

文章编号: 1671-7449(2026)01-0026-08

J. Test Measur. Technol., 2026, 40(1): 26-33.

基于改进YOLOv11n的液体火箭发动机地面测试异常火焰检测

任勇峰*, 姜力玮

(中北大学 极限环境光电动态测试技术与仪器全国重点实验室, 山西 太原 030051)

摘要: 液体火箭发动机作为航天运载器的核心动力装置, 其地面测试中出现的异常火焰是结构性失效甚至灾难性事故的关键早期征兆。此类故障发展迅速且破坏性大, 所以准确、迅速识别故障火焰非常重要。为此提出了一种基于优化YOLOv11n的火焰识别算法。首先, 在C3k2模块中引入可变形卷积DCNv4, 并添加到YOLOv11n骨干网络中, 增强模型对复杂几何形状和尺度变化的感知; 其次, 引入DySample上采样替代邻近插值上采样, 减少上采样过程中的特征信息丢失, 从而提升模型对小目标的识别能力; 最后, 将CIoU Loss替换为Focal-EIoU损失函数, 提高收敛速度和回归精度。实验结果表明, 优化后算法的检测效果有了明显提升, 平均检测精度达到了91.8%, 较基准模型YOLOv11n提升2.4个百分点, 在参数量仅增加25%的代价下, 实现了检测精度和模型复杂度的平衡。

关键词: YOLOv11n; 目标检测; 算法改进; 故障识别; 动态采样

中图分类号: V434

文献标识码: A

DOI: 10.62756/csjs.1671-7449.2026044

引用格式: 任勇峰, 姜力玮. 基于改进YOLOv11n的液体火箭发动机地面测试异常火焰检测[J]. 测试技术学报, 2026, 40(1): 26-33.

REN Yongfeng, JIANG Liwei. Abnormal flame detection of liquid rocket engine ground test based on improved YOLOv11n[J]. Journal of Test and Measurement Technology, 2026, 40(1): 26-33.

Abnormal Flame Detection of Liquid Rocket Engine Ground Test Based on Improved YOLOv11n

REN Yongfeng*, JIANG Liwei

(State Key Laboratory of Extreme Environment Optoelectronic Dynamic Measurement Technology and Instrument, North University of China, Taiyuan 030051, China)

Abstract: Abnormal flames observed during ground tests of liquid rocket engines that is core propulsion systems for aerospace launch vehicles suggests critical early indicators of structural failures or catastrophic accidents. Given the rapid progression and severe destructiveness of such faults, accurate and prompt flame detection is essential. To address this issue, an optimized flame detection algorithm based on YOLOv11n is developed. Firstly, DCNv4 is integrated into the C3k2 module within the YOLOv11n backbone network, enhancing the model's perception of complex geometries and large-scale variations. Secondly, DySample upsampling is introduced to replace nearest-neighbor interpolation to mitigate feature information loss during resolution recovery, improving small-target detection. Thirdly, the CIoU loss

【收稿日期】2025-09-06

【基金项目】国家自然科学基金资助项目(52435011)

*【通信作者】任勇峰(1968—), 男, 教授, 博士, 主要从事测试计量技术及仪器研究。E-mail: renyongfeng@nuc.edu.cn.

function is substituted with Focal-EIoU to accelerate convergence and refine localization precision. Experimental results demonstrate that the optimized algorithm achieves significant improvements, and mean average precision reaches 91.8% and improves a 2.4 percentage point compared with the baseline YOLOv11n model. While maintaining a 25% parameter overhead, this method achieves a balance between detection accuracy and computational complexity.

Key words: YOLOv11n; object detection; algorithm improvement; fault identification; dynamic upsampling

0 引言

液体火箭发动机作为航天运载器的核心动力装置,其地面测试的安全性与可靠性直接关乎试验成败和人员设备安全^[1]。在发动机测试中出现的异常燃烧现象(如局部烧穿、密封失效导致的推进剂泄漏燃烧、点火时序错误引发的爆燃),是预示结构性失效甚至灾难性事故的关键早期征兆。因此,对异常位置出现的火焰进行快速、准确的检测是辅助故障诊断、保障试验安全、优化发动机设计的关键环节。

传统检测方法主要分为两类,一类是依赖离散式传感器的网络报警,另一类是采用基于固定阈值分割的图像处理技术。这些方法往往存在响应滞后、空间分辨率受限、难以捕捉火焰形态复杂变化等问题,无法满足现代高密度、高风险测试任务对实时性与高精度的迫切需求。近年来,随着高帧率 HDR 摄像设备的发展与深度学习算法的进步,基于深度学习的异常火焰实时检测技术在毫秒级响应与像素级定位方面展现出显著潜力。主流的深度学习目标检测算法分为两大类:单阶段算法与两阶段算法。单阶段目标检测算法核心思想是端对端预测,代表算法有 SSD^[2]、YOLO^[3]、RT-DETR^[4]等;两阶段算法基于区域建议,代表模型有 R-CNN^[5]、Faster R-CNN^[6]等。单阶段目标检测算法相较于两阶段算法,具有更好的实时检测性能。

近年来,针对火焰的目标检测算法取得了很大进展。黄力等^[7]针对小目标难以检测的问题,在主干网络后采用递归特征金字塔结构以增强模型在多尺度上的特征提取能力。周欣等^[8]针对提高火焰检测精度的问题,设计了一种改进的 EIoU 损失函数,通过对比实验确定参数 α 的最佳取值,提高了模型的火焰检测精度。刘成明等^[9]针对小目标火焰的检测,增加了一个小目标检测层,并引入 SE 注意力模块从而增强对小目标特征的提

取能力。马耀名等^[10]针对复杂背景下烟雾火焰目标与背景混淆的问题,设计了多尺度上下文融合模块来捕捉并利用上下文信息,增强特征的表示。卞苏阳等^[11]利用 XSepConv、大卷积核、Mish 激活函数等对 YOLOv5 的骨干网络进行改造,加强了模型的火焰特征提取能力。

综上所述,研究者在应对复杂背景干扰、小目标检测、强化特征提取能力等提升火焰检测性能的关键方向已取得显著进展。基于此,本文开展针对液体火箭发动机测试的异常火焰识别研究。首先,建立数据集,收集液体火箭发动机测试环境下的火焰图片,为了增加数据集的多样性,加入不同火焰的图片对数据集进行扩充。其次,对于主干部分,使用可变形卷积网络 DCNV4^[12]改进 C3k2 模块,提出 C3k2_DCN 模块,强化网络对不同形态特征的提取能力。对于颈部网络,采用动态上采样^[13]作为高层特征图上采样的方式,增强小目标检测能力。最后,使用 Focal-EIoU 损失函数提高模型回归精度。

1 相关原理

1.1 Yolov11 算法

YOLOv11^[14]是 2024 年由 Ultralytics 公司发布的目标检测算法。与之前的 YOLO 算法相比,YOLOv11 在检测精度和处理速度上都得到了进一步提高,其主要由主干网络、颈部网络和检测头 3 个部分组成。在主干部分,YOLOv11 使用 C3k2 结构替换 C2f 结构,使用小核卷积使模型轻量化。在 SPPF 之后增加了 C2PSA 结构,其通过将通道与空间注意力机制融入跨阶段局部网络,实现了效率与全局感知能力的完美结合,从而在显著提升模型精度的同时保持了较高的计算效率。

1.2 算法存在的问题

鉴于液体火箭发动机测试对准确、实时检测

的需求,本研究以YOLOv11n为基础模型。然而,在实际应用中发现其存在一定局限性:该模型采用的传统卷积模块难以有效应对动态尺寸目标的特征提取,使其难以有效识别不同尺度的火焰,尤其对小目标火焰的检测效果不佳;其次,由于火焰形状不规则,导致特征提取困难,模型易出现漏检和误检,整体识别精度较低。

2 改进模型

在YOLOv11n框架的基础上,本文提出了一种改进的液体火箭发动机异常火焰检测模型DDF-YOLO11n。该模型在保持轻量化的同时,实现了识别精度的提升。图1展示了DDF-YOLO11n模型的架构。




图1 YOLO11n算法改进图

Fig. 1 Improved YOLO11n algorithm

2.1 C3k2_DCN模块

在卷积神经网络中,模型的性能在很大程度上取决于其感受野的大小和形状,传统卷积操作中卷积核的大小和采样位置是固定的,难以适应火焰在形状和尺度上的变化,传统卷积在这一场景下的检测任务存在效果不佳的问题。

斯坦福大学的研究者于2019年提出了DCN算法,其核心思想是通过引入额外的可学习偏移量来动态调整卷积核的形状,从而扩大有效感受野并捕获长距离依赖关系,使卷积核能够聚焦于目标关键区域,从而增强网络对输入特征图尺度和形状变换的适应性。假设输入特征图 $x \in \mathbb{R}^{H \times W \times C}$,其工作流

程如下:

首先,将输入特征图按照通道数分成多个组,对于分组后的特征图,使用一个深度可分离卷积和一个线性层动态预测每个位置 K 个采样点的采样点偏移量 Δp_{gk} 和调制量 Δm_{gk} 。然后,根据生成的偏移在特征图上进行可变形卷积操作,得到这一组的特征图。在获得所有分组的输出结果后,继而沿通道维度将其拼接,聚合为最终的特征图。该过程的数学表达为

$$y_g = \sum_{k=1}^K \Delta m_{gk} x_g(p_0 + p_k + \Delta p_{gk}), \quad (1)$$

$$y = \text{concat}([y_1, y_2, \dots, y_g], \text{axis} = -1), \quad (2)$$

式中: g 为分组数; x_g 和 y_g 分别为第 g 组的输入与输出特征图; p 为卷积中心点; K 为采样点总数;

Δp_{gk} 和 Δm_{gk} 为第 g 组中的第 k 个采样点的偏移量与调制量; y 为最终输出的特征图。可变形卷积的流程如图 2 所示。

C3k2 模块的核心是跨尺度特征融合, 这种结构有助于融合浅层原始信息和深层抽象信息, 从而学习复杂的特征变换。DCNv4 通过偏移量动态调整卷积核采样位置, 有效提升了输入图像中几何变形、不规则形状和不同尺度目标的适应性。将 C3k2 结构中 Bottleneck 部分第二层的常规卷积替换为可变形卷积 DCNv4, 形成了 Bottleneck_DCN 模块。其具体操作是: 如果输入通道数与输出通道数相等, 则启用残差连接, 将输入特征图 X 与 DCNv4 处理后的输出进行融合。这种设计不仅融合了跨尺度信息, 并增强了对空间变形的鲁棒性, 还增加了梯度流动, 有效缓解了深层网络的梯度消失问题。残差连接时该模块的输出为

$$Y = X + \text{DCNv4}(\text{Conv2d}(X)). \quad (3)$$




图 2 可变形卷积操作

Fig. 2 Deformable convolution operation

由于深层特征对应更大的感受野, 包含更抽象的语义信息, 在深层网络添加 C3k2_DCN 模块是合适的, 增强上下文建模能力的同时不会大幅增加计算量。

2.2 上采样算子 DySample

DySample 算子的核心思想是通过输入特征动态生成采样位置, 实现轻量且内容感知的上采样。该算法生成的核随输入火焰区域的形态特征而变化。对于飘动、扩散的火焰边缘区域, 它能产生更合适、非均匀的权重分布, 更好地捕捉火焰的特征。其实现过程如下:

输入尺寸 $H \times W \times C$ 的特征图 X , 首先通过采样点生成器, 为输出特征图 X' 上的每个目标位置 (i, j) 预测 K 个归一化偏移量 $(\Delta x_k, \Delta y_k)$ 。这些偏移量被约束在 $[-1, 1]$ 范围内, 表示相对于标准位

置的适应性调整。这些偏移与参考点叠加后, 形成目标位置敏感的动态采样点集 S 尺寸 $(sH \times sW \times 2g)$, 其中 $2g$ 为 x 轴与 y 轴的坐标。接下来, 通过 grid sample 函数, 根据点采样集 S , 对输入特征图 X 重新采样。输出最终上采样结果 X' 。该过程如图 3 所示。

$$X' = \text{grid.sample}(X, S), \quad (4)$$

式中: X 为输入特征图; S 为调整后的采样网格; X' 为输出特征图; grid.sample 为采样函数。




图 3 DySample 采样过程

Fig. 3 Process of DySample

采样集是对特征图进行内容感知采样的核心依据, 偏移量的计算是这一算法的核心操作。偏移量通过线性投影生成, 实现流程如下:

首先, 尺寸为 $H \times W \times C$ 的多通道张量经过两个并行的线性变换层, 输出两个尺寸为 $H \times W \times 2gs^2$ 的偏移量 O_1 和 O_2 , 将 O_1 输入 sigmoid 函数再与 0.5 静态范围因子进行点乘, 再与 O_2 通过像素重组, 将偏移量结合, 重塑成 $sH \times sW \times 2g$ 的偏移量 O , 最后, 通过结合偏移量 O 和原始数据 G 生成采样集 S 。动态点采样集生成过程如图 4 所示。




图 4 采样点生成器结构

Fig. 4 Structure of sampling point generator

$$O = 0.5 \text{sigmoid}(\text{linear}_1(X)) \cdot \text{linear}_2(X), \quad (5)$$

$$S = G + O, \quad (6)$$

式中: O 为偏移量, 用于调整采样网格位置; H 、 W 分别为特征图的高度与宽度; s 为缩放因子; G 为原始采样网格; linear 为线性变换层, 用于对输入特征进行变换操作; Pixel Shuffle 为像素重排操作。

与采用简单的将不同来源或层级的特征图在通道维度上直接拼接的方法不同, DySample 模块通过引入跨通道和空间维度的动态自适应采样与

加权融合机制,使模型在提升特征表达能力的同时保持了更高的推理效率与参数利用率。

2.3 Focal_EIoU 损失函数

在边界框回归任务中,YOLOv11n采用的CIoU损失函数虽然在常规目标检测任务中表现优异^[15],但因其仅考虑预测框与真实框间的几何关系,难以有效处理复杂场景下的火焰目标检测任务。一方面,火焰形态变化较大,常导致预测框与真实框无交集,使CIoU损失失效;另一方面,训练样本的难易不均衡导致模型难以学习到关键细节。

针对CIoU存在的问题,引入了Focal-EIoU损失函数^[16],其由Focal Loss和EIoU^[17]组成。Focal Loss通过对易分类样本进行降权,重新分配模型的学习重点,能够有效解决目标边界框回归过程中训练样本难易不平衡的问题。而EIoU在CIoU的基础上进行了改进,将中心点距离的惩罚拆解为在宽和高两个方向上的独立惩罚,对无交集情况的鲁棒性更强。相关数学表达为

$$L_{\text{EIoU}} = L_{\text{IoU}} + L_{\text{dis}} + L_{\text{asp}}, \quad (7)$$

$$L_{\text{EIoU}} = 1 - \text{IoU} + \frac{\rho^2(b, b^{\text{gt}})}{(\omega_c)^2 + (h_c)^2} + \frac{\rho^2(\omega, \omega^{\text{gt}})}{(\omega_c)^2} + \frac{\rho^2(h, h^{\text{gt}})}{(h_c)^2}, \quad (8)$$

式中: L_{IoU} 为IoU损失; L_{dis} 为距离损失; L_{asp} 为纵横比损失; ρ 为欧氏距离; b 和 b^{gt} 分别为预测框和真实框的中心点; ω_c 和 h_c 为覆盖两个框的最小包围框的宽度和高度。

Focal-EIoU定义为

$$L_{\text{Focal-EIoU}} = \text{IoU}^\gamma L_{\text{EIoU}}, \quad (9)$$

式中: γ 为控制异常值抑制程度的参数。

Focal-EIoU的完整表达式为

$$L_{\text{Focal-EIoU}} = \left(1 - \text{IoU} + \frac{\rho^2(b, b^{\text{gt}})}{(\omega_c)^2 + (h_c)^2} + \frac{\rho^2(\omega, \omega^{\text{gt}})}{(\omega_c)^2} + \frac{\rho^2(h, h^{\text{gt}})}{(h_c)^2} \right) \times \text{IoU}^\gamma. \quad (10)$$

令 $L = L_{\text{Focal-EIoU}}$, 对预测框参数 x 求导,

$$\frac{\partial L}{\partial x} = \gamma \cdot \text{IoU}^{\gamma-1} \cdot \frac{\partial \text{IoU}}{\partial x} \cdot L_{\text{EIoU}} + \text{IoU}^\gamma \cdot \frac{\partial L_{\text{EIoU}}}{\partial x}. \quad (11)$$

加法中的第一项为Focal调节项,第二项为EIoU梯度,可以发现,当 $\gamma > 0$ 时,对于高IoU样本(易样本), IoU^γ 较小,整体损失减小,对于低IoU样本(难样本), IoU^γ 较大,损失权重增加。通过这种方式可以使模型聚焦困难样本的学习,从

而提高模型识别精度。

3 实验设计与结果分析

3.1 实验环境设置

采用 Ubuntu 20.04 操作系统,搭载 Intel Xeon Gold 6330 CPU 与 NVIDIA RTX 3090 GPU 硬件平台。软件环境基于 Python 3.10 和 PyTorch 2.2.2 框架,并通过 CUDA 12.1 实现 GPU 加速。训练过程中的具体超参数配置详见表 1。

表 1 训练参数设置

Tab. 1 Training parameter settings

参数	值
输入图片大小/像素	640×640
初始学习率	0.01
Batch Size	16
Epoch	200
优化器	SGD
权重衰减	0.000 5

3.2 数据集

本文所使用的数据集旨在提取不同场景下火焰的典型特征。其来源主要包括两部分:一是液体火箭试车视频中截取出的包含火焰的图像帧;二是从公开来源收集的火焰图像。原始图像共计 1 000 张,涵盖了复杂背景、火焰形态变化、多尺度目标以及过曝状态等多种场景。

为提升模型泛化能力,避免过拟合问题,原始数据集经过数据增强处理,应用了包括随机组合、翻转、裁剪、平移和加噪等多种方法,数据集增至 3 000 张。在模型训练阶段,设定总训练轮次为 200,若连续 50 个训练轮次中模型在验证集上的性能指标未见改善,则训练将提前终止。

3.3 评价指标

为评估本文提出的模型对故障火焰的检测性能,采用的评估指标包括:精确率 P 、召回率 R 、均值平均精度 mAP 、参数量、浮点计算量以及帧率。部分公式为

$$P = \frac{TP}{(TP + FP)} \times 100\%, \quad (12)$$

$$R = \frac{TP}{(TP + FN)} \times 100\%, \quad (13)$$

式中: TP 为正确预测的正类样本数; FP 为误预测为正类的负类样本数; FN 为误预测为负类的正类

样本数; TN 为正确预测的负类样本数。

3.4 对比实验与实验结果分析

为了验证本文提出的 DDF-YOLO11n 模型的性能优势,在自建数据集上进行训练和测试,在各种

超参数一致的条件下将其与 Faster R-CNN、SSD、RT-DETR-r18、YOLOv5n、YOLOv8n、YOLOv9-tiny、YOLOv10n 和 YOLO11n 8 种主流的目标检测模型进行比较,实验结果如表 2 所示。

表 2 不同算法模型的性能对比

Tab. 2 Performance comparison of different algorithm models

模型	$P/\%$	$R/\%$	$mAP@0.5/\%$	参数量/M	计算量/GFLOPs	帧率/(帧 $\cdot s^{-1}$)
Faster R-CNN	75.6	74.3	82.7	65.3	240.1	32.5
SSD	79.4	73.1	78.2	27.8	96.2	43.6
RT-DETR-r18	82.8	84.4	89.5	25.9	53.4	68.5
YOLOv5n	79.8	78.1	87.3	2.6	6.8	105.6
YOLOv8n	80.7	83.4	89.8	3.0	8.2	142.5
YOLOv9-tiny	78.3	80.9	85.2	2.2	6.5	78.2
YOLOv10n	81.7	79.4	86.9	2.9	8.4	96.9
YOLOv11n	85.2	82.2	89.4	2.6	6.3	103.2
DDF-YOLO11n	87.3	88.6	91.8	3.2	8.3	95.3

与 YOLO 系列中的轻量级算法模型(包括 YOLOv5n、YOLOv8n、YOLOv9-tiny、YOLOv10n 及 YOLOv11n)相比,DDF-YOLO11n 在未显著增加模型参数量与计算负担的前提下,有效提升了检测性能。具体而言,其准确率较上述模型分别提高了 7.5、6.6、9.0、5.6 和 2.1 百分点;召回率分别提升 10.5、5.2、7.7、9.2 和 6.4 百分点; mAP 也相应增长 4.5、2.0、6.6、4.9 和 2.4 百分点。在上述评估维度均实现显著提升。在实验中,YOLO 系列模型帧率均大于 30 帧/s,能够很好地满足实时性要求。尽管 DDF-YOLOv11n 的参数量较 YOLOv11n 增加了 25%,计算效率略有下降,但其凭借 2.4 百分点的 mAP 提升有效弥补了其在轻量化方面的差距。同时,召回率的显著提升使得改进模型能够检测出更多被基准模型 YOLOv11n 漏检的火焰,从而展现出更优的综合性能。

进一步与当前先进的实时检测模型 RT-DETR 对比,RT-DETR 虽在平均识别精度上表现良好,但其较高的参数量与计算成本难以满足轻量化应用需求。与经典单阶段检测算法 SSD 相

比,DDF-YOLO11n 在各项指标上均具备明显优势;同时,相较于双阶段检测算法 Faster R-CNN,DDF-YOLO11n 同样保持性能领先。

3.5 消融实验

为了验证本文改进算法对火箭发动机异常火焰检测性能的影响,针对提出的改进策略,进行一系列消融实验,并分别记录每次实验相应的结果,如表 3 所示。从表 3 可以看出,提出的 C3k2_DCN 模块加强了模型对形变目标的识别能力。在此基础上使用 DySample 算子优化上采样模块,提升了模型针对小目标的识别能力。最后,使用 FocalLoss 与 EIou 相结合作为模型的损失函数,解决了难易样本不平衡的问题,更准确地衡量了预测框和真实框之间的相似性,从而提高了模型的检测精度,因此,模型整体性能得到了提高;相较于 YOLO11n,本文改进模型的 P 、 R 和 mAP 分别提高了 2.1、6.4 和 2.4 百分点,再次证明了 DDF-YOLO11n 模型在火箭发动机异常火焰检测方面的高效性。

表 3 消融实验结果

Tab. 3 Results of ablation experiment

Baseline	C3K2_DCN	Dysample	Focal_EIoU	$P/\%$	$R/\%$	$mAP@0.5/\%$
✓	—	—	—	85.2	82.2	89.4
✓	✓	—	—	83.0	86.1	90.6
✓	—	✓	—	80.2	81.7	91.2
✓	—	—	✓	83.1	81.2	90.5
✓	✓	✓	—	86.6	84.2	90.3
✓	✓	✓	✓	87.3	88.6	91.8

为探究 DCNv4 模块在 YOLOv11n 架构中的最优集成位置,设计了 4 组对比实验:1) 基准

YOLOv11n 模型;2) DCNv4 融入骨干网络;3) DCNv4 融入颈部网络;4) DCNv4 融入检测头。

各组实验结果对比如表4所示。

实验结果表明,将DCNv4模块单独集成至骨干网络深层时,在精度提升与参数效率间取得了最佳平衡。具体而言,该方案在仅增加约3.8%参数量的前提下,实现了1.2个百分点的 mAP 提升。相比之下,将DCNv4集成至颈部网络或检测头带来的性能增益有限(mAP 提升均不足0.3百分

点),却伴随着更多的参数量增长。分析认为,骨干网络深层负责提取强语义特征,对几何形变建模的需求最为迫切;而颈部网络的核心职责在于多尺度特征融合,其对空间不变性的要求高于几何形变适应能力。因此,综合权衡精度增益与模型复杂度,最终确认仅在骨干网络深层集成C3k2_DCN为最优方案。


表4 DCNv4不同集成位置的性能对比

Tab. 4 Comparison of DCNv4 at different integration positions

Baseline	$P/\%$	$R/\%$	$mAP@0.5/\%$	参数量/M	计算量/GFLOPs	帧率/(帧 $\cdot s^{-1}$)
YOLOv11n	85.2	82.2	89.4	2.60	6.3	103.2
+DCNv4 骨干网络	83.0	86.1	90.6	2.70	6.6	98.5
+DCNv4 颈部网络	84.5	85.5	89.6	2.78	6.8	95.2
+DCNv4 检测头	84.0	85.3	89.5	2.71	6.5	100.8

3.6 可视化分析

为直观对比改进模型与原模型的检测效果,本文选取测试集图片进行了可视化分析,结果如图5所示。图5(a)为原YOLOv11n模型检测结果,图5(b)为改进的YOLOv11n模型检测结果。从结果中可以看出两方面显著改进:一方面,本文方法对同一目标的检测置信度(0.9)远高于原模型(0.6),体现了识别精度的提升;另一方面,改进模型的检测框定位更为精准,进一步验证了其检测结果的可靠性。



(a) 原YOLOv11n模型

(b) 改进YOLOv11n模型

图5 改进算法识别结果对比

Fig. 5 Comparison of recognition results of improved algorithm

4 结论

本研究建立了液体火箭发动机火焰数据集,以YOLOv11n模型为基础,在骨干网络上引入可变形卷积模块,提升模型对不同形状火焰的识别能力。对于特征图上采样模块,引入DySample算子,增强小目标检出能力。最后,引入Focal-EIoU损失函数,提升定位精度,从而增强模型的检测能力。实验表明,与原模型相比,改进后的DDF-YOLO11n具有更高的检测精度,平衡了模型的计算速度和检测精度,能够满足实时检测的

需求,为实现液体火箭发动机异常火焰的快速检测提供了一种可行的算法方案。展望未来,为构建在极端工况下更具鲁棒性的感知系统,引入多模态信息融合是至关重要的演进方向。可通过融合可见光与红外热成像以综合利用形态与温度信息,分析异常火焰的特征,进行更加深入的分类研究,为实现下一代高可靠性的发动机健康监测与故障预警系统奠定坚实基础。

利益冲突声明/Conflict of Interests

所有作者声明不存在利益冲突。

All authors declare no relevant conflict of interests.

参考文献

- [1] 谭永华, 邓永锋, 胡海峰, 等. 基于数字技术的液体火箭发动机可靠性研究进展[J]. 火箭推进, 2025, 51(3): 19-26.
TAN Yonghua, DENG Yongfeng, HU Haifeng, et al. Research progress on reliability of liquid rocket engines based on digital technology [J]. Journal of Rocket Propulsion, 2025, 51(3): 19-26. (in Chinese)
- [2] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot MultiBox detector[M]. Computer Vision-ECCV 2016. Cham: Springer International Publishing, 2016: 21-37.
- [3] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 779-788.
- [4] ZHAO Y, LÜ W, XU S, et al. DETRs beat YOLOs on real-time object detection [C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recogni-

- tion (CVPR), 2024: 16965-16974.
- [5] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]//Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580-587.
- [6] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39 (6): 1137-1149.
- [7] 黄力, 吴珈承. 改进 Faster R-CNN 的输电线路山火图像检测方法 [J]. 现代电子技术, 2025, 48(9): 173-179.
- HUANG Li, WU Jiacheng. Improved faster R-CNN method for detecting wildfire images in transmission lines [J]. Modern Electronics Technique, 2025, 48(9): 173-179. (in Chinese)
- [8] 周欣, 徐培哲, 李堃, 等. 基于损失函数与注意力机制改进的 YOLOv8 火焰目标检测算法优化研究 [J]. 船海工程, 2025, 54(2): 19-25.
- ZHOU Xin, XU Peizhe, LI Kun, et al. Optimization of YOLOv8 flame target detection algorithm based on improved loss function and attention mechanism [J]. Ship & Ocean Engineering, 2025, 54(2): 19-25. (in Chinese)
- [9] 刘成明, 吴凡, 李学相. 基于改进 YOLOv7 的火灾火焰检测模型 [J]. 郑州大学学报(理学版), 2025, 57(5): 1-8.
- LIU Chengming, WU Fan, LI Xuexiang. A flame detection model based on improved YOLOv7 [J]. Journal of Zhengzhou University (Natural Science Edition), 2025, 57(5): 1-8. (in Chinese)
- [10] 马耀名, 张鹏飞, 谭福生. 面向复杂背景下烟雾火焰检测的改进 YOLOv8s 算法 [J]. 计算机工程与应用, 2025, 61(3): 121-130.
- MA Yaoming, ZHANG Pengfei, TAN Fusheng. Improved YOLOv8s model for smoke and flame detection in complex backgrounds [J]. Computer Engineering and Applications, 2025, 61 (3): 121-130. (in Chinese)
- [11] 卞苏阳, 严云洋, 龚成张, 等. 基于 CXANet-YOLO 的火焰检测方法 [J]. 南京大学学报(自然科学), 2023, 59(2): 295-301.
- BIAN Suyang, YAN Yunyang, GONG Chengzhang, et al. Flame detection method based on CXANet-YOLO [J]. Journal of Nanjing University (Natural Sciences), 2023, 59(2): 295-301. (in Chinese)
- [12] XIONG Y, LI Z, CHEN Y, et al. Efficient deformable ConvNets: rethinking dynamic and sparse operator for vision applications [C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2024: 5652-5661.
- [13] LIU W, LU H, FU H, et al. Learning to upsample by learning to sample [C]//2023 IEEE/CVF International Conference on Computer Vision (ICCV), 2023: 6004-6014.
- [14] KHANAM R, HUSSAIN M. Yolov11: an overview of the key architectural enhancements [EB/OL]. (2024-10-23) [2025-06-15]. <https://doi.org/10.48550/arXiv.2410.17725>.
- [15] ZHENG Z, WANG P, REN D, et al. Enhancing geometric factors in model learning and inference for object detection and instance segmentation [J]. IEEE Transactions on Cybernetics, 2022, 52(8): 8574-8586.
- [16] ZHANG Y F, REN W, ZHANG Z, et al. Focal and efficient IOU loss for accurate bounding box regression [J]. Neurocomputing, 2022, 506: 146-157.
- [17] TIAN Y, SU D, LAURIA S, et al. Recent advances on loss functions in deep learning for computer vision [J]. Neurocomputing, 2022, 497: 129-158.