

# 细节增强：一种改进的恶劣天气目标检测方法

母崇铭

桂林电子科技大学 广西桂林 541004

**摘要：**目标检测是城市道路交通检测的基础。如何实现快速且精确的检测是城市道路交通检测需要解决的重要问题。随着Transformer的提出，自注意力机制在目标检测中被广泛应用，在交通检测领域，也具有不错的效果。但是在恶劣天气条件下（如雨、雪、雾天），检测效果会受到极大影响。本文聚焦于道路交通恶劣天气场景，在目标检测网络中引入注意力机制FLA与并行特殊卷积DEconv，以增强模型在恶劣天气下检测的抗干扰性。测试表明，本文的方法提升了检测效果，具备较强的鲁棒性。

**关键词：**恶劣天气；目标检测；FLA；DEconv

## 引言

车辆行人的道路交通目标检测作为计算机视觉的核心课题，通过解析复杂场景图像完成多类别目标的定位与状态识别。该技术基于像素级语义理解模型，可输出目标的边界框、类别概率和实例分割掩码，实现精细化空间分析。作为环境感知的关键模块，它为高阶决策系统提供实时场景解析。当前，该技术已应用于智慧交通多领域：如智能信号配时、自动驾驶冲突预测、异常行为预警及交通资源调度优化。随着深度学习与多模态感知的发展，该技术将持续推动基础设施的数字化转型。

## 一、相关研究

深度学习在城市场景交通检测中具有重要地位<sup>[3]</sup>。卷积神经网络（CNN）凭借卷积层、池化层等结构可自动提取图像特征，尤其擅长处理具有空间关系的网格数据，已在交通检测领域展现出卓越性能。

然而实际应用中，恶劣天气严重影响图像质量<sup>[4]</sup>：暴雨导致模糊和光线折射，雾霾降低对比度，夜间引起噪声和失真，雪天造成高亮干扰。这些因素严重削弱目标清晰度和特征表达，导致检测算法的精度和鲁棒性大幅下降。

YOLO算法作为一种优秀的目标检测算法，常常被应用于多种领域<sup>[5]</sup>，交通场景当人也不例外。例如，Wenyu Liu等人在YOLOv3的基础上提出IA-YOLO<sup>[6]</sup>，提出了一个可微图像处理（DIP）模块，这个方法可以自适应地处理正常和不利天气下的图像。尹靖涵等人针对雾霾、雨雪等恶劣天气，对YOLOv5进行结构优化<sup>[7]</sup>，通过调整残差模块的特征传递深度来抑制背景特征的重叠

加，提升了检测精度。梁天添等人通过改进YOLOv8s算法<sup>[8]</sup>，利用可扩张残差结构对主干网络中的C2F模块进行了优化，引入高效多尺度注意力机制，能够有效地捕获图像中丰富多变的多尺度特征，增强了模型对环境变化的适应能力。

本文基于YOLO模型，结合注意力与多种差分卷积，提出FDA-YOLO的改进模型，试图提升模型在恶劣天气下的检测性能，通过对比试验来验证其效果。

## 二、方法与模型

YOLOv4<sup>[1]</sup>是一个基于深度学习的实时目标检测模型。Mobilenetv3<sup>[2]</sup>是一种轻量级卷积神经网络，其特点是参数少、计算量小、推理时间短。考虑到移动端的推理能力有限，将Mobilenetv3替换原本YOLOv4中的Darknet53主干网络，从而减小参数，提升推理速度。为了提升网络对小目标的能力，将PANet中的五次卷积替换为N-FLA层。为了提升对恶劣天气遮挡目标的检测能力，将检测头中的深度可分离卷积替换为DEconv层加上FLA层。




图1 聚焦函数的实现

### （一）FLA层

在线性注意力中，计算Query和Key的相似度可以表示为以下式子：

$$Sim(Q, K) = \phi(Q)\phi(K)^T$$

在实际运用中，线性注意力权重的分布过于松散，无法聚焦于更有信息量的特征。针对此，本文使用聚焦

函数使线性注意力达到接近于Softmax注意力一样的分布，具体公式如下：

$$\phi_p(x) = f_p(\text{Relu}(x)),$$

$$f_p(x) = \frac{\|x\|}{\|x^{**p}\|} x^{**p}$$

$x^{**p}$  表示逐元素计算  $x$  的  $p$  次方。再添加一个深度可分离卷积 (DWC) 到注意力矩阵，提升模型提取特征的多样性。最终，FLA 可以表示为：

$$O = \text{Sim}(Q, K)V = \phi_p(Q)\phi_p(K)^T V + \text{DWC}(V)$$




图2 深度可分离卷积 (DWC)

### (二) N\_FLA 层

该层是融合了FLA的特征提取模块，使用了双分支处理。分支1经过  $n$  个串联的Bottleneck处理，实现特征提取。分支2保留所有的原始信息。两个分支最后经  $1 \times 1$  卷积进行特征融合。

Bottleneck 作为 N\_FLA 的基本处理单元，使用了残差连接。先通过  $1 \times 1$  卷积压缩通道，再使用  $3 \times 3$  的深度可分离卷积进行空间特征挖掘，输出端接入FLA层。残差连接将原始输入特征与经FLA处理后的特征进行融合，这个过程可以经过  $n$  次。

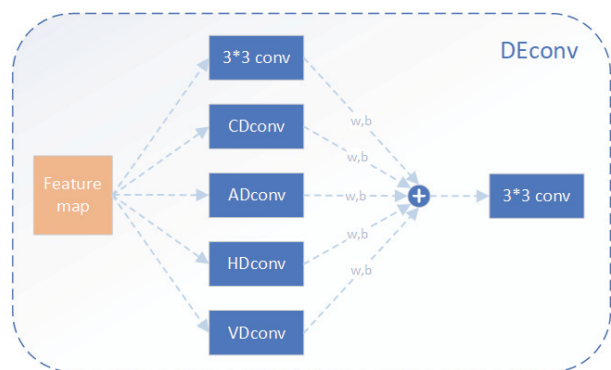


图3 DEconv层

### (三) DEconv层

本文设计了一个DEconv层，它包含5个并行的卷积层（普通卷积，中心差分卷积，角度差分卷积，水平差

分卷积，垂直差分卷积）。

以水平差分卷积为例，首先通过计算选定像素对的差值来计算水平梯度。经过训练后，等价地重新排列学习到的卷积核权重，并将权重运用于输入特征。HDconv就是这样将梯度先验编码到卷积中，通过学习有益的梯度来增强表达能力和泛化能力。

使用DEconv层，对恢复在恶劣天气场景下拍摄图像的高频信息（如边缘和轮廓）具有重要意义。




图4 水平差分卷积 (HDconv) 的推导

## 三、实验与结果分析

### (一) 实验平台与数据集

本文采用RTTS数据集，该数据集源自RESIDE数据集，包含了4322张真实世界的雾天模糊图像，主要涵盖了交通和驾驶场景，覆盖了五类交通场景下常见的检测目标（行人、小汽车、公共汽车、自行车、摩托车），选取训练集3501张，测试集389张，验证集432张。



图5 数据集示例

本次实验的硬件配置如下：16 vCPU Intel (R) Xeon (R) Gold 6430、120GB内存和RTX 4090 (24GB)。

### (二) 消融实验

为了评估本文提出的方法的对YOLOv4网络模型带来的影响，设计了如下的消融实验进行对比，迭代次数为300轮，模型实验结果如表1所示。

表1 消融实验结果

| 模型                                  | 精确率 /% | 召回率 /% | F1 分数 /% | mAP@0.5 /% |
|-------------------------------------|--------|--------|----------|------------|
| YOLOv4+mobilenetv3                  | 58.2   | 52.3   | 55.1     | 48.3       |
| YOLOv4+mobilenetv3+FLA+N_FLA        | 65.7   | 58.9   | 62.1     | 55.8       |
| YOLOv4+mobilenetv3+FLA+N_FLA+DEconv | 77.8   | 49.8   | 60.6     | 65.4       |

表1的消融实验结果显示,用轻量化的mobilenet3来替换主干网络,在减少模型参数、提升推理速度的同时,精确率达到了58.2%。在此基础上,引入FLA+N\_FLAModule,FLA层通过聚焦函数优化线性注意力的分布,结合N\_FLAM层双分支处理,强化了特征提取与融合。召回率提升了6.6%,精确度提升了7.5%,有效增强了对目标的特征表达能力,改善了小目标的检测能力。最后通过在头部网络中使用DEconv层代替深度可分离卷积,采用5种卷积并行处理的方式,精确率进一步提升到了77.8%、召回率达到49.8%、F1分数达到60.6、mAP@0.5达到65.4%,提升了恶劣天气遮挡目标的检测能力,模型整体性能全面优化。

### (三) 对比实验

为全面验证所提模型的性能,在RTTS数据集上使用广泛的恶劣环境目标检测评价指标(平均精度, mAP)进行了深入对比。表2显示了RTTS数据集上近年不同检测算法的mAP@0.5值。

表2 对比实验结果

| 数据集  | IA-YOLO | DE-YOLO | GDIP-YOLO | FDA-YOLO (Ours) |
|------|---------|---------|-----------|-----------------|
| RTTS | 57.7    | 55.2    | 57.8      | 65.4            |

实验结果表明,本文提出的FDA-YOLO在RTTS数据集上的精度突出,在复杂的天气条件下对车辆目标检测和定位能力更强,证明了本文改进算法的有效性。

## 四、讨论

### (一) 方法的优点与创新点

本文提出的改进框架在恶劣天气目标检测领域展现出显著优势。创新性集中体现在三方面:其一,FLA层通过聚焦函数重构线性注意力分布,结合深度可分离卷积增强特征多样性提取,解决了传统线性注意力权重分散的问题;其二,DEconv层采用五路异构卷积并行架构,通过梯度先验编码有效恢复雨雪天气中丢失的高频边缘信息;其三,以MobileNetv3替换Darknet53主干的轻量化设计,在降低参数量的同时维持实时性。实验验证该框架在RTTS雾天数据集上实现mAP@0.5指标的提升,证明其对恶劣天气干扰具有强鲁棒性。

### (二) 方法的局限性

然而,局限性依然存在。模型在暴雨/沙尘暴等

动态强干扰场景下召回率波动明显,反映其跨气象泛化能力不足;其次,浓雾中小目标检测精度低于42%,因高频信息损失导致N\_FLAM双分支机制失效;此外,DEconv五路并行计算使推理时延增加,制约毫秒级响应场景的应用。

### (三) 改进方向

面向未来,改进方向可从三方面突破:开发动态气象感知架构,通过可微分天气分类器激活差异化卷积路径,并融合大气散射模型提升数据真实性;引入红外成像与雷达点云的多模态融合机制,构建跨光谱特征互补;设计知识蒸馏框架,实现硬件级加速与模型压缩。这些改进将显著增强系统在复杂气象条件下的工程化落地能力。

## 参考文献

- [1]Bochkovskiy A, Wang C Y, Liao H Y M. Yolov4: Optimal speed and accuracy of object detection[J]. arXiv preprint arXiv:2004.10934, 2020.
- [2]Howard A, Sandler M, Chu G, et al. Searching for mobilenetv3[C] //Proceedings of the IEEE/CVF international conference on computer vision. 2019: 1314-1324.
- [3]钱磊,赵长海,孙明.关于我国智能交通系统发展的思考[J].内蒙古科技与经济,2021,(19):94-95+97.
- [4]祝培.恶劣天气环境下图像的清晰化[D].西安理工大学,2004.
- [5]徐彦威,李军,董元方,等.YOLO系列目标检测算法综述[J].计算机科学与探索,2024,18(09):2221-2238.
- [6]Yu C, Mai Y, Yang C, et al. IA-YOLO: A Vatica Segmentation Model Based on an Inverted Attention Block for Drone Cameras[J]. AGRICULTURE-BASEL, 2024, 14(12):2252.
- [7]尹靖涵,瞿绍军,姚泽楷,等.基于YOLOv5的雾霾天气下交通标志识别模型[J].计算机应用,2022,42(09):2876-2884.
- [8]梁天添,杨淞淇,钱振明.基于改进YOLOv8s的恶劣天气车辆行人检测方法[J].电子测量技术,2024,47(09):112-119.