]．交通工程，2024，24(6)：85-88.
XIN Shaoqiang，ZHANG Haihui，YU Taifu. Review of the Current State and Applications of Intelligent Inspection Technologies for Road Bridges[J]. Journal of Transportation Engineering，2024，24(6)：85-88.

[25] HE K M，SUN J，TANG X O. Single Image Haze Removal Using Dark Channel Prior[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence，2011，33(12)：2341-2353.

(责任编辑　汪沁萱)

(上接第203页)

全风险评估方法[J]．上海公路，2024(4)：119-131，241.
LU Yi，GUO Xinyu，LIU Jian，et al. Security Risk Assessment Method of Autonomous Vehicle Road Test Data[J]. Shanghai Highways，2024(4)：119-131，241.

[17] 张琼丽，陈　翼．数据分级分类方法及实践研究[J]．技术与市场，2022，29(8)：150-153.
ZHANG Qiongli，CHEN Yi. Research of Data Classification Model and Practice[J]. Technology and Market，2022，29(8)：150-153.

[18] 孙文桥，刘启钢，赵国盛，等．基于本质安全的智能化铁路编组站生产作业安全评价指标体系构建研究[J]．铁路物流，2025，43(4)：50-56.
SUN Wenqiao，LIU Qigang，ZHAO Guosheng，et al. Construction of Safety Evaluation Index System for Intelligent Railway Marshalling Station Operations Based on Inherent Safety[J]. Railway Logistics，2025，43(4)：50-56.

(责任编辑　金　晶)