

基于改进 YOLOv8 的隧道火灾检测研究

闵浩, 屈八一, 谢子豪

(长安大学 信息工程学院, 西安 710064)

摘要: 隧道内火灾检测存在检测困难和难以直接部署到资源有限的嵌入式设备进行实时检测的问题, 提出一种基于改进 YOLOv8 的隧道火灾检测算法; 首先引入极化注意力保持高分辨率信息来抑制冗余特征, 同时增强全局信息的捕捉; 其次引入了一种新的局部卷积 PConv 来实现低延迟和高吞吐量的模型; 最后使用 WIoU 函数优化网络的边界框损失, 使网络能够快速收敛。实验结果表明, 该网络在所使用隧道火灾数据集上的平均精度 mAP 提升了 1.3%, 同时轻量化后模型参数减少了 29.7 个百分点, 向前推理时间降低了 44%; 算法能够平衡精度和轻量化的需求, 可以满足隧道场景下的实时检测。

关键词: YOLOv8; 局部卷积; WIoU; 极化注意力; 轻量化

Research on Tunnel Fire Detection Based on Improved YOLOv8

MIN Hao, QU Bayi, XIE Zihao

(School of Information Engineering, Chang'an University, Xi'an 710064, China)

Abstract: There are the difficulties of detecting fires inside tunnels and directly deploying to the embedded devices with limited resources for real-time detection, a tunnel fire detection algorithm based on improved YOLOv8 is proposed. Firstly, the polarized attention mechanism is introduced to preserve high-resolution information and suppress redundant features, while enhancing the capture of global information. Secondly, the novel partial Convolution (PConv) is introduced to achieve the model with low latency and high throughput. Finally, the WIoU function is used to optimize the loss of network bounding box, enabling the fast convergence of the network. Experimental results demonstrate that on the utilized tunnel fire dataset, the mean average precision (mPA) of the proposed network improves by 1.3%. Furthermore, the model parameters of the lightweight model reduces by 29.7%, and the forward inference time by 44%. The algorithm meets the requirements of accuracy and lightweight, making it suitable for real-time detection in tunnel scenarios.

Keywords: YOLOv8; partial convolution; WIoU; polarized attention; lightweight

0 引言

近几十年经济的快速发展, 我国在基础道路设施方面投入了大量的资源, 进入 21 世纪以来, 国内的隧道数量和里程不断增加。由于国内大部分地区地势复杂, 多采用长隧道和特长隧道来解决这个问题, 但是隧道由于空间细长狭小、密闭性强和救援困难等特点, 一旦发生火灾就会产生严重后果。对社会公共财产和人身安全造成巨大的损失。在火灾发生的初期阶段火焰的燃烧面积较小, 所以火势发展比较缓慢, 如果在早期阶段就能消灭火灾, 就可以避免重大灾难性事故的发生。因此提高隧道火灾检测的准确性和实时性, 能够联合消防在火灾初期阶段迅速熄灭火灾, 消除火灾隐患, 是隧道运营及安保部门需要重点解决的问题。

近些年关于隧道火灾检测的研究大多是基于视频图像的火灾检测算法, 主要有基于传统分类器的火灾检测和基于深度学习的火灾检测。前者首先通过 SIFT^[1] 和 HOG^[2] 等特征提取方法来提取火焰和烟雾的亮度、颜色、纹理和边缘等特征, 将其特征向量传入分类器训练, 最后采用

SVM、贝叶斯网络和 BP 神经网络等分类器判断图像中是否含有火焰和烟雾, 如文献 [3], 这种算法的主要问题是大多采用一些手工制定的算法来提取图像的低级特征, 之后再对结果进行优化, 所以有较大的时间消耗, 导致火灾和烟雾探测的性能低下且实时性变慢。并且由于遮挡干扰等原因还在背景检测中产生了许多误报和错误。所以上述方法并不能在隧道火灾初期有效及时发现并发出警报。

而基于深度学习的火灾检测算法可以提取更加抽象、更高级的火焰烟雾特征, 展示出远优于基于分类器方法的性能, 其具有效率高并且准确的特点。文献 [4] 提出一种可以自动识别视频中火灾的卷积神经网络, 该网络通过卷积层提取特征, 池化层来缩小特征图简化计算复杂度进行特征压缩, 全连接层连接所有特征并输出到分类器。相比人工提取特征的算法准确率和速度得到了相当大的提升。但是其使用的二维卷积忽略了火焰和烟雾的运动特征并且由于数据集的限制只能识别红色的火焰。

文献 [5-6] 将循环神经网络 (RNN, recurrent neural

收稿日期: 2023-06-01; 修回日期: 2023-07-10。

作者简介: 闵浩 (1998-), 男, 硕士生。

通讯作者: 屈八一 (1981-), 男, 博士, 副教授, 硕士生导师。

引用格式: 闵浩, 屈八一, 谢子豪. 基于改进 YOLOv8 的隧道火灾检测研究[J]. 计算机测量与控制, 2024, 32(5): 38-45.

networks) 应用到火灾检测任务中, RNN 用于提取不同帧中同一目标对应特征之间的关系, 具有对视频信息长时记忆的特点。基于 RNN 的长短期记忆网络 (LSTM, long short-term memory) 解决了传统 RNN 模型中梯度消失的问题, LSTM 应用到火灾检测上可以同时提取火焰和烟雾的空间域特征以及时间域特征, 既能实现高准确率及低召回率, 又能满足实时要求。但是网络中全连接层数比较多, 时间跨度大、网络深, 需要计算的参数太多导致难以训练。Panagiotis 等^[7]提出基于改进 Faster R-CNN 实现火灾检测, 使用了多维纹理分析来提取图像的特征, 对不同类型的火焰图像都能够更准确地识别, 在噪声和光照变化上也有一定的适应性, 但是多纹理特征提取导致了算法的复杂度高, 并且 Faster R-CNN 是一个二阶段的目标检测算法, 需要进行候选区域生成的操作, 精度高, 定位准确, 但是模型结构复杂, 检测速度慢。

YOLO 系列算法是单阶段典型算法, 马庆禄等^[8]通过在 YOLOv5s^[9]中引入卷积注意力模块^[10] (CBAM, convolutional block attention module), 提高了对轮廓特征不明显的隧道烟雾及初期火焰特征检测的准确率, 并且对一些模块进行了替换, 提高了检测效率。张晋瑞等^[11]使用 3D 卷积核构建了一个帧差网络, 并将其衔接至 YOLOv5 的主干网络, 使网络可以融合视频各帧之间的时空信息, 提高了检测精度。

此外, 深度学习算法应用到隧道火灾检测中同样面临着嵌入式设备部署的问题, 因为嵌入式设备计算力有限, 需要使用轻量化网络来满足实时处理的需求。针对这个问题, 诸多研究者提出了轻量级的神经网络, 文献 [12-14] 提出了基于深度可分离卷积的 MobileNet 系列网络, 其中 MobileNet V3^[14]使用了包括非线性激活函数、自适应宽度卷积和网络结构搜索等多种技术来优化模型, 来达到更快的速度和更小的参数。文献 [15-16] 提出基于逐点分组卷积和特征通道混洗的 ShuffleNet 网络。在保留算法准确度的同时减少参数计算, 文献 [17] 提出 GhostNet, 其主要思想是通过少量计算的一系列线性操作来代替网络中的冗余特征图。除了上述多种方法, 对现有算法进行剪枝等处理同样能达到轻量化的目的。文献 [18] 对 YOLOv3^[19]使用了通道剪枝来轻量化减少参数, 然后应用到火灾检测中, 但通道剪枝的过程中, 输入和输出维度的改变会引起一些偏差。

上述多篇论文都已经证明了 YOLO 系列算法在隧道场景下对火灾的检测效果的优越性。而 YOLOv8 算法是 YOLOv5 原作者在之前基础上的进一步改进, 之前的 YOLO 系列算法大多都是基于预定义的锚框。如果目标存在多个重叠的物体时, YOLO 的检测效果可能会受到干扰, 特别是在重叠较多的情况下。而 YOLOv8 是一个无锚框模型,

并且速度和准确性都有了明显的提升。所以本文选择 YOLOv8 算法作为隧道火灾检测算法并对其进行改进, 主要贡献如下:

为了改善原有 YOLOv8 算法应用到隧道中在复杂灯光下的误检, 在特征提取模块中嵌入 PSA 极化自注意力, 改进了损失函数, 同时为了在算法精度和轻量化之间达到平衡引入了 PConv 局部卷积。

1 YOLOv8n 目标检测网络及改进

在当前 COCO 公开数据集上的检测效果显示, YOLOv8 准确率和速度超过其他 YOLO 系列模型。YOLOv8 主要由三部分构成: Backbone、Neck 和 Head。如图 1 所示。其中 Backbone 主要由多个 CBS、C2f、SPPF 等模块组成, 用于图像特征的提取。CBS 是一个简单的卷积层, C2f 模块就是参考了 YOLOv5 中 C3 模块以及 YOLOv7^[20]中 ELAN 的思想进行的设计, 让 YOLOv8 可以在保证参数量下降的同时获得更加丰富的梯度流信息, 其结构如图 2 所示。Neck 通过高层特征与底层特征的融合, 实现高分辨率信息和高语义信息的集

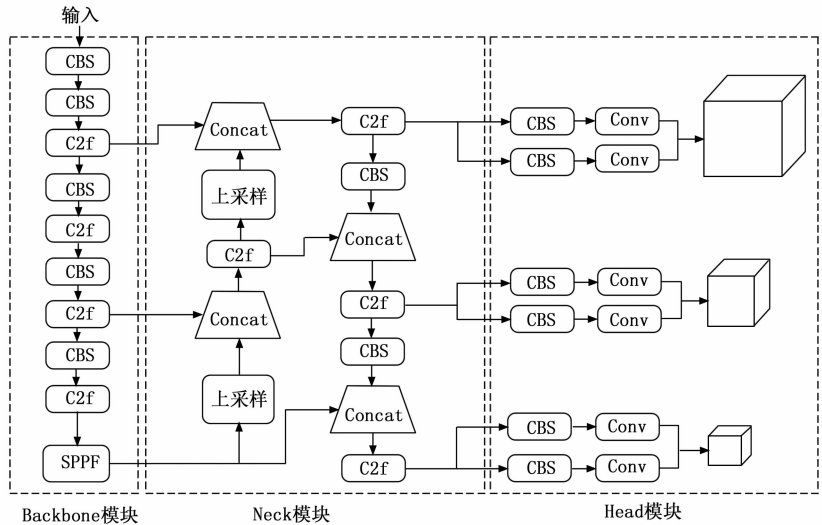


图 1 YOLOv8 网络结构图

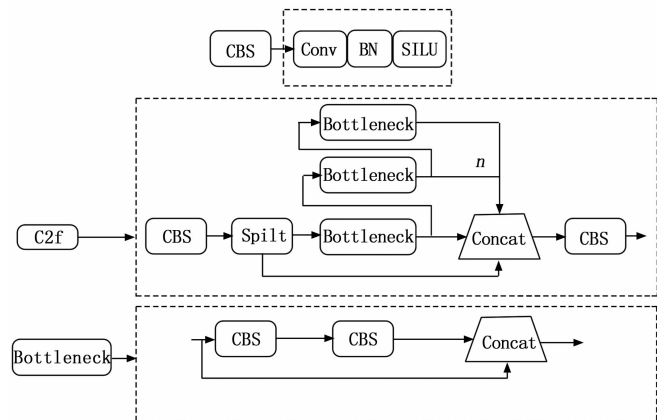


图 2 C2f 结构图

只能提取特征信息，无法完成定位任务，Head 负责将 Neck 精炼的特征信息进行解耦，得出目标物体的位置和类别。

1.1 特征提取网络改进

由于隧道各种灯光比较复杂，火灾现场摄像头采集的图像中大多都是烟雾、车灯还有路灯共同出现的复杂情况，所以在这种情况下检测出准确的火焰和烟雾对检测算法来说是一个非常困难的。文献 [21] 指出 YOLO 系列算法在预测目标位置时没有借助先验信息，所以其在进行目标定位时丧失部分精度。不仅如此，当对每个单元格对应的检测结果进行预测时，YOLO 算法以应当位于单元格内部作为对目标中心点的要求，这种变相将较强的外部空间约束强压在算法预测过程中的方式，缺失了区域采样这一关键步骤，仅仅凭借细节特征的信息，这就导致对早期目标较小的火焰图像的检测效果有很大的改善空间。并且针对上述复杂情况下的烟雾检测效果比较差。

出于以上观点，本文选择将极化自注意力机制 (PSA, polarized self attention)^[22] 嵌入到 YOLOv8 的主干网络中，PSA 极化注意力可以加强对全局信息的特征提取，提高模型对物体的上下文信息感知能力，从而增加模型的检测准确率。

PSA 注意力机制采用了一种极化的方式来过滤输入张量，即在一个方向上完全折叠特征，同时在其正交方向上保留高分辨率。这种极化方式可以帮助模型更好地捕捉全局信息特征，并且在像素级回归任务中表现出色。通过高动态范围技术来增加注意力的动态范围，进一步提高了模型对全局信息特征的感知能力。同时其通过保持最高的内部分辨率，在注意力计算中充分利用了高分辨率信息，所以相比于 GC、CBAM 等注意力其充分结合了全局信息和局部信息来实现了更准确和全面的结果。

除了极化滤波外，PSA 中还使用了增强模块，它可以用非线性函数转化输入的向量，将其映射到更高维度的空间，并与 PSA 相结合。通过增强模块的设计，可将特征维度减少并实现参数共享，因此在特征提取过程中运算速度更快。

其结构如图 3 所示，首先将输入张量进行压缩操作，将其压缩为一个向量。然后通过使用 softmax 函数对该向量进行归一化处理，并将其作为权重矩阵与原始输入张量进行点积运算。这样可以得到一个加权后的张量表示。

接下来，在通道和空间两个方向上分别进行非线性变换，并将它们组合起来以获得最终输出。在计算过程中需要保持高内部分辨率，并且需要考虑到不同层之间的信息传递问题。因此，在每个层之间都需要进行适当的归一化和缩放操作，以确保信息的有效传递和保留。

本文在 YOLOv8n 的主干网络卷积层间嵌入 PSA 注意力机制，使得原特征提取网络由 10 层增添为 13 层，进行网络模型优化。提高模型对物体的上下文信息感知能力，抑制其他无用的信息，使模型专注于火焰和烟雾的信息来增加检测准确率。

1.2 轻量化网络设计

在隧道火灾检测的实际场景中，需要将模型部署在嵌

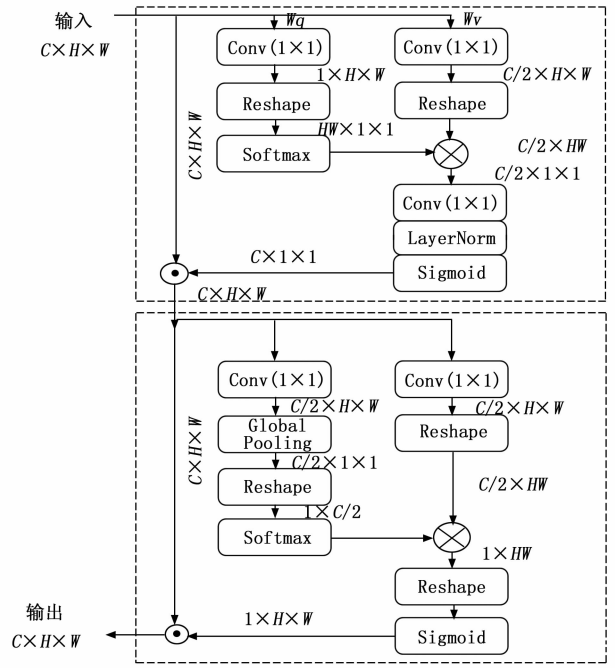


图 3 PSA 自注意力结构图

入式设备、边缘设备或者其他资源受限的环境中，因此模型的轻量化变得至关重要。并且因为在隧道火灾发生的早期就要及时地检测到火灾并做出响应的原因，所以隧道火灾检测的实时性需求比较高，轻量化之后的 YOLOv8 模型可以提高推理速度，从而实现现场的实时检测。

目前有很多研究者通过引用 MobileNet、ShuffleNet 和 GhostNet 等轻量化网络来对 YOLO 算法主干网络进行改进，如文献 [23] 将 YOLOv5s 的骨干网络替换为轻量化网络 Shufflen-etu2。文献 [24] 引入 GhostNet 中的 Ghost 卷积模块，并且融合并行卷积来替换 YOLOv5 中的 CSP 模块。虽然上述研究在提高模型精度的同时，减少了计算量，但是其在低延迟和高吞吐量上面还有很大的进步空间，Chen^[25] 等人指出 MobileNet、ShuffleNet 和 GhostNet 等轻量化网络通过深度可分离卷积和逐点分组卷积来达到更少的浮点运算，但是浮点运算次数的减少并不会带来延迟的减少，主要是因为每秒浮点运算 (FLOPs, floating-point operations per second) 效率低下，在减少浮点运算次数 (FLOPs, floating-point operations) 的过程中，算子经常会受到内存访问增加的副作用的影响，尤其是深度卷积。该文献对上述各种轻量化神经网络进行了对比，发现大部分网络的 FLOPs 低于流行的 ResNet50，在 FLOPs 如此低的情况下，显然并不是一个真正快速的轻量化网络。另一方面，上述网络通常伴随着级联、池化和混洗等额外的数据操作造成了一定的冗余计算。考虑到这两个问题，文献提出了一种新的局部卷积 (PConv, partial convolution)，如图 4 所示。

PConv 在减少浮点运算次数的同时，又保持高每秒浮点




图 4 普通卷积

运算次数, 减少了冗余计算和内存访问次数, 更好地利用了设备上的计算能力, 同时具有更低的延迟和更高的吞吐量。

1.3 损失函数优化

YOLOv8 的损失函数构成如式 (1) 所示:

$$L = L_{box} + L_{cls} + L_{DFL} \quad (1)$$

其中: L_{cls} 、 L_{box} 和 L_{DFL} 分别是分类损失、边界框回归损失和分布式焦点损失 (DFL, distribution focal loss)^[26]。DFL 是以交叉熵的形式去优化与标签 y 最接近的左右 2 个位置的概率, 从而让网络更快的聚焦到目标位置的邻近区域的分布。如公式 (2) 所示:

$$DFL(S_i, S_{i+1}) = -((y_{i+1} - y) \log(S_i) + (y - y_i) \log(S_{i+1})) \quad (2)$$

分类损失是二值交叉熵损失 (BCE, binary cross entropy loss)。边界框回归损失为 $CIoU$ ^[27], 完整的计算如式 (3) 所示:

$$LCIoU = 1 - IoU + \frac{\rho^2(b, b^{gt})}{c^2} + \alpha v \quad (3)$$

其中: α 是权重函数, 而 v 用来度量宽高比的相似性, 定义如式 (4) 和 (5), IoU 为预测框和真实框的交并比, ρ 为欧氏距离, b 和 b^{gt} 分别是预测框和真实框的中心点, c 表示最小包围预测框和真实框的对角线长度。

$$\alpha = \frac{v}{(1 - IoU) + v} \quad (4)$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{\omega^{gt}}{h^{gt}} - \arctan \frac{\omega}{h} \right)^2 \quad (5)$$

式中, ω 、 h 、 ω^{gt} 、 h^{gt} 分别为预测框和真实框的宽和高。

$CIoU$ 虽然将边界框回归的距离、重叠面积、中心点偏移以及宽高比都考虑在内, 避免了 $DIoU$ 中心点重合时交并比一样无法区分的情况, 对于边界框回归有更好的收敛率。但是没有考虑到真实框与预测框之间不匹配的方向。文献 [28] 指出 $CIoU$ 公式 (5) 中 v 仅仅只是反映了宽高比的差异, 而不是预测框宽高和真实框宽高的实际关系, 并且质量差的回归样本对回归损失产生了比较大的影响, 回归质量相对较好的样本则难以进一步优化。出于这两个原因导致模型训练收敛速度慢且效率较低, 预测框不够精确。该文献提出 Focal $EIoU$ v1 来解决质量较好和质量较差的样本间的 BBR 平衡问题。

但是由于 $EIoU$ 使用静态聚焦机制 (FM, focusing mechanism), 非单调 FM 的潜力没有被充分利用, 基于这

一思想, 文献 [29] 提出了一种具有动态非单调 FM 的损失, 名为 $WIoU$ 。

综合考虑本文选择使用 $WIoUv3$ 为边界框回归损失。 $Wise IoUv1$ 损失计算公式如式 (6):

$$LWIoUv1 = RWIoULIoU \quad (6)$$

式中, $RWIoU$ 和 $LIoU$ 计算如式 (7) 和 (8):

$$RWIoU = \exp\left(\frac{(x - xgt)^2 + (y - ygt)^2}{(W_g^2 + H_g^2)^2}\right) \quad (7)$$

$$LIoU = 1 - IoU \quad (8)$$

其中: x 、 y 和 xgt 、 ygt 分别是预测框和真实框的中心点坐标, W_g 和 H_g 是真实框的宽和高。

$LWIoUv3$ 的计算公式如式 (9), 动态聚焦机制计算如式 (10), 其定义离群度以描述锚框的质量, 离群度小意味着锚框质量高。

$$LWIoUv3 = rLWIoUv1, r = \frac{\beta}{\delta \alpha^{\beta-\delta}} \quad (9)$$

$$\beta = \frac{L_{IoU}^*}{LIoU} \in [0, +\infty) \quad (10)$$

2 实验

2.1 实验环境

本文所有实验是基于 Ubuntu 18.04 LTS 操作系统下, CPU 型号为 15vCPU Intel (R) Xeon (R) Platinum 8358P CPU @ 2.60 GHz, 配置一个 RTX A5000 (24 GB) 显卡。深度学习框架为 pyTorch1.13.1。在准备好实验数据集以及配置好实验环境之后, 采用 YOLOv8n 进行迭代训练。

2.2 实验数据集

目前在隧道火灾场景下, 还没有一个公开的常用标准数据集, 由于隧道火灾的场景照片比较难以获得, 经过爬虫技术只能得到 629 张有效隧道场景火灾现场照片, 如图 5 (a) 部分。图 5 (b) 部分是公开模拟的火灾实验视频截图图片, 考虑到在实际隧道火灾中含有车辆的背景图片占有大部分比例, 本文的数据集还包括图 (5) c 部分的车辆起火模拟视频图片。除了模拟实验视频来源外, 还有包括兰州绕城高速公路隧道等地 5 个隧道消防真实救援视频, 经过对视频的帧处理得到 4 484 张图片。




图 5 隧道场景火灾数据集示例图

最后经过裁剪平移、改变亮度、加噪声和旋转角度等数据增强技术获得 17 910 张照片作为训练集一部分。数据增强如图 6 所示。




图 6 数据增强示例

为了能够让训练之后的模型适应各种不同的场景，提高鲁棒性，本文数据集还包括有 18 778 张图片是随机场景下的火灾图片。其中部分来源于公开数据集 Fire Dunning Dataset，这个数据集各种不同场景的火灾图像。如图 7 所示。




图 7 随机场景火灾数据集示例

本文数据集总共包含 40 356 张火焰和烟雾图片。其中随机场景火灾图片、验证集和测试集未使用数据增强，这样可以更准确地评估模型的性能。因为验证集和测试集的主要目的是评估模型的泛化能力，而不是提高模型性能。因此，如果使用数据增强技术，并不会得到对模型泛化性能的真正评估。

2.3 实验评价标准

为了准确分析模型对隧道环境下火焰烟雾的检测效果，本文选择了精确率、召回率、平均精度均值和模型向前推理时间作为模型算法的衡量指标。

精确率可用来评估模型检测准确性，其定义为正确预测为正的占全部预测为总的比例，如式 (11) 所示。召回率，可用来评估模型检测的全面性，表示为正确预测为正的占全部实际为总的比例，如式 (12) 所示，而 mAP 是目标检测领域最重要的模型性能评估指标之一，用于衡量模型在多个类别上的检测准确性和全面性。其计算过程如式 (13) 所示。本文分别以交并比为 0.5 时的 mAP 和在 IoU 阈值从 0.50 到 0.95 变化的范围内的平均精度 mAP_{50-95} 作为模型的评价标准。

其中， TP 为真正例， FP 为假正例， FN 为假负例。 mAP 计算先是以准确率和召回率分别为 Y 轴和 X 轴绘制曲线得到值，最后进行一个平均值计算。

$$precision = \frac{TP}{TP + FP} \quad (11)$$

$$Recall = \frac{TP}{TP + FN} \quad (12)$$

$$mAP = \frac{\sum_{n=1}^N \int_0^1 Precisionnd(Recalln)}{N} \quad (13)$$

2.4 实验结果与分析

训练时，初始学习率为 0.000 1，批处理大小设置为 16，迭代次数设置为 150，训练以及测试的图片大小均为 640×640 。由图 8 和图 9 可知模型训练在 80 个迭代次数后已经趋向稳定。因为在最后训练的 10 个迭代次数中关闭了 Mosaic 增强的操作，所以曲线有一段明显的下降趋势，说明其有效地提升了模型的效果。




图 8 YOLOv8n 训练损失曲线




图 9 YOLOv8n mAP 曲线

2.4.1 PSA 注意力对比实验

为了改善原有 YOLOv8 算法在隧道灯光复杂情况下对烟雾的误检，同时减少隧道早期火焰的漏检，以及增强算法对全局信息的获取能力，本文选择将 PSA 极化自注意力机制嵌入到 YOLOv8n 的主干网络中，为了能够准确评估 PSA 注意力对原有算法的提升效果，在原有数据集外还使用各种复杂场景下的真实隧道火灾视频录像的图片进行了测试，如图 10 所示。

由对比结果明显可以看到原 YOLOv8 算法存在相当数量上的误检和漏检情况，第 1、3、4 和 6 组没有检测到火焰，第 2 和 5 组分别将车灯和墙壁误检成火焰和烟雾。



图 10 PSA 注意力测试部分结果对比

2.4.2 不同改进的消融实验

为了能够公平测试 WIoU 损失函数, 本文在仅改动 YOLOv8 的损失函数情况下进行训练, 如表 1 所示, 其中 AP^{fire} 、 AP^{Smoke} 和 mAP 分别代表的是 IoU 交并比为 0.5 的平均精度。通过该表可以看出, 针对火焰的平均精度 AP 由原先的 0.802 提升到 0.811, 烟雾的平均精度 AP 由 0.865 提升到 0.875, 总的 mAP 由 0.833 提升到 0.843。所以可以得出结论使用 WIoU 损失函数可以有效改进原 CIoU 损失函数的缺点。

表 1 WIoU 与 CIoU 训练结果对比

	AP^{fire}	AP^{Smoke}	mAP
CIoU	0.802	0.865	0.833
WIoU	0.811	0.875	0.843

为验证本文对于 YOLOv8n 网络模型改进方法的有效与合理性, 以及算法是否能够同时满足高精度和轻量型的要求, 本文对原网络模型的结构改进以及所加模块后对模型的性能影响进行了充分完整的实验, 分别对各自改进后模型训练并测试, 在所用数据集上进行消融实验, 结果如表 2 所示。

表 2 不同改进模型训练结果对比

	参数量 /MB	GFL OPS	模型向前推理时间/ms	AP (fire)	AP (Smoke)	mAP
YOLOv8n	3.00	8.1	0.9	0.802	0.865	0.833
YOLOv8n+WIoU	3.00	8.1	0.7	0.811	0.875	0.843
YOLOv8n+PCConv+WIoU	2.11	5.9	0.5	0.804	0.866	0.835
YOLOv8n+PCConv+WIoU+PSA	2.47	6.6	0.7	0.812	0.871	0.842

在消融实验中, 本文以原 YOLOv8n 模型为基线, 依次更改损失函数为 WIoU, 引入 PCConv 局部卷积, 嵌入 PSA 模块。训练过程中, 依旧采用相同的配置参数与实验平台展开实验。从表 2 的结果来看, 在引入 PCConv 局部卷积后, 模型的参数量从 3 MB 减少到 2.11 MB, 缩小了 29.7%, 模型向前推理时间从 0.9 ms 减少到 0.5 ms, 消耗时间降低了 44%, 与此同时精度并没有减少, 还有所提升, 在模型轻量化和精度上达到了一定的平衡。

表 3 不同改进模型训练结果对比

	AP^{fire} 50-90	AP^{Smoke} 50-90	mAP 50-90	AP^{fire}	AP^{Smoke}	mAP
YOLOv3	0.433	0.56	0.496	0.773	0.829	0.801
YOLOv5	0.457	0.579	0.518	0.801	0.855	0.828
YOLOv8n	0.492	0.635	0.563	0.802	0.865	0.833
本文方法	0.496	0.638	0.569	0.814	0.878	0.846

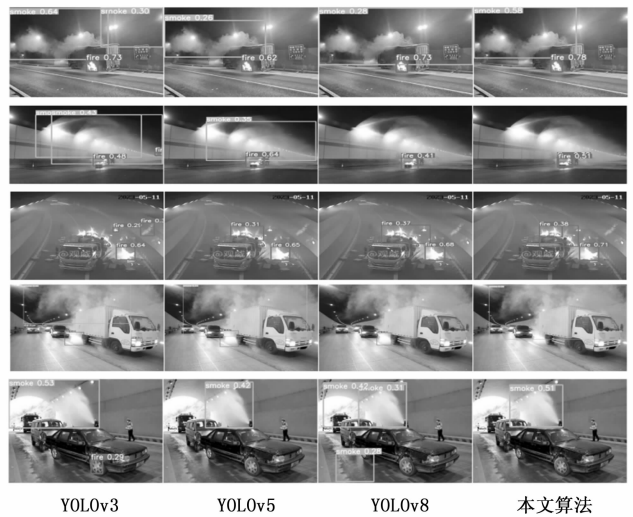


图 11 检测结果对比示例

为了进一步评估本文方法在隧道火灾检测上的性能, 本文与现有广泛应用的 YOLOv3、YOLOv5 和原有 YOLOv8 算法进行比较, 结果如表 3 所示。表中 AP^{fire} 50-90, AP^{Smoke} 50-90 和 mAP 50-90 分别表示 IoU 阈值从 0.50 到 0.95 变化的范围内的火焰、烟雾和总类别平均精度。

与 YOLOv3 和 YOLOv5 相比, 本文算法对火焰的 AP^{fire} 50-90 分别提升了 6.3 和 3.9 个百分点, 对烟雾的 AP^{Smoke} 50-90 分别提升了 7.8 和 5.9 个百分点, mAP 50-90 分别提升了 7.3 和 5.1 个百分点, 在模型性能上有很大的提升。

YOLOv3 将图像划分为较小的网格, 这在处理长宽比较大的目标时可能导致检测框不准确。例如图 11 中第 1 组和第 4 组检测结果中, YOLOv3 将灯光误以为烟雾产生了误检, 在第 2 组和第 5 组中将喷水误检为烟雾, 特别的是在第 5 组图片中 YOLOv3 将汽车轮胎误检成火焰。从上述结果可以看出 YOLOv3 方法在隧道火灾实际检测中有较大的缺陷。

YOLOv5 和 YOLOv8 相比 YOLOv3 算法的误检情况改善了不少,但是在隧道内灯光复杂情况下仍然存在将车灯误以为烟雾的情况如第 4 组图片和第 5 组图片。

相比于上述几种方法,本文方法可以改善隧道内灯光复杂下对烟雾的误检情况,同时减少早期火焰的漏检。可以满足隧道火灾的实时检测。

3 隧道火灾检测

在实际的隧道检测中需要根据现场需求铺设一定数量的视频摄像头,以一个实时的视频数据作为本文所提出改进算法的输入,并且在隧道内或者入口处安装一个嵌入式终端设备、火灾报警器和通信模块来进行火灾检测。

在火灾发生的早期阶段是进行救援和灭火的最佳时期。为了更加准确地检测早期火灾,本文对原 YOLOv8 算法进行了引入 PSA 注意力机制和损失函数优化。在隧道内一旦发现烟雾或者明火,通过改进的算法可以很快识别出来。当系统检测到火灾发生时,部署在隧道入口处的报警器进行示警,阻止后来车辆进入隧道。同时,利用通信模块向消防部门报警以获得及时的救援。

4 结束语

针对隧道复杂场景下的火灾检测这一目标,本文提出一种基于改进 YOLOv8 的隧道火灾检测算法,引入极化注意力抑制特征中的冗余信息,使网络集中在火焰和烟雾两种类别的检测,同时为了达到模型轻量化的目的,引入了 PConv 来实现低延迟和高吞吐量的模型,使用 WIoU 函数优化网络损失。

本文在隧道场景数据集上进行了充分的训练实验。对比了不同注意力的改善效果,同时进行了提出的不同改进模块的消融实验。结果表明,本文方法的平均精度相比原有方法有很大提升,并且算法模型的参数大大降低,推理速度提升效果明显。但是由于隧道场景的数据获取比较困难,所以在数据集方面仍然还需要进一步的扩充。

参考文献:

- [1] LOWE D G. Distinctive image features from scale-invariant key points [J]. *International Journal of Computer Vision*, 2004, 60 (2): 91 - 110.
- [2] KUANG H L, CHAN L H, YAN H. Multiclass fruit detection based on multiple color channels [C] // *International Conference on Wavelet Analysis and Pattern Recognition*, 2015: 1 - 7.
- [3] KOSMAS D, PANAGIOTIS B, and NIKOS G. Spatiotemporal flame modeling and dynamic texture analysis for automatic videobased fire detection [J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2015, 25 (2): 339 - 351.
- [4] FRIZZI S, KAABI R, BOUCHOUICHA M, GINOUX J. Convolutional neural network for video fire and smoke detection. [C] // *Annual Conference of the IEEE Industrial Electronics Society*, 2016: 877 - 882
- [5] YICHAO C, FENG Y, QINGFEI T, et al. An attention enhanced Bidirectional LSTM for early forest fire smoke recognition [J]. *IEEE Access*, 2019, 7: 154732 - 154742.
- [6] NGUYEN M D, VU H N, PHAM D C. Multistage realtime fire detection using convolutional neural networks and long shortterm memory networks [J]. *IEEE Access*, 2021, 9: 146667 - 146679.
- [7] PANAGIOTIS B, KOSMAS D, KYRIAKI K, NIKOS G, et al. Fire detection from images using Faster RCNN and multidimensional texture analysis [C] // *IEEE International Conference on Acoustics, Speech and Signal Processing*. Brighton, UK: 2019: 8301 - 8305
- [8] 马庆禄, 鲁佳萍, 唐小垚, 等. 改进 YOLOv5s 的公路隧道烟火检测方法 [J]. *浙江大学学报(工学版)*, 2023, 57 (4): 1 - 12.
- [9] JOCHER, GLENN, ALEX WONG, et al. YOLOv5: improved realtime object detection [J]. *arXiv*: 1912.05274, 2020.
- [10] WOO, SANGHYUN, et al. CBAM: convolutional block attention module [C] // *European Conference on Computer Vision (ECCV)*. Munich: Springer, 2018: 3 - 19.
- [11] 张晋瑞, 宋焕生, 孙士杰, 等. 改进 YOLOv5 的隧道火灾帧差检测网络与应用方法 [J]. *计算机工程与应用*, 2023, 59 (2): 222 - 230.
- [12] HOWARD A G, ZHU M, CHEN B, et al. Mobilenets: efficient convolutional neural networks for mobile vision applications [J]. *arXiv preprint arXiv*: 1704.04861, 2017.
- [13] SANDLER M, HOWARD A, ZHU M, et al. Mobilenetv2: inverted residuals and linear bottlenecks [C] // *Proceedings of the IEEE conference on computer vision and pattern recognition*, Salt Lake City: 2018.
- [14] ANDREW H, MARK S, GRACE C, et al. Searching for mobilenetv3 [C] // *In Proceedings of the IEEE/CVF International Conference on Computer Vision*, Seoul: 2019: 1314 - 1324.
- [15] ZHANG X, ZHOU X, LIN M, et al. Shufflenet: an extremely efficient convolutional neural network for mobile devices [C] // *Proceedings of the Proceedings of the IEEE conference on computer vision and pattern recognition*, Salt Lake City, 2018.
- [16] MA N, ZHANG X, ZHENG HT, et al. Shufflenet v2: practical guidelines for efficient cnn architecture design [C] // *Proceedings of the Proceedings of the European Conference on Computer Vision*, Munich: 2018.
- [17] KAI H, YUNHE W, QI T, et al. Ghostnet: more features from cheap operations [C] // *In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020, 1580 - 1589.
- [18] QIAN H, SHI F, CHEN W, et al. A fire monitoring and alarm system based on channelwise pruned YOLOv3 [J]. *Multi-media Tools and Applications*, 2021: 1 - 19.
- [19] JOSEPH R, ALI F. YOLOv3: an incremental improvement [C] // *Proceedings of the IEEE Conference on Computer Vi-*

sin and Pattern Recognition, Salt Lake City; 2018; 7794 - 7803.

[20] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: trainable bag of freebies sets new state of the art for real time object detectors [J]. ArXiv Preprint ArXiv; 2207.02696, 2022.

[21] 杨 锋, 丁之桐, 邢蒙蒙, 等. 深度学习的目标检测算法改进综述 [J/OL]. 计算机工程与应用, https://kns.cnki.net/kcms/detail//11.2127.tp.20230214.1459.040.html.

[22] HUAJUN L, FUQIANG L, XINYI F, et al. Polarized self-attention: towards high quality pixel-wise regression [J]. ArXiv Preprint ArXiv; 2107.00782, 2021.

[23] 皮 骏, 刘宇恒, 李久昊. 基于 YOLOv5s 的轻量化森林火灾检测算法研究 [J]. 图学学报, 2023, 44 (1): 26 - 32.

[24] 邓楷文, 葛晨阳. 改进 YOLOv5 的轻量化红外交通目标检测 [J/OL]. 计算机工程与应用, https://kns.cnki.net/kcms/detail/11.2127.TP.20230329.0923.006.html.

[25] JIERUN C, SHIUHONG K, HAO H, et al. Run, don't walk: chasing higher FLOPS for faster neural networks [J]. ArXiv Preprint ArXiv; 2303.03667, 2023.

[26] XIANG L, WENHAI W, LIJUN W, et al. Generalized focal loss: learning qualified and distributed bounding boxes for dense object detection [J]. ArXiv; 2006.04388, 2020.

[27] 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, 34 (7): 12993 - 13000.

[28] YIFAN Z, WEIQIANG R, ZHANG Z, et al. Focal and efficient IOU loss for accurate bounding box regression [J]. ArXiv; 2101.08158, 2022.

[29] ZANJIA T, YUHANG C, ZEWEIF X, et at. Wise-IoU: bounding box regression loss with dynamic focusing mechanism [J]. ArXiv; 2301.10051.

讯技术, 2023, 63 (6): 811 - 816.

(上接第 37 页)

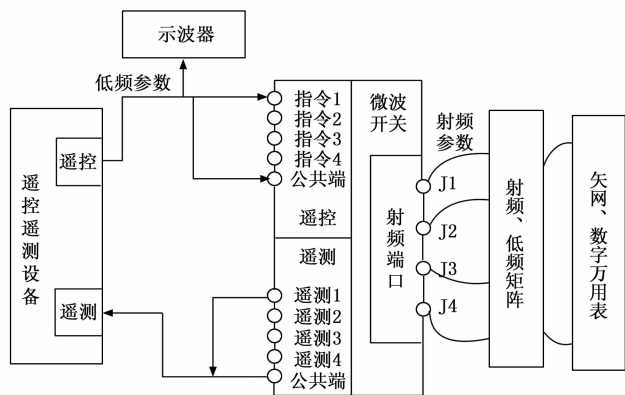


图 15 测试连接示意图

动化程度高、测试可靠性高、适用范围广和可扩展性强等特点。通过定制遥控遥测设备、射频开关矩阵及测试软件的自动化控制,最大可满足 16 个微波开关的同步测试,简化了微波开关测试流程,提高了测试效率及测试可靠性,可广泛应用于微波开关生产及测试领域。

参考文献:

[1] 杨 军, 姜立伟. 星载微波开关概述 [J]. 空间电子技术, 2017, 14 (6): 39 - 43.
[2] 姜立伟, 李志鹏, 杨 军. 宇航微波开关研究现状及发展趋势 [J]. 空间电子技术, 2023, 20 (5): 85 - 93.
[3] 李明军, 刘延迪, 杨 畅, 等. 一种微波开关自动测试设备及方法 [P]. CN202211730885.1. 2023 - 3 - 31.
[4] 王 琦. 射频与微波开关系统的设计与应用 [J]. 国外电子测量技术, 2015, 34 (5): 12 - 14.
[5] 马宏涛. 射频开关自动测试系统 [J]. 国外电子测量技术, 2010, 29 (2): 1 - 6.
[6] 郑晓波, 王 博, 贾守波, 等. 三型微波组件通用自动测试系统设计及实现 [J]. 计量与测试技术, 2023, 50 (7): 5 - 8, 13.
[7] 吴慧伦. 基于 MBSE 的微波统一测控系统测试性设计 [J]. 电

[8] 田 波, 甄蜀春, 张永顺. 现代微波测量的发展动态 [J]. 宇航计测技术, 2003 (5): 61 - 64.
[9] 李士刚, 王文伟, 姚崇斌. 微波开关矩阵设计与使用 [J]. 国外电子测量技术, 2009, 28 (7): 69 - 70, 75.
[10] 麻来宣, 张 厚, 张晨新, 等. 微波矩阵开关设计 [C] // 中国电子学会, 2009 年全国天线年会论文集 (下), 2009: 5, 838 - 842.
[11] 虞 蓉, 黄新临, 马 刚, 等. 微波 12x8 矩阵开关系统 [C] // 中国电子学会, 2001 年全国微波毫米波会议论文集, 2001: 3, 697 - 699.
[12] 薛江波, 张文政. 一种小型化微波开关矩阵 [J]. 空间电子技术, 2015, 12 (2): 9 - 11, 19.
[13] 朱宜东, 李晓辰, 杨晓敏. 动态校准技术在航天微波产品测试中的应用研究 [C] // 中国电子学会, 2023 年全国微波毫米波会议论文集 (三), 2023: 3, 74 - 76.
[14] 肖苗苗, 任 翔, 马帅帅, 等. 微波器件 S 参数全温在线测试技术研究 [J]. 环境技术, 2023, 41 (8): 126 - 132.
[15] 张 萍, 毛立勇, 马艺薇, 等. 基于网络分析仪的多类型微波器件 S 参数自动校准软件研究 [J]. 宇航计测技术, 2023, 43 (3): 66 - 71.
[16] 周 璐. 微波功率参数测量不确定度的评定方法 [J]. 电子质量, 2023 (3): 60 - 64.
[17] 刘祖深. 微波毫米波测试仪器技术的新进展 [J]. 电子测量与仪器学报, 2009, 23 (3): 1 - 8.
[18] 张 凯, 宗俊吉, 霍 鑫, 等. 微波测试系统日志管理的设计与开发 [J]. 电子工业专用设备, 2023 (2): 26 - 30.
[19] 蒋晓红. 射频和微波元器件的测试 [J]. 测控技术, 2004 (1): 14 - 16.
[20] 倪 玲, 张 琦, 郭 霞. 自动测试技术发展综述 [J]. 中国制造业信息化, 2007 (13): 46 - 49.
[21] 唐敬双. 微波毫米波天线测试系统技术研究 [D]. 西安: 西安电子科技大学 (西安), 2007: 25, 29 - 32.
[22] 刘宗玉. 基于虚拟仪器的自动测试系统的研究 [D]. 西安: 西北工业大学 (西安), 2001.