

中文引用格式:马庆禄,邱高建,白锋. 基于改进YOLOX的隧道火灾检测算法[J]. 中国安全科学学报, 2025, 35(4):28-34.

英文引用格式:MA Qinglu, QIU Gaojian, BAI Feng. Tunnel initial fire detection method based on improved YOLOX algorithm[J]. China Safety Science Journal, 2025, 35(4):28-34.

基于改进YOLOX的隧道火灾检测算法*

马庆禄 教授, 邱高建, 白锋

(重庆交通大学 交通运输学院, 重庆 400074)

中图分类号: X932

文献标志码: A

DOI: 10.16265/j.cnki.issn1003-3033.2025.04.0960

基金项目: 重庆市自然科学基金面上项目资助(CSTB2023NSCQ-MSX0551); 交通部三峡库区奉建高速公路安全智能建造科技示范工程项目(Z29210003); 2024年研究生科研创新项目(2024S0078); 2024年研究生科研创新项目(CYS240483)。

【摘要】 针对隧道初期火灾检测中存在的复杂环境干扰和低识别率问题, 提出一种基于改进YOLOX算法的检测方法YOLOX-T。该方法在YOLOX中引入归一化注意力模块(NAM)机制来抑制环境噪声和干扰, 提高系统的鲁棒性及识别的精确性; 引入加权双向特征金字塔网络(BiFPN)增强特征提取和融合能力, 优化 α -交并比(IoU)损失函数, 以提高对轮廓特征不明显的隧道初期烟雾火焰的检测精度; 在现有公开数据集不足的情况下, 通过网络采集、模拟试验和扩充现有数据集, 构建隧道火灾数据集, 在包含真实场景和模拟场景的自建隧道火灾数据集上进行验证。结果表明: 相比于原始YOLOX模型, 改进后的算法均值平均精度(mAP@0.5)提高1.89%, mAP@0.5~0.95提高0.88%, 精确率提高4.57%, 召回率提高5.45%, 改进后的算法能够实现更优的检测性能。

【关键词】 隧道火灾; YOLOX; 火灾检测; 归一化注意力模块(NAM); 加权双向特征金字塔网络(BiFPN)

Tunnel initial fire detection method based on improved YOLOX algorithm

MA Qinglu, QIU Gaojian, BAI Feng

(School of Traffic & Transportation, Chongqing Jiaotong University, Chongqing 400074, China)

Abstract: To address the issues of complex environmental interference and low recognition rates in early-stage tunnel fire detection, an improved YOLOX-based detection method, YOLOX-T, was proposed. The proposed method incorporated a NAM into the YOLOX network to suppress environmental noise and interference, thereby enhancing the model's robustness. A weighted BiFPN was integrated to improve multi-scale feature extraction and fusion. Furthermore, an α -IoU (Intersection over Union) loss function was employed to enhance the detection accuracy of early-stage tunnel smoke and flames, which often exhibit indistinct contours. Addressing the scarcity of publicly available datasets, a tunnel fire dataset encompassing both real-world and simulated scenarios was constructed through web data acquisition, simulated fire experiments, and the augmentation of existing datasets. Experimental results on the self-built dataset demonstrate that, compared to the original YOLOX model, the YOLOX-T method achieves improvements of 1.89% in mean Average Precision (mAP@0.5), 0.88% in mAP@0.5~0.95, 4.57% in precision, and 5.45% in recall. The improved algorithm can achieve better detection performance.

Keywords: tunnel fire; YOLOX; normalization-based attention module (NAM); bidirectional feature pyramid network (BiFPN); fire detection

0 引言

截至 2023 年底,我国(不含港澳台地区)公路隧道总里程长达 3 023.18 万延米^[1]。隧道火灾一般涉及汽油、电缆等高热值可燃物,且受狭长密闭空间制约,烟气扩散与燃烧动力学特性显著区别于常规建筑火灾,易引发重大伤亡与结构损伤^[2]。

现有的火灾预警系统多依赖温感、烟感等传感器^[3],基础预警效能易受制于环境干扰,且检测有滞后性,难以实现早期火灾的精准识别。基于数字图像处理的传统计算机视觉识别方法,由于特征选择的不确定性^[4],检测效率低。如 ÇELIK 等^[5]设计一种有效分离亮度和色度分量的新规则,实现了基于像素特征的火灾图像分类。MONDAL 等^[6]通过图像预处理和块标记,实现对火灾的快速响应。TORABIAN 等^[7]通过算法从视频序列中提取时空特征,转化为分形特征描述火灾运动特性,利用支持向量机分类器对这些特征分类,确定火灾区域。随着计算能力的显著提升,近年来深度学习技术在火灾探测领域得到广泛应用。马庆禄等^[8]提出一种基于改进 YOLOv5s 算法的隧道初期火灾检测方法。胡勤等^[9]提出一种基于动态纹理的火焰检测方法。李宁等^[10]通过改进 YOLO 层,增大感受野范围,提高火焰检测能力。李澎林等^[11]先通过光流算法对目标区域进行筛选,再通过 YOLOv3 对检测区域进行二次识别,减少外界因素干扰。王冠博等^[12]优化激活函数,再引入通道注意力机制,提高 YOLOv4 模型检测火焰的精度。曹康壮等^[13]通过将 YOLOv5 与轻量化卷积神经网络结合,优化损失函数及引入置换注意力机制,提高在复杂环境下火灾检测的识别效果。尚明鹏等^[14]通过融合加权双向特征金字塔网络(Bidirectional Feature Pyramid Network, BiFPN),提升复杂环境下的火灾检测水平。张军等^[15]将特征融合注意力模块引入至主干网络中提升烟雾特征提取。隧道环境的特殊性使传统检测算法在精度和鲁棒性上存在不足。尽管现有深度学习算法在火灾检测中取得一定成果,但隧道复杂环境下,难以有效抑制噪声和干扰,导致误报率较高。

因此,笔者拟提出基于改进 YOLOX^[16]的隧道火灾智能检测算法,在原 YOLOX 模型基础上引入归一化注意力模块(Normalization-based Attention Module, NAM),并引入 BiFPN^[17],重点解决复杂隧道环境下烟雾识别率低、干扰敏感度高为关键问题,以期实现隧道复杂环境下隧道火灾自动检测。

1 基于目标检测的隧道火灾检测 YOLOX-T 算法

1.1 YOLOX 目标检测算法

YOLOX 心创新包括解耦头、数据增强、无锚框思想以及动态样本匹配。YOLOX 由主干特征提取网络、颈部特征增强网络和预测检测头组成,如图 1 所示。主干特征提取网络采用跨阶段局部网络,提升效率与准确性;颈部通过多尺度特征融合增强对不同尺度目标的检测能力;预测部分使用解耦头进行回归与分类预测,精确定位目标并进行类别判定。YOLOX 结构中卷积-归一化-激活(Convolution-Batch Normalization-SiLU Activation, CBS)模块负责基本的特征提取,跨阶段局部网络(Cross Stage Partial Network, CSP)模块增强网络的特征提取能力,同时降低计算量。

1) 解耦头。目标检测在深度学习中至关重要,涵盖分类和回归 2 个主要方面。传统 YOLO 系列算法采用耦合的检测头,将分类和回归任务封装在单个分支中,导致二者冲突,影响网络的收敛性。为此,YOLOX 引入视网膜网络的解耦检测头,将分类和回归任务分为 2 个并行任务,并独立更新各自的参数,解耦头结构如图 2 所示。这种解耦设计提高网络的性能和收敛速度,通过分开处理分类和回归任务,网络能更有效地学习目标的语义信息和空间位置信息,从而提高目标检测的准确性和鲁棒性。

2) 动态样本匹配。YOLOX 采用基于最优传输分配的动态正负样本分配策略。在确定正样本候选区域时,以特征图不同尺度的网格中心点为圆心,选择该区域内的真实框(Ground Truth, GT)。特征图的尺度包括 20×20、40×40 和 80×80 等。在使用较小尺度特征图时,可能导致正样本匹配不准确。随着特征图尺度的增大,GT 更容易与较小的 GT 匹配,但较小尺度特征图能够匹配的 GT 数量较少。最优传输分配策略通过减少锚框数量,降低模型参数和计算复杂度,同时提升检测速度。

1.2 嵌入 NAM 机制

隧道摄像头图像中,初期火灾通常光亮度较弱且伴有稀薄烟雾,受隧道灯光等干扰,影响特征提取。引入 NAM,置于骨干网络后,关注小尺度目标特征,抑制噪声和干扰,增强鲁棒性与识别精度。NAM 通过加权处理特征图,突出火焰和烟雾等显著特征,抑制背景干扰,提升目标识别精度和模型性

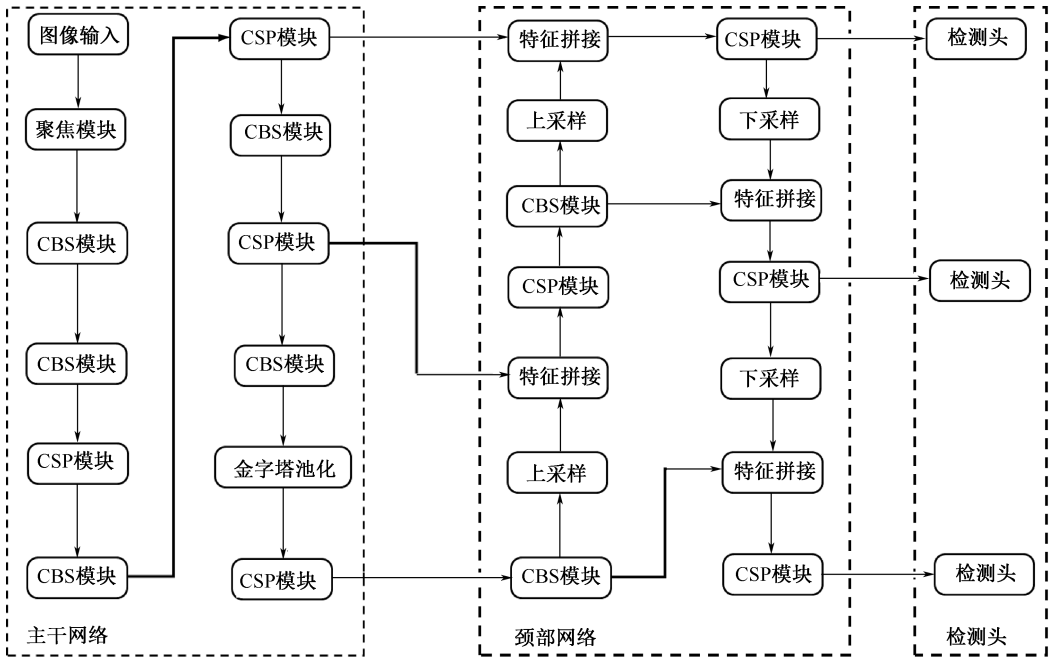


图1 YOLOX 结构

Fig. 1 YOLOX structure

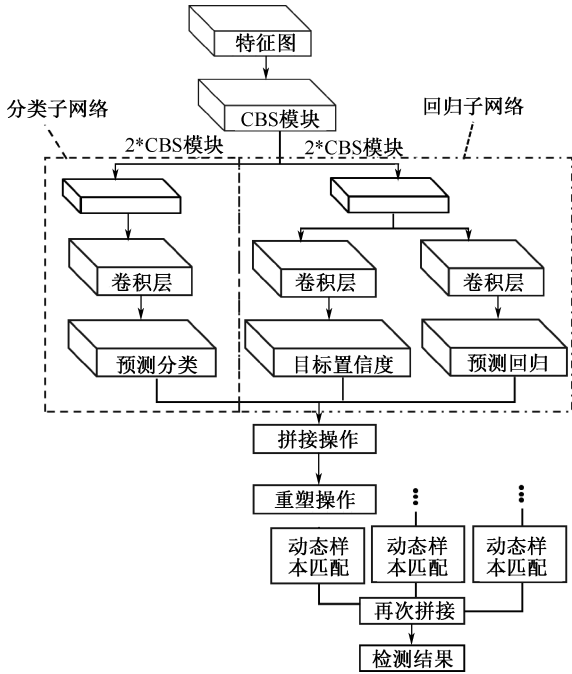


图2 YOLOX 的解耦头

Fig. 2 Decoupling head of YOLOX

能。通过权重稀疏惩罚机制, NAM 降低不显著特征的权重, 突出显著特征。图 3 为 NAM 机制示意, 该机制通过重构通道注意力和空间注意力子模块来增强特征表达能力。

通道注意力模块使用批量归一化 (Batch Normalization, BN) 函数的缩放因子来衡量每个通道特征的权重, 缩放因子越大, 通道的权重越大。BN

函数的输出特征 B_o 为:

$$B_o = \text{BN}(B_i) = \gamma_{\text{BN}} \frac{B_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} + \beta \quad (1)$$

式中: B_i 为输入特征; γ_{BN} 为可训练的缩放因子; μ_B 为批量 B 的均值; σ_B^2 为 B 的方差; ϵ 为无穷小量; β 为可训练的平移参数。

通道注意力模块的输出特征 M_c 为:

$$\begin{cases} M_c = \text{Sigmoid} \{ W_i [\text{BN}(T_1)] \} \\ W_i = \frac{\gamma_i}{\sum_{j=0} \gamma_j} \end{cases} \quad (2)$$

式中: W_i 为通道 i 的权重; T_1 为输入特征图; γ_i 为通道 i 的缩放因子。

空间注意力模块的输出特征 M_s 为:

$$\begin{cases} M_s = \text{sigmoid} \{ Q_i [\text{BN}(T_2)] \} \\ Q_i = \frac{\lambda_i}{\sum_{j=0} \lambda_j} \end{cases} \quad (3)$$

式中: Q_i 为空间 i 的权重; λ_i 为空间 i 的缩放因子。

1.3 引入 BiFPN

隧道初期火灾检测对检测算法的实时性和准确性要求高。原 YOLOX 网络结构在处理不同尺寸特征图时, 采用简单相加的融合方式, 在目标检测任务中精度受到一定限制。为保证实时性的前提下进一步提升对隧道初期火灾的检测精度, 对网络结构进

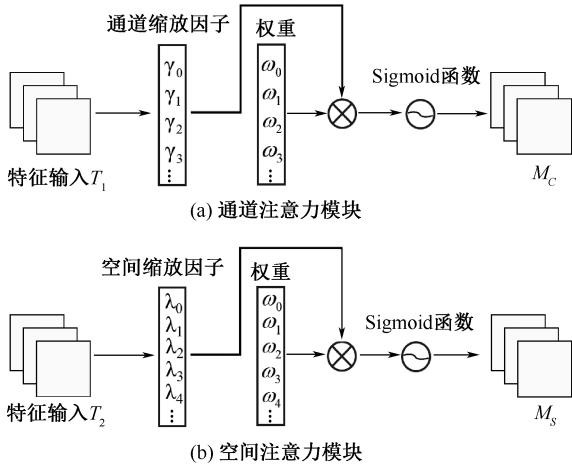


图 3 NAM 模块
Fig. 3 NAM module

行优化。图 4 为 2 种网络结构的对比, YOLOX 原颈部结构为特征金字塔网络 (Feature Pyramid Network, FPN), 采用简单的特征加法融合, 而 BiFPN 过加权双向特征融合的方式和减少冗余连接, 网络结构更加简洁, 在提升特征融合效果的同时, 兼顾模型的效率。

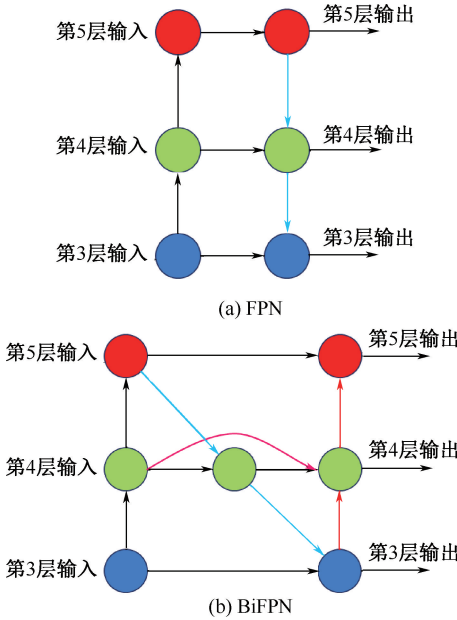


图 4 FPN 和 BiFPN 的结构对比
Fig. 4 Comparison of FPN and BiFPN structures

BiFPN 加权融合机制是将所有特征值的总和直接除以权重, 经过融合的输出特征 O 为:

$$O = \sum_i \frac{\eta_i}{\nu \sum_j \eta_j} * I_i \quad (4)$$

式中: η_i 为第 i 层输入特征可学习的权重; ν 为近似于 0 的最小值, 防止分母为 0; $I_i (i = 1, 2, \dots, 5)$ 为

第 i 层输入特征。

BiFPN 的第 i 层的特征融合表达式为:

$$P_i^o = \text{conv} \left[\frac{w'_1 \cdot P_i^i + w'_2 \cdot P_i^{\text{ld}} + w'_3 \cdot R(P_{i-1}^i)}{w'_1 + w'_2 + w'_3 + \nu} \right] \quad (5)$$

式中: P_i^o 为第 i 层的输出特征; P_i^i 为自底向上的 BiFPN 路径上第 i 层的输入特征; P_i^{ld} 为同一层中间层的特征; R 为下采样或上采样操作; 权重 $w'_m (m = 1, 2, 3)$ 为权重参数。

YOLOX 引入 BiFPN 优化网络, 通过移除仅有一条输入边的特征图以减少冗余信息、提升计算效率, 将被移除的单输入边特征图连接至下一层, 以实现跨尺度特征融合, 并在同一层网络中增加额外的输入边, 以增强网络的信息流动性和多样性, 从而提升特征表达能力, 改进后网络结构如图 5 所示。




图 5 改进后网络结构
Fig. 5 Improved network structure

1.4 损失函数优化

传统的单阶段和 2 阶段检测器采用边界框回归技术使用 L_{n-n} 损失函数进行目标检测。近年, 交并比 (Intersection over Union, IoU) 损失函数逐渐取代 L_{n-n} 。IoU 为:

$$\text{IoU} = \frac{A \cap B}{A \cup B} \quad (6)$$

式中 A, B 分别为真实边界框和预测边界框的区域。

L_{IoU} 损失函数定义为:

$$L_{\text{IoU}} = 1 - \text{IoU} \quad (7)$$

当 2 个边界框完全重叠时, IoU 为 1。为避免 IoU 预测框未能与真实框精确重合对检测结果准确性的影响, 训练过程采用基于参数 α 损失函数 $L_{\alpha-\text{IoU}}$ [18]:

$$L_{\alpha-\text{IoU}} = (1 - \text{IoU}^\alpha) / \alpha, \alpha > 0 \quad (8)$$

式中: α 为调节因子, 只能取正值。当 $\alpha = 1$ 时, $L_{\alpha-\text{IoU}}$ 为 L_{IoU} ; 当 $\alpha \rightarrow 0$ 时, $L_{\alpha-\text{IoU}}$:

$$L_{\alpha-\text{IoU}} = -\log(\text{IoU}) \quad (9)$$

当 $\alpha \geq 1$ 时, $L_{\alpha-\text{IoU}}$:

$$L_{\alpha-\text{IoU}} = 1 - \text{IoU}^{\alpha_1} + F^{\alpha_2}(K, K^{\text{st}}) \quad (10)$$

式中: α_1 为变化敏感度, $\alpha_1 > 0$; α_2 为惩罚程度, $\alpha_2 > 0$, F^{α_2} 为预测框 K 和真实框 K^{gt} 的惩罚项。

利用式(10)对基于 IoU 的损失进行转换。然后通过使用 L_{CloU} 转换为 $L_{\alpha\text{-CloU}}$, 使用 α 和惩罚参数 $F^{\alpha}(K, K^{\text{gt}})$ 计算预测和真实边界框:

$$\begin{cases} L_{\alpha\text{-CloU}} = 1 - \text{IoU}^{\alpha} + \frac{\rho^{2\alpha}(b, b^{\text{gt}})}{c^{2\alpha}} + (\tau v)^{\alpha} \\ v = \frac{4}{\pi^2} \left(\arctan \frac{\omega^{\text{gt}}}{h^{\text{gt}}} - \arctan \frac{\omega}{h} \right)^2 \\ \tau = \frac{v}{(1 - \text{IoU}) + v} \end{cases} \quad (11)$$

式中: ρ 为欧氏距离; b, b^{gt} 分别为预测框 K 和真实框 K^{gt} 的中心点; c 为最小框的对角线长度; $\omega^{\text{gt}}/h^{\text{gt}}$ 和 ω/h 分别为真实框和预测框的长宽比。

2 基于改进 YOLOX 的隧道火灾检测算法

2.1 隧道火灾数据集

由于缺乏公开且标注完善的公路隧道火灾数据集,通过网络采集、模拟地下人行通道火灾试验以及扩充现有公开数据集的方式,构建一个包含火焰和烟雾 2 类样本的公路隧道火灾数据集。通过亮度调整、高斯模糊等方式增加样本多样性,增强模型对不同条件的适应性,如图 6 所示。每张图片随机应用 1 到 2 种增强方法,最终构建包含 20 000 张图像的公路隧道火灾数据集。为满足隧道特殊场景的需求,并将测试集划分为 2 类,即模拟隧道火灾数据集 I 和真实隧道火灾数据集 II。

2.2 运行环境

基于 Windows11 专业版操作系统的工作站验证算法,硬件配置包括高性能图形处理和 6 核 12 线程处理器、32GB 内存以及高速存储系统,软件环境为 Python 3.6。为降低 200 个训练周期内过拟合的风险,训练过程采用学习率预热策略。初始学习率逐渐升至 0.000 15,并采用余弦退火算法进行动态调整。批处理大小设置为 8,预热训练迭代次数为 5。

2.3 算法评价指标

模型评价指标精确率 P 、召回率 R 、平均精度均值(mean Average Precision, mAP)。平均精度 P_A 是以 R 为横轴, P 为纵轴构成的曲线下的面积;mAP 是对所有类别的 P_A 求平均值;其中 P 和 R 可表示为:

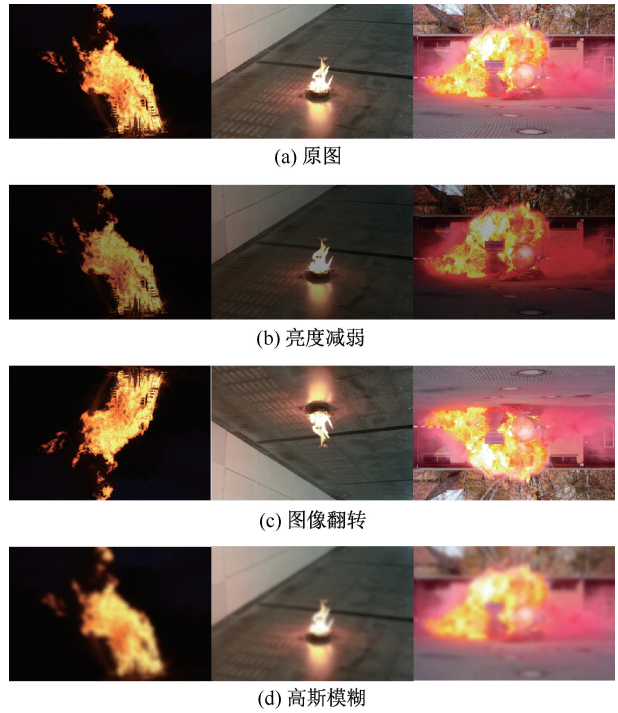


图 6 数据集图像增强

Fig. 6 Image enhancement of dataset

$$P = T_p/T_p + F_p \quad (12)$$

$$R = T_p/T_p + F_N \quad (13)$$

式中: T_p 为预测和标签都为正的样本数量; F_p 为预测为正,但标签为负的样本数量; F_N 为预测为负,但标签为正的样本数量。

2.4 消融结果与分析

为系统地评估嵌入 NAM 机制、BiFPN 及损失函数对 YOLOX 网络火灾目标检测性能的影响,构建包含真实火灾场景的自制公路隧道火灾数据集,并基于该数据集开展各个模块的消融分析,结果见表 1。

从表 1 可知:对比原始网络和单独添加改进模块的网络,添加所有改进策略的 YOLOX 网络在 mAP@0.5、mAP@0.5~0.95、 P 和 R 相比 YOLOX 模型分别提升 1.89%、0.88%、4.57%、5.45%。YOLOX 在添加 NAM 模块后,mAP@0.5、mAP@0.5~0.95、 P 和 R 分别提升 0.50%、0.23%、1.04% 和 1.24%,表明 NAM 能有效抑制背景噪声干扰。BiFPN 模块的引入相较于原模型,精确率提升 3.15%,说明 BiFPN 特征融合路径有效增强检测能力。综上,改进后 YOLOX 网络对于提高对隧道环境复杂背景条件下初期火灾的检测精度有积极作用,验证 YOLOX 改进模型在模拟数据集和真实火灾数据集中对烟火的检测效果,部分检测结果如图 7 所示。

表 1 消融分析结果对比
Table 1 Comparison of ablation analysis results

模型	改进策略						
	NAM	BiFPN	α -IoU	mAP@ 0.5	mAP@ 0.5~0.95	P	R
YOLOX	—	—	—	82.89	70.23	93.37	82.34
A	✓	—	—	83.39	70.46	94.41	83.58
B	✓	✓	—	82.98	70.61	96.52	83.77
YOLOX-T	✓	✓	✓	84.78	71.11	97.94	87.79

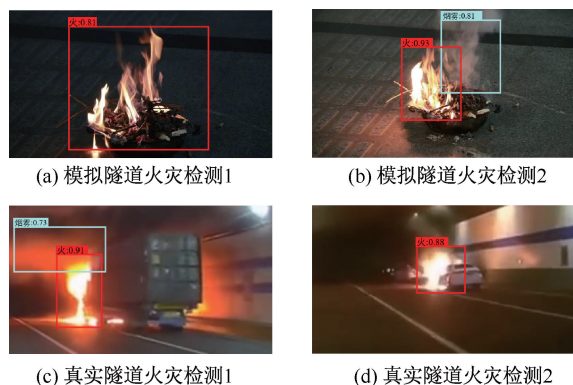


图 7 烟火检测的验证结果

Fig. 7 Verification results of smoke and flame detection

由图 7 可知:改进后的模型在模拟数据集上可实现火焰与烟雾的完整检测;针对真实场景中的低光照环境,仍能保持烟火检测精度;在复杂光照条件下有效抑制光源干扰引起的烟雾误检现象,这证明了算法的优越性。

2.5 算法对比分析

从测试集中选取若干图像,对比分析改进 YOLOX 网络模型与原 YOLOX 模型在目标检测能力上的差异,结果如图 8 所示。

图 8 中,每组图像的左侧为原 YOLOX 模型的检测结果,右侧为改进后的 YOLOX 模型的检测结果。对比可见:改进后的 YOLOX 模型显著提升检测精度,尤其在纯火焰、纯烟雾及隧道场景中表现突出,对复杂背景下的烟火检测能力显著增强。

对比分析快速区域卷积网络 (Fast Region-Convolutional Neural Network, Faster R-CNN)、RetinaNet、YOLOv5s、单步多框检测器 (Single Shot MultiBox Detector, SSD)、YOLOv3 和 YOLOv4 等具有代表性的目标检测算法与原 YOLOX 模型及本文提出的 YOLOX-T 模型,所有检测算法输入图像尺寸均统一为 640×640 像素,对比指标为 mAP@ 0.5 和 P,结果见表 2。可以看出,原始 YOLOX 模型在火焰烟雾检测任务中 mAP@ 0.5 和精确率指标更高,已

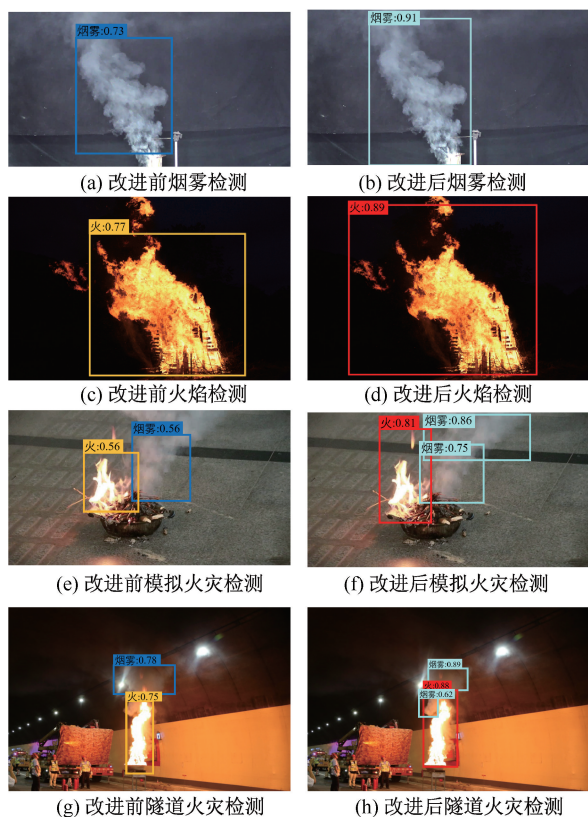


图 8 检测结果对比

Fig. 8 Comparison of test results

展现出优越性能。而 YOLOX-T 模型较原始 YOLOX 模型, mAP@ 0.5 提升 2.23%, 精确率提升 4.57%, 性能提升幅度明显。

表 2 不同模型结果对比

Table 2 Comparison results of tests on different models

检测算法	mAP@ 0.5	P/%
Faster R-CNN	75.51	85.66
RetinaNet	75.32	83.54
SSD	71.46	78.69
YOLOv3	72.44	80.17
YOLOv4	73.66	81.67
YOLOv5S	75.43	85.33
YOLOX	82.89	93.37
YOLOX-T	84.78	97.94

3 结论

1) YOLOX-T 算法采用 BiFPN 结构进行多尺度特征融合。相比于传统的特征金字塔网络, BiFPN 的双向跨尺度连接和加权特征融合方式可显著提升

模型对不同大小火灾目标的检测能力。

2) YOLOX-T 的 mAP@0.5 和 mAP@0.5~0.95 分别提高 1.89% 和 0.88%, 精确率提高 4.57%, 这表明该算法能更准确地识别隧道初期火灾。

参考文献

- [1] 交通运输部. 2023 年交通运输行业发展统计公报[R/OL]. (2024-06-18). https://www.gov.cn/lianbo/bumen/202406/content_6957901.htm.
- [2] 何潇剑. 公路隧道消防灭火系统优化设计研究[J]. 隧道建设, 2017, 37(4): 505-509.
HE Xiaojian. Study of optimization design of firefighting system of highway tunnel[J]. Tunnel Construction, 2017, 37(4): 505-509.
- [3] 张思祥, 甘凯, 周围. 提高火灾烟雾传感器检测精度的方法[J]. 传感器与微系统, 2021, 40(1): 151-153.
ZHANG Sixiang, GAN Kai, ZHOU Wei. Method for detection precision improving of fire smog sensor[J]. Transducer and Microsystem Technologies, 2021, 40(1): 151-153.
- [4] 李先锋, 徐森, 花义明. 基于 OpenCV 计算机视觉的海事视频船舶火灾烟雾检测技术[J]. 舰船科学技术, 2021, 43(22): 202-204.
LI Xianfeng, XU Sen, HUA Yiming. Maritime video ship fire smoke detection technology based on OpenCV computer vision[J]. Ship Science and Technology, 2021, 43(22): 202-204.
- [5] ÇELİK T, DEMİREL H. Fire detection in video sequences using a generic color model[J]. Fire Safety Journal, 2009, 44(2): 147-158.
- [6] MONDAL M S, PRASAD V, KUMAR R, et al. Automating fire detection and suppression with computer vision: a multi-layered filtering approach to enhanced fire safety and rapid response[J]. Fire Technology, 2023, 59(4): 1555-1583.
- [7] TORABIAN M, POURGHASSEM H, MAHDAVI-NASAB H. Fire detection based on fractal analysis and spatio-temporal features[J]. Fire Technology, 2021, 57(5): 2583-2614.
- [8] 马庆禄, 孙泉, 唐小垚, 等. 基于改进 YOLOv5s 算法的隧道初期火灾检测模型[J]. 中国安全科学报, 2023, 33(10): 214-223.
MA Qinglu, SUN Xiao, TANG Xiaoyao, et al. Optimization method for tunnel initial fire detection based on YOLOv5s algorithm[J]. China Safety Science Journal, 2023, 33(10): 214-223.
- [9] 胡勤, 陈琛, 刘敏. 一种基于动态纹理的烟雾和火焰检测方法[J]. 消防科学与技术, 2014, 33(6): 667-669.
HU Qin, CHEN Chen, LIU Min. A smoke and fire detection method based on dynamic texture[J]. Fire Science and Technology, 2014, 33(6): 667-669.
- [10] 李宁, 刘青, 熊俊, 等. 基于无人机的火灾检测系统设计与实现[J]. 火灾科学, 2022, 31(1): 46-51.
LI Ning, LIU Qing, XIONG Jun, et al. Design and implementation of fire detection system based on UAV[J]. Fire Safety Science, 2022, 31(1): 46-51.
- [11] 李澎林, 章军伟, 李伟. 基于光流改进与 YOLOv3 的烟雾检测方法[J]. 浙江工业大学学报, 2021, 49(1): 9-15.
LI Penglin, ZHANG Junwei, LI Wei. Smoke detection method based on optical flow improvement and YOLOv3[J]. Journal of Zhejiang University of Technology, 2021, 49(1): 9-15.
- [12] 王冠博, 杨俊东, 李波, 等. 改进 YOLOv4 的火焰图像实时检测[J]. 计算机工程与设计, 2022, 43(5): 1358-1365.
WANG Guanbo, YANG Jundong, LI Bo, et al. Real-time flame image detection using improved YOLOv4[J]. Computer Engineering and Design, 2022, 43(5): 1358-1365.
- [13] 曹康壮, 焦双健. 融合注意力机制的轻量级火灾检测模型[J]. 消防科学与技术, 2024, 43(3): 378-383.
CAO Kangzhuang, JIAO Shuangjian. A lightweight fire detection model integrating attention mechanism[J]. Fire Science and Technology, 2024, 43(3): 378-383.
- [14] 尚明鹏, 周敏, 陈燕军, 等. 融合 BiFPN 与 YOLOv5 网络的工厂火灾检测[J]. 智能计算机与应用, 2023, 13(10): 137-141, 146.
SHANG Mingpeng, ZHOU Min, CHEN Yanjun, et al. Factory fire detection with BiFPN and YOLOv5[J]. Intelligent Computer and Applications, 2023, 13(10): 137-141, 146.
- [15] 张军, 尹柳, 巩欣飞, 徐赫桦. 基于改进 YOLOv5 的小目标烟雾检测算法[J]. 中国安全科学学报, 2023, 33(11): 75-81.
ZHANG Jun, YIN Liu, GONG Xinfei, XU Hehua. Small target smoke detection algorithm based on improved YOLOv5[J]. China Safety Science Journal, 2023, 33(11): 75-81.
- [16] GE Zheng, LIU Songtao, WANG Feng, et al. YOLOX: exceeding YOLO series in 2021[EB/OL]. [2024-07-05]. <https://arxiv.org/abs/2107.08430v2>.
- [17] TAN Mingxing, QUOC L. Efficientnet: rethinking model scaling for convolutional neural networks[C]. International Conference on Machine Learning. PMLR, 2019: 6105-6114.
- [18] HE Jiabo, ERFANI S, MA Xingjun, et al. α -IoU: a family of power intersection over union losses for bounding box regression[EB/OL]. [2024-07-05]. <https://arxiv.org/abs/2110.13675>.

作者简介: 马庆禄 (1980—), 男, 陕西渭南人, 博士, 教授, 主要从事自动驾驶、智能交通、交通安全等方面的研究。E-mail: qm@cqjtu.edu.cn。

