燃烧科学与技术
Journal of Combustion Science and Technology
2026,32(5):533-542
DOI 10.11715/rskxjs.R202507011

基于改进 YOLOv8 轻量级电力管廊初期火灾检测方法的研究

王宇航，陈　勇，邢　卉，孙晓云，张宇彤，付立宁
（石家庄铁道大学电气与电子工程学院，石家庄 050043）

摘　要：针对于传统城市电力管廊内火灾检测算法模型参数量大、计算量大、推理时间长和可见光对于早期火灾图像识别困难等问题，提出了一种基于图像融合(EMAFusion)的早期火灾检测方法，对 YOLOv8 算法进行改进，用于初期火灾检测. 将早期火灾红外图像与可见光图像融合用于火灾隐患的检测，得到热红外信息又补充可见光纹理信息、轮廓特征，调节弥补了红外与可见光特征. 相较于单一图像，融合图像可以提升火灾检测的准确率以及模型在复杂场景下的鲁棒性. 此外，构建了一种基于改进的 YOLOv8n 的早期火灾检测算法模型，在特征融合阶段 Neck 端引入 AFPN(渐近特征金字塔网络)通过自适应权重融合和多尺度特征融合，AFPN 能够显著提升模型对小目标的检测能力；引入 LADH 检测头在保持轻量化的同时提高模型的检测精度；最后使用 WIoU 损失函数优化网络的边界损失，提高网络模型检测准确性以及加快模型的收敛. 实验结果表明，该网络在所使用的模拟电力管廊火灾数据集上的准确率提高了 2.3%，参数量下降了 23.88%，计算量下降了 17.23%，其中检测速度 FPS 相比于基准模型提升了 34.65%. 算法精度不仅得到了提升又满足了轻量化的需求，可以满足电力管廊场景下的实时检测.

关键词：EMAFusion；渐进特征金字塔；LADH 检测头；WIoU；轻量化
中图分类号：TP391　　**文献标志码**：A　　**文章编号**：1006-8740(2026)05-0533-10

Early Fire Detection for Lightweight Power Tunnel Based on Improved YOLOv8

Wang Yuhang，Chen Yong，Xing Hui，Sun Xiaoyun，Zhang Yutong，Fu Lining
（School of Electrical and Engineering，Shijiazhuang Tiedao University，Shijiazhuang 050043，China）

Abstract：Traditional urban power tunnel fire detection algorithms suffer from several drawbacks，including a large parameter count，high computational load，long inference time，and the difficulty in early fire image recognition using visible light. To address these problems，a novel early fire detection method based on image fusion(EMA Fusion)is proposed，which improves the YOLOv8 algorithm for initial fire detection. This method fuses infrared and visible light images of early fires to detect fire hazards，obtaining both thermal infrared information and visible light texture and contour features. Compared to single-image detection，the fused images enhance the accuracy of fire detection and the robustness of the model in complex scenarios. Moreover，an early fire detection algorithm model is constructed based on the improved YOLOv8n. In the feature fusion stage，the asymptotic

收稿日期：2025-08-22.
基金项目：石家庄市科技计划重点资助项目(241130163A).
作者简介：王宇航(1998—　　)，男，硕士研究生，2075744423@qq.com.
通信作者：孙晓云，女，博士，教授，sunxyheb@stdu.edu.cn.

feature pyramid network (AFPN) is introduced at the Neck end. Through adaptive weight fusion and multi-scale feature fusion, this network can significantly enhance the model's ability to detect small targets. The LADH detection head is incorporated to improve detection accuracy while maintaining a lightweight structure. Lastly, the WIoU loss function is used to optimize the boundary loss of the network, thereby increasing detection accuracy and accelerating model convergence. Experimental results indicate that on the simulated power tunnel fire dataset, the accuracy of this network increased by 2.3%, while the parameter count decreased by 23.88% and the computational load by 17.23%. The detection speed, measured in frames per second (FPS), was improved by 34.65% compared to that of the baseline model. The algorithm not only achieves higher precision but also meets the requirements for lightweight design, making it suitable for real-time detection in power tunnel scenarios.

Keywords: EMA Fusion; adaptive feature pyramid network (AFPN); LADH detection head; WIoU; lightweight

近几十年来,我国在城市基础设施建设中投入大量资源,电力管廊建设尤为突出[1]. 电力管廊是用于敷设电力电缆的地下构筑物,包括隧道、排管、综合管廊电力仓等. 21 世纪以来,其建设规模不断扩大,数量和总里程持续增加[2]. 根据综合电力管廊火灾事故统计[3]. 电力舱电缆火灾是发生率最高的火灾类型. 电力舱内部容纳众多电缆,相对封闭的空间内着火会造成大规模的火蔓延[4-6]. 因此,早期预警和快速定位火源对保障电力管廊安全至关重要. 如何提升对电力管廊早期火灾实时准确检测并做出火灾预警是早期火灾检测的关键.

当前火灾检测主要集中在传统图像检测和基于深度学习的神经网络检测,传统图像检测方法主要利用 OpenCV 对火灾图像进行特征分析进行手工特征提取,这种方法虽解释性较强但是对于复杂环境显得鲁棒性较差,难以实现实时精准检测效果.

利用传统图像火灾检测主要对图像中火灾的静态特征和动态特征进行提取[7],如颜色特征、尖角特征等静态特征. 其中动态特征包括频闪特征运动特征等. 采用传统图像处理火灾检测主要是结合一种特征或者融合多种特征并结合机器学习的方式进行火灾检测. Foggia 等[8]提出通过分析视频图像,基于颜色形状变化和运动分析的互补信息来构建可以部署在嵌入式轻量化的火灾检测系统. Celik 等[9]利用可见光相机通过对火灾像素的样本图像进行统计分析,构建通用火灾颜色模型. 基于火焰区域的视觉特征实现了火灾检测. Hashemzadeh 等[10]开发了一种基于鲁棒帝国竞争算法的颜色模型和引入了一种运动强度感知的运动检测技术提取包含运动的区域以及每个运动像素的运动强度率,然后将其用于分析火灾的特征. 肖霞等[11]给出一种基于火点与背景的类间方差和烟雾掩膜的红外光谱火点检测算法. 该算法的潜在火点判定阈值利用 MODIS 热红外光谱通道亮温数据的类间方差值将森林火灾火点从背景中区分出来,并对低温闷烧火点采用烟雾掩膜进行识别. 上述方法采用传统图像处理方式对火灾图像不同的特征进行特征提取,但是传统图像处理特征提取对于图像包含特征提取并不全面,只能提取到浅层信息存在一定的局限性. 而且传统图像算法容易受到环境干扰误报率高,精度有限.

随着深度学习的快速发展,基于卷积神经网络(convolution neural networks, CNN)的目标检测被提出,有许多研究人员将其应用到火灾检测任务当中. 冯路佳等[12]提出基于卷积神经网络(CNN)特征提取对火灾烟雾的检测. 张坚鑫[13]基于 Faster R-CNN,结合注意力机制实现了对火灾的检测,并取得了一定的检测效果.

基于深度学习的方法能够提取到火灾更加深层次的特征,适用于更加复杂的场景,鲁棒性较高. 李悦明等[14]在应对古建筑火灾事故频繁发生,对于珍贵文物保护中提出了一种基于图像超分辨率技术的消防危险品检测模型. 通过对 YOLOv8 模型实现了有效且高效的古建筑火灾防控任务. 邓力等[15]采用轻量型模块 SlimNeck 和切片辅助推理方法 SAHI,分别优化了 YOLOv8 算法的网络结构和推理框架,实验结果表明改进算法有效改善了火灾检测的漏检与误检的现象. Chen 等[16]基于火灾检测的性能,提出了一种改进的 PP-YOLO 的火焰检测方法. 引入一个特征融合网络来融合两个相邻的主干输出特征图,使得高层特征能够更好地融合低层特征的细节. Xiao 等[17]指出在火灾探测中为了提高嵌入式设备的火灾探测精度需要大量的计算资源,但是火灾探测所需的高精度与许多嵌入式设备的低计算能力之间产生了矛盾. 因此提出了一种多尺度注意模块(MAM),它

有效地整合了多尺度信息以增强特征表示. 另外一种新的高效多尺度卷积模块(EMCM)被结合到 C2f 结构中，以增强火焰和烟雾特征的提取，从而在不增加计算复杂度的情况下提供额外的特征信息.

当前深度学习网络模型检测精度表现良好，但是网络参数量较大，对设备性能要求过高不利于部署在边缘设备. 处于阴暗环境下的电力管廊内小目标火源和暗光条件下检测效果不理想，针对早期阴燃阶段识别缺陷问题提出了一种基于 YOLOv8 改进的轻量级的早期火灾检测方法，并通过使用红外可见光图像融合技术提升早期火灾检测的准确性以及低误检率.

笔者首先在特征融合阶段 Neck 端引 AFPN(渐近特征金字塔网络)有效解决了传统特征金字塔网络自顶向下的融合方式所带来的信息丢失的问题. 其渐进式融合策略和自适应空间融合操作有助于更好地提取小目标的特征. 在此基础上使用更轻量化的目标检测头 LADH(lightweight asymmetric dual-head)，LADH 检测头在减少模型参数和计算量的同时，保持较高的检测性能；并且可以提升模型的推理速度，更加适合实时目标检测任务. 替换原始 YOLOv8 的损失函数更换为 WIoU，其引入了权重机制，对于不同大小的目标可以赋予不同的权重，并且可以提高模型对于小目标的检测精度. 使用 EMAFusion 红外可见光图像融合算法对红外与可见光图像融合，融合图像结合两种图像优势，可以显著提高早期火灾检测的准确性、可靠性和适应性，降低误报率和漏报率，为火灾早期检测提供了有效地支持.

1 早期火灾检测方法

1.1 YOLOv8 算法

继 YOLOv5 之后，Ultralytics 公司在 2023 年发布了 YOLOv8，该版本可以用于执行目标检测、实例分割和图像分类任务. YOLOv8 算法提供了 n、s、m、l、x 五种不同尺度的模型，用于不同场景的需求. YOLOv8 在模型结构上主要将检测头由耦合头改进为解耦头，将 C3 模块改进为 C2f 提供了更加丰富的语义信息，而且轻量化和实时性表现更好. 而 YOLOv8 使用 FPN 结构来实现多尺度特征融合，通过自顶向下和自底向上的路径聚合不同尺度的特征图，这种融合方式会损害非相邻层次之间的特征融合效果. 这些问题限制了目标检测性能的提升，容易导致信息的丢失，需要进一步研究.

1.2 YOLOv8-fire 算法

本文选择 YOLOv8n 作为基准模型进行轻量化的改进，图 1 为提出的 YOLOv8-fire 轻量级早期火灾检测识别方法的网络结构.

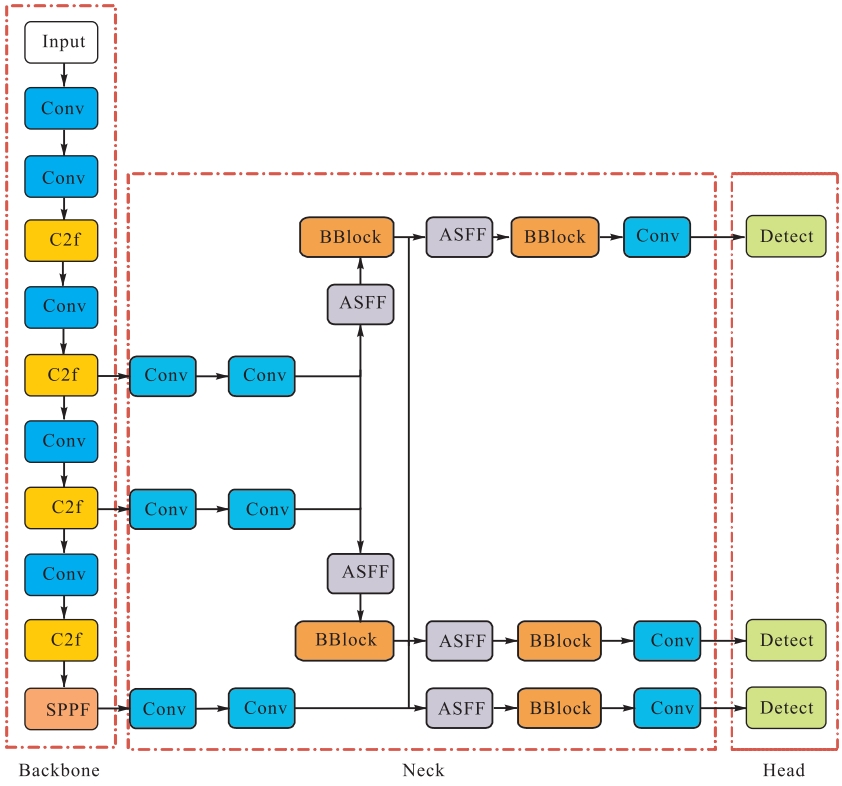


图 1 YOLOv8-fire 网络结构

Fig.1 YOLOv8-fire network structure

在输入端，YOLOv8 会接收输入数据的图像数据，在将输入图像送入模型之前，输入端会对图像进行一些预处理，使用 Mosaic 进行数据增强，以增加模型训练时的数据多样性，提高模型的泛化能力.

在特征融合阶段，分别使用多个 Conv 层和 ASFF_2、ASFF_3 模块进行特征融合和处理. 这些模块可以通过自适应地调整特征图的尺寸和权重，能够有效地融合不同层级的特征图，相比于 YOLOv8 特征融合通过上采样和特征图拼接(Concat)实现，使用 C2f 模块进行进一步的特征提取. 这种方法简单直接，但在处理不同层级特征图时可能不够灵活. 改进后的特征融合更好地保留不同尺度的特征信息，从而提高模型对不同大小目标的检测能力. 此外，ASFF 模块的灵活性也允许模型根据输入数据的特点动态调整特征融合策略，进一步提高模型的适应性和性能.

1.3　AFPN 特征融合网络

YOLOv8 算法采用了 PAFPN 特征融合网络以提升目标检测的性能. 然而，在传统的特征金字塔结构中，高层语义特征需经过多个中间尺度的传播和融合才能与底层定位信息相结合. 此过程中，高层语义信息可能发生丢失或退化，导致底层和顶层特征间的语义信息差距扩大，进而影响小目标的检测精度. 为解决非相邻特征层间语义信息差异过大的问题，AFPN 网络采用了一种渐进式多轮融合策略[18]，AFPN 有助于保留高层语义信息，提高小目标的检测能力；逐层融合和多轮迭代有助于更好地整合不同层级的特征，增强模型的特征表达能力. 自适应空间融合和特征对齐技术有助于提高模型对于不同场景和目标的适应性，增强鲁棒性. AFPN 通过渐进式融合策略减少了不必要的计算，优化了计算效率，使模型在保持高性能的同时，还能实现较低的计算成本.

从主干网络(Backbone)中的 C2f 模块进行下采样后得到不同尺度的特征图，选择 $80 \times 80 \times 256$、$40 \times 40 \times 512$ 和 $20 \times 20 \times 512$ 输入特征图集{C3，C4，C5}. 如图 2 所示，特征图 C3 和 C4 首先进行一阶 AFPN 渐进特征融合.

在进行一阶 AFPN 特征融合之后，得到输出特征 P3 和 P4. 然后对于又生成的特征图 P3 和 P4 与 C5 进行二阶的 AFPN 特征融合，得到输出特征图 Q3、Q4 和 Q5，如图 3 所示.

1.4　LADH 检测头

LADH(lightweight asymmetric detection head)是一种轻量级非对称检测头[19]，检测头通常采用对称结构，即对不同任务(如分类和回归)使用相同的卷积层. 然而，分类和回归任务的关注点不同，分类更侧重于样本的纹理特征，回归则更关注目标的边缘特征，这种对称结构会导致任务间的冲突，影响检测性能. LADH 检测头采用非对称设计，将网络路径根据任务类型进行分离，分别处理分类和回归任务，从而减少任务间的冲突，提高检测精度. 另外，LADH 检测头还引入了多级压缩的概念. 通过在不同的检测层级上应用不同程度的压缩，逐级减少卷积核数量和通道数量，从而降低模型的参数量和计算复杂度，同时保持较高的检测精度. 其 LADH 结构图如图 4 所示，P3 ~ P5 为 AFPN 生成的特征图. LADH 包含两个主要组件：Asymmetric-Head 和 Dual-Head. 前者负责对不同类别的特征进行非对称压缩，以适应不同类别特征的差异性，从而提高模型对各类目标的检测能力. 这种非对称设计能够更好地适应目标的大小变化，提高检测的准确性和效率. 而 Dual-Head 则通过两个并行的分支分别处理分类和回归任务，有效解决分类和回归任务之间的冲突，提高模型的检测性能. 这种设计通过分离分类和边界框任务，避免了两个任务的过度扩展，因为与两个任务匹配的正样本相对较少，相关损失也较小，从而进一步减少模型参数并提高检测速度. 这种设计通过优化检测头结构，既可以显著减少模型参数，又可以提高检测精度.

在检测头部分，使用改进的新检测头 LADH，它

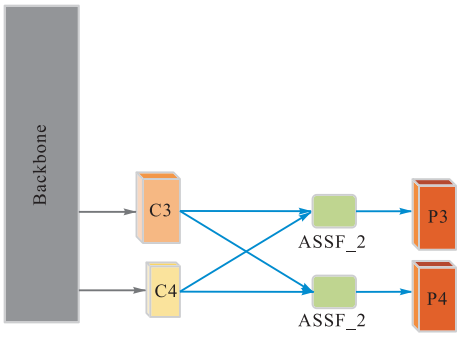


图 2　一阶 AFPN

Fig.2　First-order AFPN

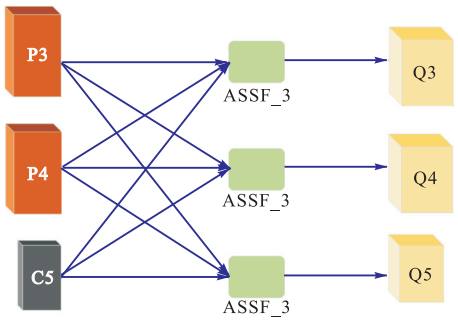


图 3　二阶 AFPN

Fig.3　Second-order AFPN

是在原有的 YOLO 架构基础上进行的改进，LADH 使用动态生成锚点，有助于提高模型对于不同尺寸目标的适应性，特别是对于小目标的适应性. 通过额外的卷积层对特征图进行处理和融合，这有助于提取更丰富的特征. 并且 LADH 使用 DFL 来优化边界框预测，这可能有助于提高模型对小目标和重叠目标的检测能力.

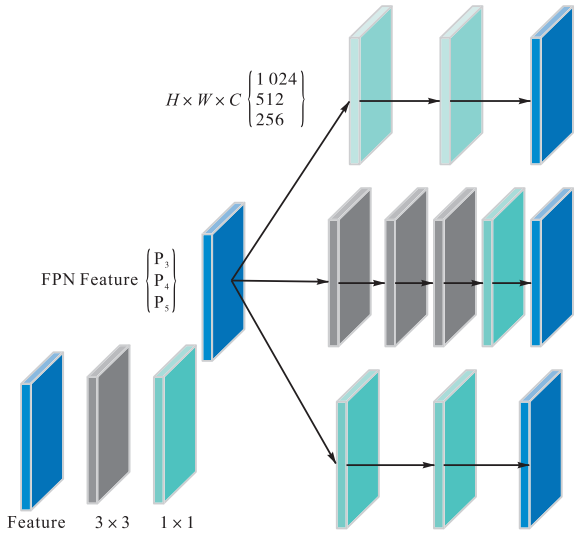


图 4　LADH 结构

Fig.4　LADH structure

1.5　WIoU 损失函数

在早期火灾检测任务中，由于早期火灾目标小，边界框与真实火灾区域的重叠较小，I_{IoU} 值低，从而影响损失计算. 尽管 YOLOv8 中定位损失函数采用 CIoU[20]和 deep feature learning(DFL). 其中 CIoU 可以对预测框的损失和标签的真实框进行计算，虽然包含中心距离和纵横比、重叠面积，但是 CIoU 对于早期火灾小目标火源检测方面存在明显的缺陷问题. 一方面 CIoU 不仅会考虑重叠面积，还关注边界框的中心点距离和长宽比. 这使得边框形状不理想时损失过于敏感，干扰学习效果. 另一方面，CIoU 未能平衡高质量和低质量样本. 对于占比较小的火灾类别 CIoU 难以有效引导模型关注，导致特征学习困难[21]. 为了解决上述问题引入动态加权 WIoU[22] (weighted IoU with dynamic focusing)，在 WIoU 中，采用了动态非单调聚焦机制有利评估锚框异常值以及有效的梯度增益策略，以聚焦低质量锚框，从而提升整体精度. 目前，WIoU 有 3 个版本. 在 WIoUv1 中提出基于距离测量构建距离注意力机制；在 WIoUv2 中设计了一种单调聚焦机制，通过交叉熵更利于聚焦低质量的样本；WIoUv3 中，进一步引入了小梯度增益，以减少低质量样本的有害梯度. WIoUv1 公式如式(1) ~ (3)所示：

$$R_{WIoU}=\exp\left(\frac{(b_{xc}^{gt}-b_{xc})^2+(b_{yc}^{gt}-b_{yc})^2}{c_w^2+c_h^2}\right) \tag{1}$$

$$L_{IoU}=1-I_{IoU} \tag{2}$$

$$L_{WIoU}=R_{WIoU}\times L_{IoU} \tag{3}$$

WIoUv2 公式如式(4)所示：

$$L_{WIoUv2}=\left(\frac{L_{IoU}^{*}}{L_{IoU}}\right)^{\gamma}\times L_{WIoU}\qquad(\gamma>0) \tag{4}$$

WIoUv3 公式如公式(5) ~ (7)所示：

$$\beta=\frac{L_{IoU}^{*}}{L_{IoU}}\in[0,+\infty) \tag{5}$$

$$r=\frac{\beta}{\delta\alpha^{\beta-\delta}} \tag{6}$$

$$L_{WIoUv3}=r\times L_{WIoUv1} \tag{7}$$

式中：β 为锚框的质量为小梯度增益；δ 和 α 为可调超参数.

1.6　EMAFusion 图像融合

红外可见光图像融合(infrared and visible image fusion)，是一种图像处理技术，它结合红外(IR)图像和可见光(Visible)图像的优势生成单一的、增强的图像. EMAFusion 融合方法旨在通过增强的多尺度编码器和基于注意力的网络来提升红外图像和可见光图像的融合效果[23].

EMAFusion 融合方法包含 3 个主要部分：编码器(encoder)、解码器(decoder)和融合网络(fusion network)层，核大小为 1 × 3 × 1. 4 个 CBAM(卷积块注意力模块)，能够帮助编码器在提取特征时聚焦于重要特征并抑制不必要信息. 并且包含 4 个编码块，每个块包含 2 个卷积层和 1 个最大池化层. 采用跳跃连接(skip connections)来保留中间特征图，这些特征图可以被重用来改善特征表示能力. 在解码器部分采用基于嵌套架构(nest architecture)，每个解码块由 2 个卷积层组成. 不同层级的卷积层之间通过密集连接在解码器网络中串联多尺度深度特征. 融合网络通过集成通道注意力块和空间注意力块来提升图像融合性能. 通道注意力块由 8 个卷积层、两个 ReLU 层、平均池化层、最大池化层和 sigmoid 层构成，旨在增强对特征图中关键通道的感知能力. 空间注意力块则由 4 个卷积层、平均池化层、最大池化层和 sigmoid 层组成，专注于识别图像中的关键区域，如红外图像中的重要目标. 这两种注意力机制并行工作，使融合网络能够同时优化图像中的重要位置信息和特征通道，从而增强模型的整体融合效果. EMAFusion 的模型结构如图 5 所示.

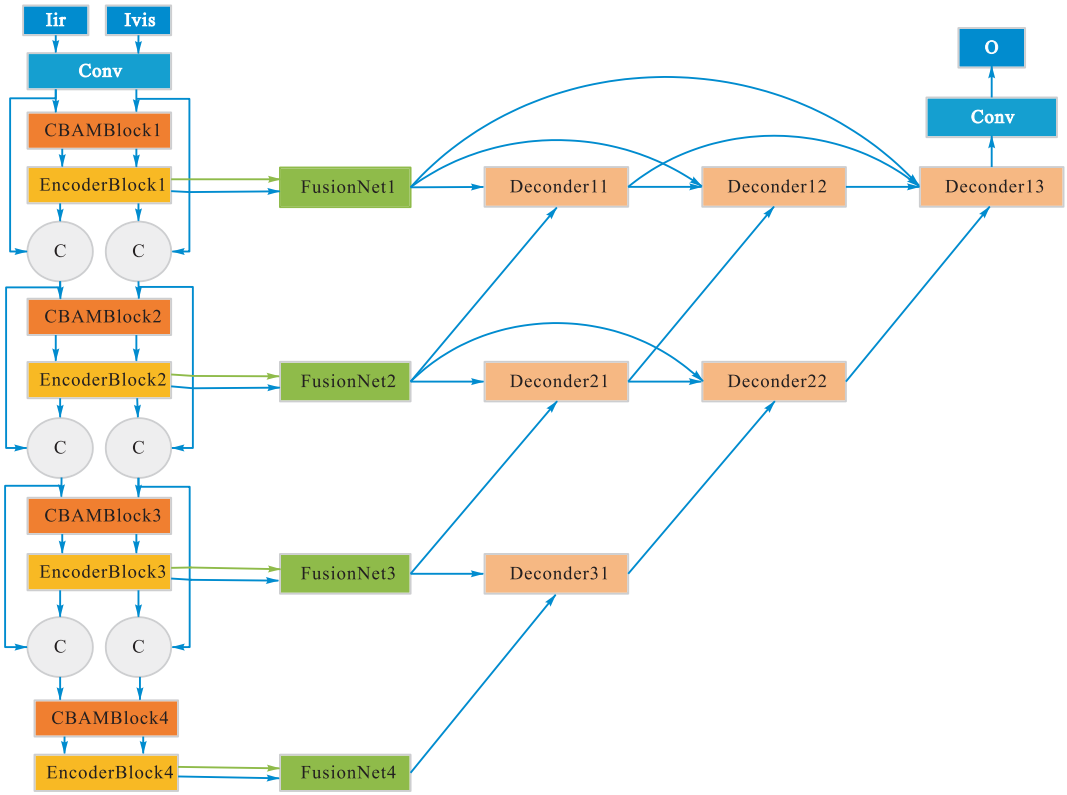
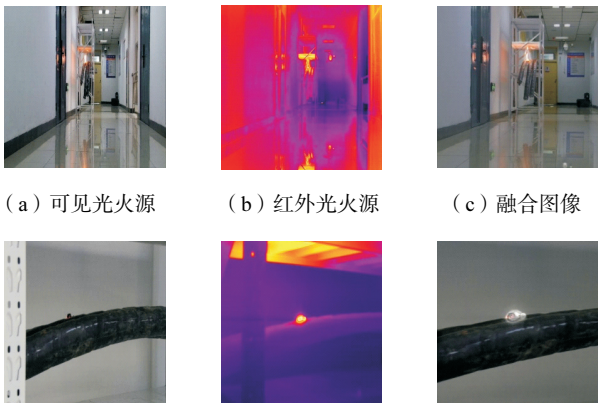


图 5　EMAFusion 结构模型[23]

Fig.5　EMAFusion structural model[23]

图 6 为可见光相机和红外相机拍摄的可见光图像和红外图像(数据集采集距离为 1 ~ 5 m)，将红外和可见光数据集经过 EMAFusion 模型融合的红外可见光融合图像. 可见光图像具有高分辨率的纹理信息，但是不包含红外图像的温度信息. 融合图像既包含可见光的纹理信息和红外图像的温度信息，二者信息互补. 对于火灾检测提供了更加有利的支持，特别在电力管廊低光照条件下提供更加全面的火灾图像信息. 红外可见光图像融合技术和可靠性，为火灾预警系统的优化提供了新的方法和思路.



（a）可见光火源　（b）红外光火源　（c）融合图像

（d）可见光阴燃图像　（e）红外阴燃图像　（f）融合图像

图 6　融合图像与单一图像对比

Fig.6　Comparison between fused image and single image

2　试验与分析

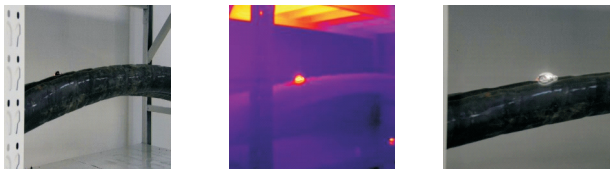
2.1　试验平台与训练参数

试验所使用的计算机 CPU 主频 2.3 GHz，内存大小为 128 GB，计算速率（以 GPU 为主）约为 83 TFLOPS（单精度）. 软件环境为 Pytorch1.13.0，Python3.10，CUDA 版本为 11.7. 使用自建数据集训练 200 个周期，初始学习效率为 0.01，使用 Mosaic 数据增强，输入图像尺寸为 640 × 640. 使用早停策略设置为 50 epcho，用于减少过拟合.

2.2　数据集制作

数据集的质量很大程度上决定着目标检测结果. 目前，火灾检测图像数据集多为森林火灾和室外火灾，而且分辨率普遍不高，不利于模型对火焰特征的学习. 因此，通过在室内试验场地模拟电力管廊环境进行早期火灾检测试验. 选择光线较为昏暗的管廊内模拟综合电力管廊光照不足环境. 数据集在制作上采用石蜡油混合碎纸屑以及阻燃材料模拟早期火灾阴燃以及小火源情况. 在自建的电力管廊场景下的火焰数据集中通过使用图像增强技术，对火灾数据集进行线性变换，包括裁剪，旋转，平移等处理，最终得到 5 000 张图像以防止过拟合，提高模型检测的

鲁棒性. 图 7 为火灾数据集的部分图像.



（a）可见光图像　（b）红外图像　（c）红外可见光融合图像

图 7　火灾图像部分数据集

Fig.7　Partial dataset of fire images

2.3　算法性能评价指标

在目标检测领域，准确评估算法的性能至关重要. 为了全面评估算法性能，采用多个评价指标来评估算法的性能，其中包括平均精确率（mean average precision，A_{mAP}），精确率（$R_{Precision}$），召回率（R_{Recall}），计算量（GFLOPs），参数量（Parameters），帧率（FPS）. 这些指标共同帮助评估算法在目标检测的表现. A_{mAP} 是衡量目标检测算法性能的重要指标之一. A_{mAP}@0.5 代表将 IoU 阈值取为 0.50 时的 A_{mAP} 值. A_{mAP}0.5∶0.95 代表 IoU 阈值在 0.50 到 0.95 之间变化时的 A_{mAP} 值. 其中精确率（$R_{Precision}$）、召回率（R_{Recall}）、平均精确率（A_{mAP}）、平均精度 A_{AP} 的计算公式，如公式（8）~（11）所示.

$$P_{Precision}=\frac{N_{TP}}{N_{TP}+N_{FP}} \tag{8}$$

$$R_{Recall}=\frac{N_{TP}}{N_{TP}+N_{FN}} \tag{9}$$

$$A_{mAP}=\frac{1}{N}\sum_{i=1}^{N}A_{P,i} \tag{10}$$

$$A_{AP}=\int_0^1 p(r)\mathrm{d}r \tag{11}$$

式中：N_{TP} 为被正确检测的正样本数，N_{FP} 为被错误检测成正样本的负样本数，N_{FN} 被错误检测成负样本的正样本数. 准确率和召回率均在 0 到 1 之间，反映算法的识别准确性和查全性. 平均精度 A_{AP} 表示在不同召回率水平下模型的精度的平均值. A_{mAP}（mean average precision）是对数据集的每个类别求 A_{AP} 值，对所有 A_{AP} 值求平均，得到 A_{mAP} 值.

2.4　模型实验结果

2.4.1　消融实验

为了验证 YOLOv8-fire 模型的有效性，进行了消融实验，实验结果见表 1.

表 1　消融实验结果

Tab.1　Ablation experimental results

Group	YOLOv8n	AFPN	LADH	WIoU	$P_{Precision}$/%	A_{mAP}@0.5/%	R	参数量/M	计算量/G	模型权重/MB	FPS/（帧/s）
1	√	×	×	×	95.8	93.4	90.7	3.0	8.1	6.3	256
2	√	√	×	×	97.0	94.9	90.4	2.3	6.8	4.9	256
3	√	×	√	×	98.2	95.0	91.4	3.0	8.1	6.3	250
4	√	×	×	√	96.1	95.1	91.2	3.0	8.1	6.3	256
5	√	√	√	×	95.3	95.1	92.1	2.3	6.7	4.9	256
6	√	√	×	√	96.1	95.0	91.6	2.3	6.7	4.9	250
7	√	×	√	√	97.2	95.3	91.2	3.0	8.1	6.2	243
8	√	√	√	√	97.1	95.3	92.9	2.2	6.7	4.9	345

注：“√”表示使用该模块，“×”表示未使用该模块.

从表 1 中可以看出，在基准模型的 $P_{Precision}$、A_{mAP}@0.5 和召回率的值分别为 95.8%、93.4% 和 90.7%，其参数量、计算量、FPS 以及模型权重分别为 3.0、8.1、256 和 6.3 在对网络轻量化时主要是对网络特征融合部分改进使用 AFPN 渐进特征融合，以及对原始检测头进行改进使用 LADH 更加轻量级的检测头使原始模型参数量和计算量以及模型权重得到了显著的下降，模型参数量下降了 23.3%，计算量下降了 17.28%，并且模型权重从 6.3 MB 下降到了 4.9 MB；相较于基准模型改进后的模型实现轻量化. 在此基础上引入新的损失函数 WIoU 后，$P_{Precision}$ 提升了 1.3%，A_{mAP}@0.5 提升了 1.9% 模型达到最优值，模型参数也达到了最优值 2.2 MB. 同时模型检测速度也显著提升到了 345 帧/s，相比于基准模型提升了 34.65%.

模型在轻量化后，模型参数量和计算量显著下降了，模型推理速度也有较大的提升；与此同时模型的检测精度也有提升.

2.4.2　不同算法性能对比实验

在保持实验环境相同的条件下，现将网络模型 YOLOv8-fire 和 YOLO 其他系列，SSD 和 Faster R-CNN 等先进目标检测算法进行性能上的对比，实验结果如表 2 所示.

由表 2 可以看出通过改进 YOLOv8n 基准模型，相比于其他算法本文提出的 YOLOv8-fire 在轻量化方面最具有优势的，在模型参数量上只有 2.2 MB，模型权重仅为 4.9 MB，也表现出了较大的优势. 可以看出模型显著降低了参数量和计算量. 相较于 YOLOv9 算法，参数量下降了 15.38%，而计算量显著下降了 40.71%. 而且模型在准确率和精度上也有

表 2　不同算法性能结果对比

Tab.2　Comparison of performance results of different algorithms

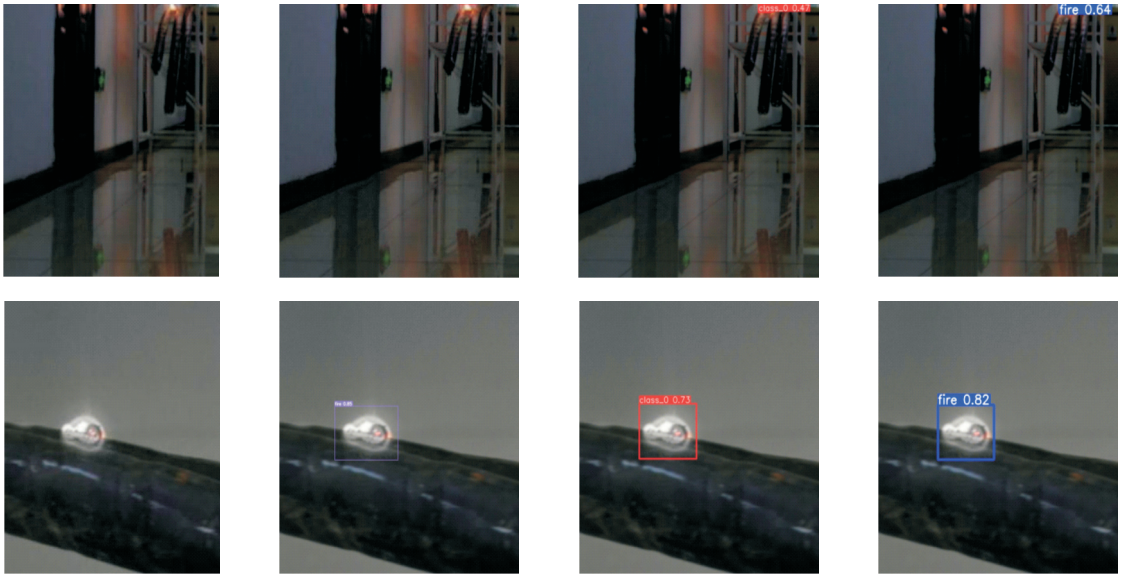
算法	P/%	A_{mAP}@0.5/%	参数量/M	权重/MB	计算量/G	FPS
Faster-RCNN	60.1	72.3	25.4	180.4	170.5	10.5
SSD	90.5	91.6	23.3	80.5	145.4	30.3
YOLO v5s	97.6	94.9	7.0	14.4	15.8	88
YOLO v7-tiny	95.5	94.1	6.5	12.3	16.5	87
YOLOv9t	94.5	95.2	2.6	6.1	11.3	220
YOLOv10n	97.3	95.0	2.6	6.7	6.3	250
YOLOv11n	97.0	94.8	2.7	5.5	6.8	278
YOLOv8 fire(ours)	97.1	95.3	2.2	4.9	6.7	345

不小的提升. 与 YOLOv10 相比模型的准确率略高于改进模型但是相比于本文改进的模型在参数量和计算量均与较大的差别，不如改进网络轻量化.

在检测速度方面，改进后的模型(YOLOv8-fire)在检测速度(FPS)方面表现是最为出色的. 改进模型 YOLOv8-fire 的 FPS 为 345 与其他 YOLO 系列基准模型相比有显著提高. 相比 YOLOv9t 提高了约 56.8% 而且模型精度也略有提升，相比 YOLOv10n 模型的准确率虽然有所下降，但是模型 FPS 和检测精度都有一定的提升.

由此可知，改进算法在早期电力管廊火灾检测方面轻量化显著优于其他算法，而且在保证模型轻量化的同时算法的检测精度仍有提升.

图 8 为不同算法在融合图像上检测结果对比，图 8(a)第 1 张图片为在火源小目标条件下融合图像；第 2 张为在火源在阴燃状态下的融合图像. 通过预测效果对比图可以看出改进后的 YOLOv8 可以很好地识别小目标火源，与其他算法相比检测效果较好.



(a) 原图　(b) Yolov5s　(c) Yolov9t　(e) 本文结果

图 8　不同算法预测结果对比

Fig.8　Comparison of prediction results from different algorithms

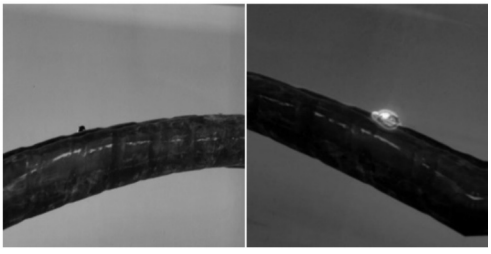
2.4.3　融合图像与单光谱图像对比实验

在保持实验条件相同的情况下，现分别使用红外图像，可见光图像，与融合图像使用改进算法进行对比实验，实验结果如表 3 所示. 图 9 为融合图像与可见光图像对比.

表 3　融合图像与单光谱图像火灾检测对比实验

Tab.3　Comparative experiment of fire detection between fused images and single-spectral images

图像数据集	P/%	A_{mAP}@0.5/%	漏检率/%
红外图像	96.8	96.0	7.5
可见光图像	95.2	95.1	8.1
融合图像	97.1	95.3	7.1



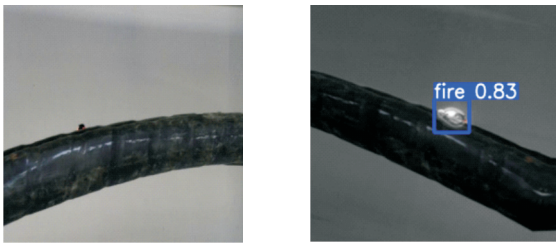
(a) 融合图像　(b) 可见光

图 9　融合图像与可见光图像对比

Fig.9　Comparison between fused image and visible light image

图 10 为融合图像与可见光图像检测效果对比

图. 可以明显地看出在可见光条件下，火灾早期火源并不明显，无法判断是否发生火灾，容易产生漏检，在融合图像下可以更加准确地检测识别出早期火灾，更加有利于防范火灾的发生.



（a）可见光　　（b）红外图像

图 10　可见光与红外图像早期火灾检测效果对比

Fig.10　Comparison of early fire detection effectiveness between visible light and infrared images

3　结　论

(1)针对电力管廊内早期火灾隐患检测存在复杂背景下小目标检测效果欠佳、模型的参数量大、不够轻量化等问题边缘设备部署困难，本文提出了一种轻量级的早期火灾检测算法：YOLOv8-fire. 该算法在特征融合阶段 Neck 端引入 AFPN(渐近特征金字塔网络)通过自适应权重融合和多尺度特征融合，AFPN 能够显著提升模型对小目标的检测能力. 引入 LADH 检测头在保持轻量化的同时提高模型的检测精度. 最后使用 WIoU 损失函数优化网络的边界损失，提高网络模型检测准确性.

(2)对于早期火灾检测存在阴燃情况，可见光图像难以检测等问题，本文提出红外可见光图像融合方法，融合算法的引进提高了早期火灾检测的准确性，减少了早期火灾检测的漏检率.

参考文献：

[1] Ko J. Study on the fire risk prediction assessment due to deterioration contact of combustible cables in underground common utility tunnels[J]. *Journal of the Society of Disaster Information*, 2015, 11(1): 135-147.

[2] 曾晓亮，李富祥，李明伟，等. 电缆隧道火灾事故特点与灭火系统研究综述[J]. 四川电力技术，2022，45(4)：55-59.
Zeng Xiaoliang, Li Fuxiang, Li Mingwei, et al. Review on characteristics of cable tunnel fire accidents and fire-extinguishing systems[J]. *Sichuan Electric Power Technology*, 2022, 45(4): 55-59(in Chinese).

[3] 杨立中，叶　开. 城市综合管廊消防标准及火灾研究综述[J]. 中国安全科学学报，2021，31(8)：132-140.
Yang Lizhong, Ye Kai. Review on fire protection standards and fire research of urban utility tunnels[J]. *China Safety Science Journal*, 2021, 31(8): 132-140(in Chinese).

[4] 许德胜，李炎锋，杨　泉. 综合管廊电力舱电缆火灾研究进展[J]. 消防科学与技术，2024，43(9)：1213-1217，1246.
Xu Desheng, Li Yanfeng, Yang Quan. Research progress on cable fires in power cabins of utility tunnels[J]. *Fire Science and Technology*, 2024, 43(9): 1213-1217, 1246(in Chinese).

[5] 张　敏，张明灿，李兵兵，等. 综合管廊电力舱散热计算及通风研究[J]. 地下空间与工程学报，2024，20(S2)：916-923.
Zhang Min, Zhang Mingcan, Li Bingbing, et al. Heat dissipation calculation and ventilation research on power cabin of utility tunnel[J]. *Chinese Journal of Underground Space and Engineering*, 2024, 20(S2): 916-923(in Chinese).

[6] 张　晋，徐大军，宋文琦，等. 城市综合管廊电力舱火灾行为试验研究[J]. 地下空间与工程学报，2020，16(6)：1818-1825.
Zhang Jin, Xu Dajun, Song Wenqi, et al. Experimental study on fire behavior of power cabin in urban utility tunnel[J]. *Chinese Journal of Underground Space and Engineering*, 2020, 16(6): 1818-1825(in Chinese).

[7] 秦　瑞，张　为. 一种无锚框结构的多尺度火灾检测算法[J]. 西安电子科技大学学报，2022，49(6)：111-119.
Qin Rui, Zhang Wei. A multi-scale fire detection algorithm based on anchor-free structure[J]. *Journal of Xidian University*, 2022, 49(6): 111-119(in Chinese).

[8] Foggia P, Saggese A, Vento M. Real-time fire detection for video-surveillance applications using a combination of experts based on color, shape, and motion[J]. *IEEE TRANSACTIONS on Circuits and Systems for Video Technology*, 2015, 25(9): 1545-1556.

[9] Celik T, Demirel H, Ozkaramanli H, et al. Fire detection using statistical color model in video sequences[J]. *Journal of Visual Communication and Image Representation*, 2007, 18(2): 176-185.

[10] Hashemzadeh M, Zademehdi A. Fire detection for video surveillance applications using ICA K-medoids-based color model and efficient spatio-temporal visual features[J]. *Expert Systems with Applications*, 2019, 130: 60-78.

[11] 肖　霞，宋卫国，王　彦，等. 基于类间方差的

MODIS 森林火灾火点检测方法[J]. 光谱学与光谱分析，2010，30(8)：2065-2068.
Xiao Xia，Song Weiguo，Wang Yan，et al. MODIS forest fire spot detection method based on inter-class variance[J]. *Spectroscopy and Spectral Analysis*，2010，30(8)：2065-2068(in Chinese).

[12] 冯路佳，王慧琴，王 可，等. 基于目标区域的卷积神经网络火灾烟雾识别[J]. 激光与光电子学进展，2020，57(16)：83-91.
Feng Lujia，Wang Huiqin，Wang Ke，et al. Fire smoke recognition based on target-region convolutional neural network[J]. *Laser & Optoelectronics Progress*，2020，57(16)：83-91(in Chinese).

[13] 张坚鑫. 基于深度学习的火灾图像分类与检测算法研究[D]. 广州：广州大学，2020.
Zhang Jianxin. Research on Fire Image Classification and Detection Algorithm Based on Deep Learning[D]. Guangzhou: Guangzhou University，2020(in Chinese).

[14] 李悦明，黄国忠，王 波，等. 一种基于 CA-SRGAN 的古建筑消防危险品检测模型[J]. 清华大学学报(自然科学版)，2024，64(11)：1870-1879.
Li Yueming，Huang Guozhong，Wang Bo，et al. Detection model of fire hazard goods in ancient buildings based on CA-SRGAN[J]. *Journal of Tsinghua University(Science and Technology)*，2024，64(11)：1870-1879(in Chinese).

[15] 邓 力，周 进，刘全义. 基于改进 YOLOv8 的火焰与烟雾检测算法[J]. 清华大学学报(自然科学版)，2025，65(4)：681-689.
Deng Li，Zhou Jin，Liu Quanyi. Flame and smoke detection algorithm based on improved YOLOv8[J]. *Journal of Tsinghua University(Science and Technology)*，2025，65(4)：681-689(in Chinese).

[16] Chen C，Yu J，Lin Y，et al. Fire detection based on improved PP-YOLO[J]. *Signal，Image and Video Processing*，2023，17(4)：1061-1067.

[17] Xiao L，Li W，Zhang X，et al. EMG-YOLO：An efficient fire detection model for embedded devices[J]. *Digital Signal Processing*，2025，156：104824.

[18] Yang G，Lei J，Zhu Z，et al. AFPN：Asymptotic feature pyramid network for object detection[C]//2023 *IEEE International Conference on Systems，Man，and Cybernetics(SMC)*. IEEE，2023：2184-2189.

[19] Zhou W，Cai C，Srigrarom S，et al. ADH-YOLO：A small object detection based on improved YOLOv8 for airport scene images in hazy weather[J]. *The Journal of Supercomputing*，2025，81(3)：1-20.

[20] Zheng Z，Wang P，Liu W，et al. Distance-IoU loss：Faster and better learning for bounding box regression[C]//*Proceedings of the AAAI Conference on Artificial Intelligence*. 2020：12993-13000.

[21] 毛 坤，朱学军，赖惠鸽，等. 多尺度融合优化的印刷电路板缺陷检测算法[J]. 激光与光电子学进展，2025，62(10)：141-152.
Mao Kun，Zhu Xuejun，Lai Huige，et al. Defect detection algorithm for printed circuit boards optimized by multi-scale feature fusion[J]. *Laser & Optoelectronics Progress*，2025，62(10)：141-152(in Chinese).

[22] Hu D，Yu M，Wu X，et al. DGW‐YOLOv8：A small insulator target detection algorithm based on deformable attention backbone and WIoU loss function[J]. *IET Image Processing*，2024，18(4)：1096-1108.

[23] Wang J，Chen Y，Sun X，et al. Advancing infrared and visible image fusion with an enhanced multiscale encoder and attention-based networks[J]. *iScience*，2024，27(10)：110915.