

# 雨天车辆检测的两阶段渐进式图像去雨算法

胡待方<sup>1</sup>, 仝秋红<sup>1\*</sup>, 柴国庆<sup>1</sup>, 王凯<sup>2</sup>, 穆雨薇<sup>1</sup>, 苏胜君<sup>1</sup>

<sup>1</sup>长安大学汽车学院, 陕西 西安 710018;

<sup>2</sup>长安大学信息工程学院, 陕西 西安 710018

**摘要** 为了提升雨天车辆检测的精度,解决智能网联汽车的车辆检测系统受雨纹干扰导致精度衰退的问题,提出一种雨天车辆检测的两阶段渐进式图像去雨算法。该算法搭建了以轻量级特征提取与加权模块、高效率特征传递与融合模块为核心的两阶段渐进式去雨网络,实现了对雨纹信息的挖掘与捕获,完成了雨纹的精准去除。为了验证所提算法的有效性,融入基准车辆检测器 YOLOv5,对输入 YOLOv5 的去雨图像进行检测。同时根据智能网联汽车的工作环境构建了混合车辆数据集。在该数据集上的结果表明:雨天交通场景下,相比其他算法,所提去雨算法对基准车辆检测器 YOLOv5 的精确率、召回率、mAP@0.5 的增益分别为 3.0 个百分点、8.9 个百分点、7.6 个百分点,证明所提去雨算法能够显著提升对雨天车辆的检测精度,可应用于实际场景。

**关键词** 图像处理; 图像去雨; 图像增强; 两阶段渐进式图像去雨算法; 车辆检测

中图分类号 TP391.41

文献标志码 A

DOI: 10.3788/LOP231053

## Two-Stage Progressive Image Deraining Algorithm for Vehicle Detection in Rainy Days

Hu Daifang<sup>1</sup>, Tong QiuHong<sup>1\*</sup>, Chai Guoqing<sup>1</sup>, Wang Kai<sup>2</sup>, Mu Yuwei<sup>1</sup>, Su Shengjun<sup>1</sup>

<sup>1</sup>School of Automobile, Chang'an University, Xi'an 710018, Shaanxi, China;

<sup>2</sup>School of Information Engineering, Chang'an University, Xi'an 710018, Shaanxi, China

**Abstract** This study proposes a two-stage progressive image deraining algorithm for vehicle detection in rainy days. The proposed algorithm aims to improve the accuracy of vehicle detection in rainy days and solve the problem of accuracy degradation caused by rain streak interference in the vehicle detection system of intelligent and connected vehicles. For the algorithm, a two-stage progressive deraining network was developed with light feature extraction and weighting block along with efficient feature transfer and fuse block as the core to realize the mining and capture of rain streak information and achieve accurate deraining. The deraining images were input to benchmark vehicle detector YOLOv5 for verifying the effectiveness of the proposed algorithm. Furthermore, a mix vehicle dataset was constructed based on the working environment of intelligent and connected vehicles. The gains of the proposed deraining algorithm on the precision, recall, and mAP@0.5 of the benchmark vehicle detector YOLOv5 are 3.0 percentage points, 8.9 percentage points, and 7.6 percentage points, respectively, under a rainy traffic scenario compared with other algorithms. The results prove that the proposed deraining algorithm considerably improves the accuracy of vehicle detection in rainy days and can be used in practice.

**Key words** image processing; image deraining; image enhancing; two-stage progressive image deraining algorithm; vehicle detection

## 1 引言

智能网联汽车(ICV)是一个融合环境感知、信息交互等核心系统于一体的尖端技术综合体<sup>[1]</sup>。ICV的环境感知系统对检测并识别周围目标语义、位置等信

息至关重要。作为ICV环境感知诸多子系统之一,车辆检测系统(VDS)对外部环境条件较为敏感,在雨天等恶劣天气下采集的图像存在雨纹遮挡、细节丢失的问题<sup>[2-4]</sup>。这些问题将导致车辆检测精度的下降<sup>[5-6]</sup>,进而影响ICV的行车安全。

收稿日期: 2023-04-07; 修回日期: 2023-06-02; 录用日期: 2023-06-20; 网络首发日期: 2023-07-12

基金项目: 国家重点研发计划(2022YFC3002602, 2019YFB1600502)

通信作者: \*tongqiuHong@chd.edu.cn

鉴于以上背景,提升恶劣天气场景下 VDS 的精度具有极其重要的理论及实际研究价值。目前已经有许多学者针对该问题展开了相关研究<sup>[7-9]</sup>。Ning 等<sup>[7]</sup>通过在 YOLOv3 中融入 DensNet 和注意力模块,提升了 YOLOv3 在雾天环境下的车辆识别准确率。院老虎等<sup>[8]</sup>基于改进数据增强算法、引入注意力机制的思路优化了 YOLOv5,提升了雾天场景下 YOLOv5 的车辆检测精确率。王战古等<sup>[9]</sup>将毫米波雷达和机器视觉融合,从而保证了雨、雾等恶劣环境下的车辆检测效果。上述研究虽然取得了一定的进展,但均聚焦于检测器的改进与辅助设备的使用,忽略了图像自身与检测精度之间的密切联系,因而在图像端的工作还有待提升。

目前,关于图像去雨的工作已有相关研究成果<sup>[10-23]</sup>。Luo 等<sup>[12]</sup>提出了基于判别稀疏编码的单幅图像去雨算法。Li 等<sup>[14]</sup>建立了基于高斯混合模型的图像去雨方法。Gu 等<sup>[15]</sup>提出了一种联合分析稀疏表示和合成稀疏表示的图像建模方法,从图像的大尺度结构和精细结构两个层次实现了对雨纹的去除。以上传统图像去雨方法虽然能在一定程度上去除雨纹,但是依赖于雨图模型的构建,计算较为复杂且去雨后图像清晰度有待加强。近年来,基于深度学习的图像去雨方法逐渐成为研究热点。Li 等<sup>[16]</sup>提出了一种基于深度卷积和循环神经网络的模型,实现了雨痕的去除。Ren 等<sup>[17]</sup>综合考虑网络架构和损失函数等模块,提出了一种渐进式去雨网络,利用网络去除雨层。Yasarla 等<sup>[18]</sup>考虑到雨纹位置信息对图像去雨的引导作用,提出了一种不确定性引导的多尺度残差去雨网络。Jiang 等<sup>[19]</sup>提出了一种基于金字塔结构的多尺度渐进融合网络,实现了对雨纹分布的感知与去除。上述算法虽然去雨性能优越,但仍存在不同程度的雨纹残留、细节信息损失等问题。Zamir 等<sup>[23]</sup>基于通道注意力和监督注意力改善了此类问题,但网络架构的简洁性有

待提升。

为提升雨天的车辆检测精度,本文设计了一种两阶段渐进式图像去雨算法(TSPNet)。该算法以轻量级特征提取与加权模块(LFEWB)和高效特征传递与融合模块(EFTFB)为核心,受益于轻量化的同时充分挖掘与捕获了不同尺度的浅层和深层雨纹特征的 LFEWB 和保持高效的同时有效传递与丰富了不同阶段的通道维度雨纹特征的 EFTFB, TSPNet 可精确感知雨纹并将雨纹层与背景层剥离,同时实现对背景层纹理等特征的保留与恢复。其次,本文融入了基准车辆检测器 YOLOv5,将 TSPNet 处理后的去雨图像输入 YOLOv5,进行车辆检测。最后,根据 ICV 的工作环境,构建了混合 COCO 和 GoPro 车辆数据集(MCGVD)。在 MCGVD 上的实验结果表明, TSPNet 可显著提升基准车辆检测器 YOLOv5 的检测精度。

## 2 所提方法内容

### 2.1 两阶段渐进式去雨网络

雨滴在图像中的形态分布受成像瞬时多种因素的影响,诸如相机参数、风速和重力、背景亮度等<sup>[24-26]</sup>。在 VDS 获取的雨天交通场景图像中,虽然三维现实立体场景被压缩在二维平面,但邻域像素仍有可能包含不同的深度与亮度信息,如果两个像素相距越远,则它们属于同一处雨纹的概率越小<sup>[27]</sup>。同时,与自车相对距离较近的车辆尺寸大,占用像素点多,处于图像的大局部区域,雨纹可能遮挡局部车辆特征信息;与自车相对距离较远的车辆尺寸小,占用像素点少,处于图像的小局部区域,雨纹可能遮挡全局车辆特征信息<sup>[6,13]</sup>。综合以上分析,基于渐进式恢复的思想,提出如图 1 所示的去雨网络 TSPNet。该网络包含两个阶段,第一阶段为始端图像去雨与复原子网,第二阶段为末端图像去雨与复原子网。考虑到网络架构的简洁性,令

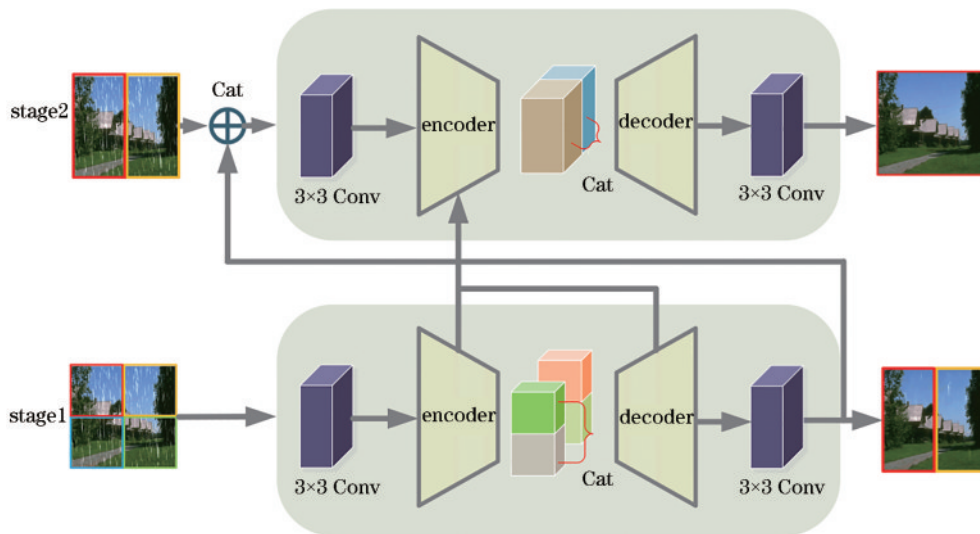


图 1 两阶段渐进式去雨网络

Fig. 1 Two-stage progressive deraining network

TSPNet的两个子网结构相似。鉴于编码器-解码器架构在挖掘特征信息方面的优势,跨阶段融合机制在互补特征信息方面的优点,两个子网均包含1个编码器-解码器架构并通过跨阶段融合机制建立联系。

设输入 TSPNet 的有雨图像为  $F_{p,q}^{\text{in}}$ ,  $p$  代表子图像所处网络阶段,  $q$  代表子图像在完整图像中的位置。

第一阶段,始端图像去雨与复原子网,  $p=1$ , 具体计算过程可分为3部分。第一部分为  $3 \times 3$  常规卷积层,对输入的有雨图像进行升维运算。

$$F_{p,q}^{\circ} = \text{Conv}_{3 \times 3}(F_{p,q}^{\text{in}}), q \in \{1, 2, 3, 4\}, \quad (1)$$

式中:  $\text{Conv}_{3 \times 3}(\cdot)$  表示  $3 \times 3$  卷积操作;  $F_{p,q}^{\text{in}}$  代表原始输入图像;  $F_{p,q}^{\circ}$  代表  $3 \times 3$  卷积操作后的特征图。第二部分为编码器-解码器架构,负责挖掘第一部分输出特征图的全局雨纹特征信息,重建复原图像,该过程表示为

$$F_{p,q}^{\text{T}} = \text{En}_p(F_{p,q}^{\circ}), q \in \{1, 2, 3, 4\}, \quad (2)$$

$$F_{p,q}^{\text{T}0} = F_{p,q}^{\text{T}} - 1 \oplus F_{p,2q}^{\text{T}}, q \in \{1, 2\}, \quad (3)$$

$$F_{p,q}^{\text{T}1} = \text{De}_p(F_{p,q}^{\text{T}0}), q \in \{1, 2\}, \quad (4)$$

式中:  $\text{En}_p(\cdot)$  表示编码运算;  $\text{De}_p(\cdot)$  表示解码运算;  $\oplus$  表示拼接处理;  $F_{p,q}^{\circ}$  为由第一部分输出并输入第二部分的特征图;  $F_{p,q}^{\text{T}}$  代表编码运算后的特征图;  $F_{p,q}^{\text{T}0}$  代表拼接处理后的特征图;  $F_{p,q}^{\text{T}1}$  代表解码运算后的特征图。第三部分为  $3 \times 3$  常规卷积层,对第二部分输出的特征图进行降维运算。

$$F_{p,q}^{\text{R}0} = \text{Conv}_{3 \times 3}(F_{p,q}^{\text{T}1}), q \in \{1, 2\}, \quad (5)$$

式中:  $F_{p,q}^{\text{T}1}$  为由第二部分输出并输入第三部分的特征图;  $F_{p,q}^{\text{R}0}$  代表  $3 \times 3$  卷积操作后的特征图,同时也是第一阶段输出的复原图像。

第二阶段,末端图像去雨与复原子网,  $p=2$ , 对第一阶段输出的去雨图像和第二阶段输入的有雨图像进

行像素级特征融合,具体计算过程参考第一阶段。最终 TSPNet 的去雨结果由第二阶段输出。

## 2.2 基于改进 U-Net 的特征提取网络

为精确感知雨纹区域以充分挖掘不同尺度的局部和全局雨纹特征,受文献[23, 28-32]启发,首先采用基于改进 U-Net<sup>[33]</sup> 的编码器-解码器架构,如图 2 所示。




图 2 基于 U-Net 的编码器-解码器架构

Fig. 2 Encoder-decoder architecture based on U-Net

其次,提出基于注意力机制的轻量级特征提取与加权模块(LFEWB),如图 3 所示。编码器-解码器架构采用 LFEWB 实现了对不同尺度雨纹特征的充分提取,同时使用跳跃连接完成了编码区和解码区对应尺度雨纹特征的精细融合,缓解了采样过程中的细节信息损失。

LFEWB 主要由特征挖掘单元全局雨纹感知模块(GRSPB)和特征加权单元轻量级通道注意力(LCA)组成,GRSPB 如图 3 局部所示, LCA 如图 4 所示。相较于使用空洞卷积增加感受野的其他方法,本文设计 LFEWB 时通过延长网络深度扩大感受野,从而保证雨纹特征信息的充分挖掘与捕获。

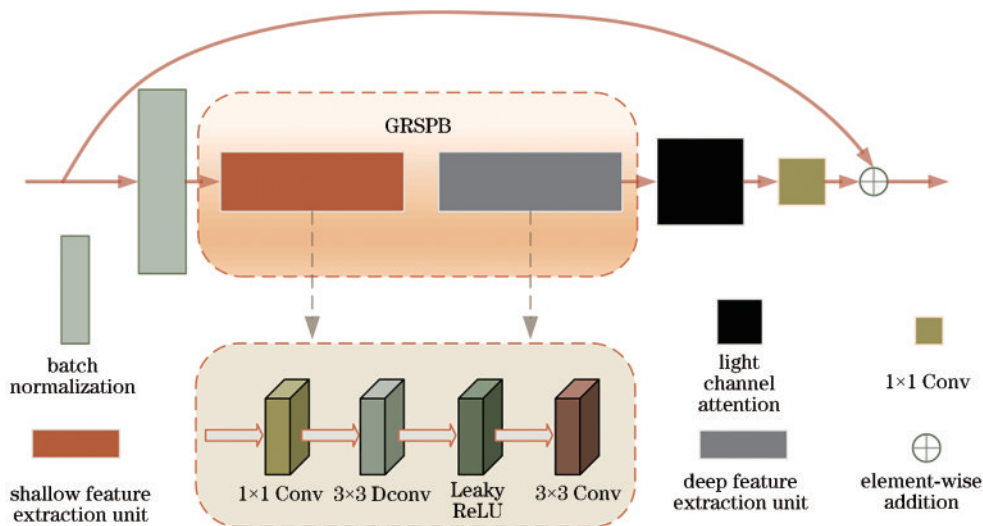


图 3 轻量级特征提取与加权模块

Fig. 3 Light feature extraction and weighting block



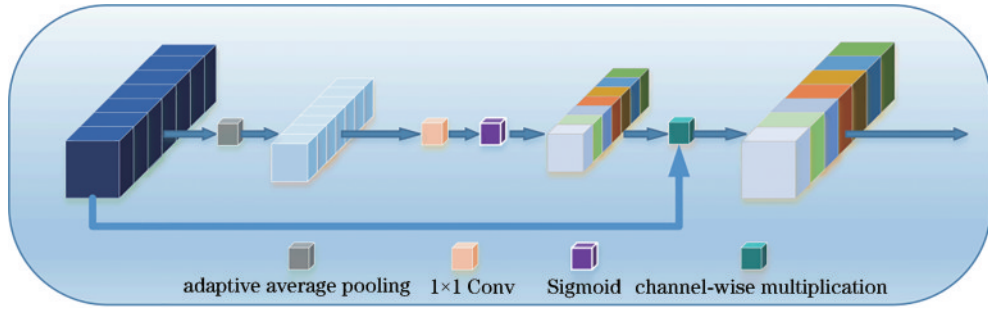


图4 轻量级通道注意力

Fig. 4 Light channel attention

然后,LFEWB融入批量归一化加速网络训练,同时采用深度卷积代替部分常规卷积,以降低计算成本。最后,融入了轻量级通道注意力机制,从通道维度筛选了更重要的雨纹信息,同时进一步提升了网络推理效率。

### 2.3 特征融合机制

针对多次卷积造成细节信息损失的问题,受文献[23]的启发,提出高效特征传递与融合模块(EFTFB),如图5所示。得益于LCA机制,第一阶段编码器和解码器传递至第二阶段编码器的特征信息聚焦于雨纹区域,有效地丰富了第二阶段通道维度的雨纹特征信息。

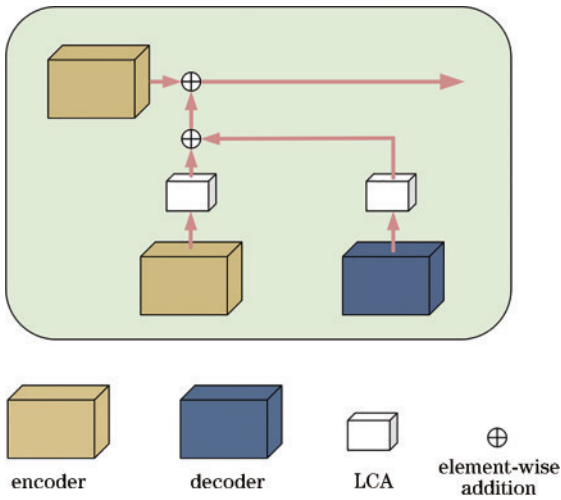


图5 高效特征传递与融合模块

Fig. 5 Efficient feature transfer and fuse block

### 2.4 损失函数

相较于其他方法,仅使用均方误差(MSE)损失的方法会不可避免地出现图像模糊的问题,本文融合对异常值兼容性更强的Charbonnier损失<sup>[34]</sup>、可提升图像视觉质量的edge损失约束网络训练。Charbonnier损失 $L_c$ 和edge损失 $L_e$ 分别定义为

$$L_c = \sqrt{(\psi_p - G_p)^2 + s^2}, \quad (6)$$

$$L_e = \sqrt{[l(\psi_p) - l(G_p)]^2 + s^2}, \quad (7)$$

式中: $l(\cdot)$ 表示拉普拉斯算子<sup>[35]</sup>; $\psi_p$ 代表预测无雨图像; $G_p$ 代表清晰无雨图像;惩罚系数 $s$ 按经验设定为 $1 \times 10^{-3}$ 。总损失函数定义为

$$L_a = \sum_{p=1}^2 [L_c(\psi_p, G_p) + \beta \cdot L_e(\psi_p, G_p)], \quad (8)$$

式中: $\beta$ 按经验设置为0.05。

## 3 实验结果与分析

实验均在Linux操作系统下完成,深度学习框架采用PyTorch,显卡采用NVIDIA RTX A5000。

### 3.1 图像去雨实验

对文献[14,36-39]提供的数据集按照表1所示的方法进行划分。其中,训练集为13172对清晰/有雨图像,测试集为Test100<sup>[39]</sup>、Rain100H<sup>[36]</sup>、Rain100L<sup>[36]</sup>、Test1200<sup>[38]</sup>、Test2800<sup>[37]</sup>。训练TSPNet时batchsize设置为4,epoch设置为350,采用Adam优化方法<sup>[40]</sup>。初始学习率设置为 $2 \times 10^{-4}$ ,采用余弦退火策略<sup>[41]</sup>将学习率衰减至 $1 \times 10^{-6}$ 停止。

表1 数据集划分

Table 1 Dataset partitioning

Dataset	Rain12	Rain1200	Rain100L	Rain100H	Rain800	Rain1800	Rain14000
Training sample	12	0	0	0	700	1800	11200
Testing sample	0	1200	100	100	100	0	2800
Name	Rain12	Test1200	Rain100L	Rain100H	Test100	Rain1800	Test2800

#### 3.1.1 合成数据集中的定量和定性对比实验

采用峰值信噪比(PSNR)<sup>[42]</sup>和结构相似度(SSIM)<sup>[43]</sup>作为定量评价指标。PSNR越高,SSIM越

接近1,代表去雨性能越优秀。TSPNet和其他先进去雨算法的定量对比如表2所示,最优结果采用加粗显示,次优结果采用下划线显示。

表 2 不同去雨算法的对比结果

Table 2 Comparison results of different deraining algorithms

Method	Test100		Rain100H		Rain100L		Test2800		Test1200		Average	
	PSNR /dB	SSIM	PSNR /dB	SSIM	PSNR /dB	SSIM	PSNR /dB	SSIM	PSNR /dB	SSIM	PSNR /dB	SSIM
DSC <sup>[12]</sup>	22.43	0.700	15.17	0.384	27.32	0.848	27.27	0.805	26.35	0.751	23.70	0.698
GMM <sup>[14]</sup>	22.74	0.740	15.37	0.449	26.40	0.741	23.97	0.666	24.08	0.749	22.51	0.669
PReNet <sup>[17]</sup>	24.81	0.851	26.77	0.858	32.44	0.950	31.75	0.916	31.36	0.911	29.42	0.897
MSPFN <sup>[19]</sup>	27.50	0.876	<u>28.66</u>	0.860	32.40	0.933	32.82	0.930	<u>32.39</u>	<b>0.916</b>	30.75	0.903
MPReNet <sup>[23]</sup>	<u>30.27</u>	<u>0.897</u>	<b>30.41</b>	<u>0.890</u>	<u>36.40</u>	<u>0.965</u>	<u>33.64</u>	<u>0.938</u>	<b>32.91</b>	<b>0.916</b>	<u>32.73</u>	<u>0.921</u>
TSPNet	<b>30.65</b>	<b>0.909</b>	<b>30.41</b>	<b>0.892</b>	<b>37.59</b>	<b>0.972</b>	<b>33.70</b>	<b>0.939</b>	32.15	<u>0.915</u>	<b>32.90</b>	<b>0.925</b>

由表 2 可得:与其他去雨算法相比,TSPNet 在 Test100、Rain100L、Rain100H 和 Test2800 中 PSNR 与 SSIM 两项指标均达到最优;取 5 个测试集的平均

PSNR 和 SSIM,TSPNet 获得全部占优的成绩。同时为进一步直观证明 TSPNet 的优越性,选取不同算法在不同场景下的去雨效果进行可视化展示,如图 6 所示。

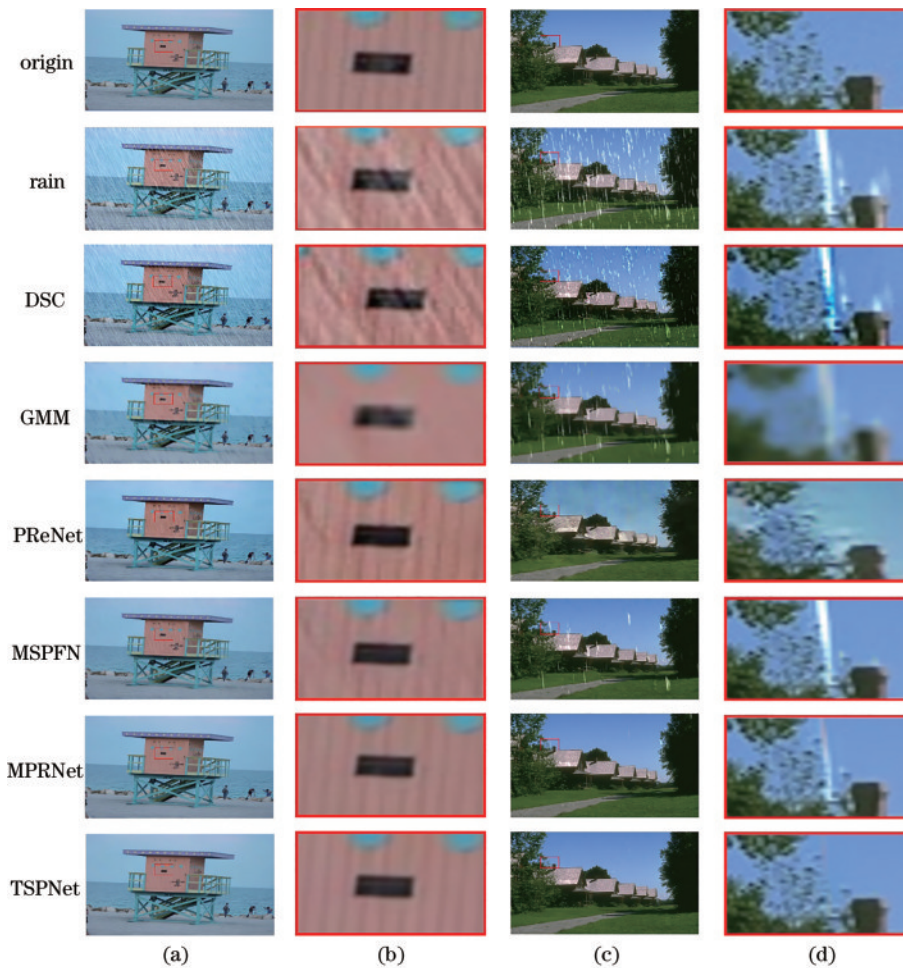


图 6 不同场景中的去雨效果。(a)海岸;(b)海岸局部放大;(c)住宅;(d)住宅局部放大

Fig. 6 Deraining results in different scenes. (a) Seaboard; (b) local magnification of seaboard; (c) house; (d) local magnification of house

如图 6(b)所示:DSC 处理的图像中雨纹痕迹残留严重;GMM 相对于 DSC 去雨效果较好,但是造成了背景模糊;PReNet、MSPFN、MPReNet 以及 TSPNet 均可有效地去除部分雨纹,但 PReNet 处理的图像产生了颜色失真现象,MSPFN 处理的图像出现背景层纹理丢失的现象。如图 6(d)所示:MSPFN 由于采用密集跳跃连接,提取的特征信息过于冗余,雨纹感知与去除

能力受到干扰,故雨纹残留明显;TSPNet 仅采用长跳跃连接,避免了该问题,既复原出干净无雨的背景层又没有丢失细节。

### 3.1.2 与其他主流算法的运行时间对比

为了验证 TSPNet 的算法运行效率,选取图像尺寸分别为  $128 \times 128$  和  $256 \times 256$  的各 100 张有雨图像作为测试集来对比主流去雨算法的平均运行时间,结

果如表 3 所示。由于 GMM 和 DSC 只能在 CPU 中运行,因此平均运行时间较长。PReNet 平均运行时间最短,但是其网络架构过于简洁,无法保证去雨性能,由表 2 可知,相较 TSPNet,PReNet 的 PSNR 和 SSIM 两

个指标分别低 3.48 dB 和 0.028。与平均运行时间相近的 MPRNet 相比,TSPNet 去雨性能占优。因此,TSPNet 实现了去雨性能和平均运行时间两者之间的均衡,进一步证明了所提算法的有效性。

表 3 不同算法的运行时间

Table 3 Running time of different algorithms

unit: s

Image size	DSC <sup>[12]</sup>	GMM <sup>[14]</sup>	PReNet <sup>[17]</sup>	MSPFN <sup>[19]</sup>	MPRNet <sup>[23]</sup>	TSPNet
128×128	11.3652	8.7201	0.0102	0.0421	0.0408	0.0387
256×256	54.6169	32.9075	0.0214	0.0658	0.0462	0.0436

### 3.2 雨天交通场景车辆检测实验

基于 YOLO 模型的目标检测算法的有效性已经在物理、测绘、交通等众多领域得到了充分的证实<sup>[44-46]</sup>,因此选用技术成熟稳定、精度占优的 YOLOv5 作为基准车辆检测器。融入基准车辆检测器 YOLOv5 的雨天车

辆检测方法如图 7 所示,该方法包括雨天交通场景图像输入模块、去雨算法 TSPNet 模块、基准车辆检测器 YOLOv5 模块和车辆检测结果输出模块。先将雨天交通场景图像输入 TSPNet,然后将去雨图像传入 YOLOv5,由 YOLOv5 输出最终的车辆检测结果。

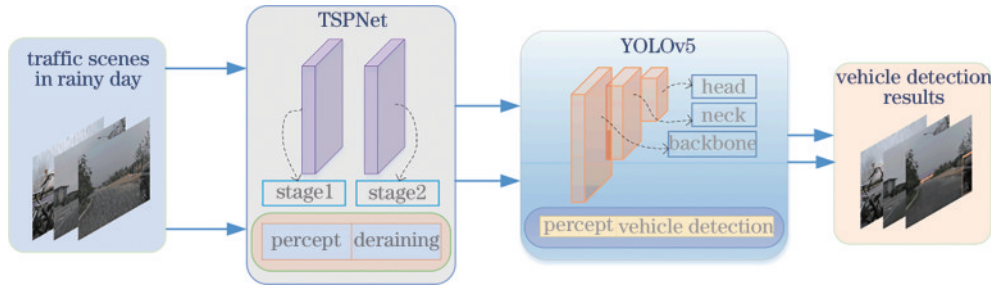


图 7 雨天车辆检测方法

Fig. 7 Method of vehicle detection in rainy days

#### 3.2.1 数据集

根据 ICV 的工作环境构建了 MCGVD,其中包含 2000 张清晰无雨交通场景图和 500 张合成雨天交通场景图,标签类别均设置为 Vehicle。综合考虑现有合成雨图方法<sup>[21,36]</sup>,本文合成雨图的方式具体设置:雨滴大小范围为 1~2,雨纹方向角度为 -30°~30°,雨纹长度范围为 40~60。由于 MCGVD 包含国内外城市、郊区和乡村等具有较大特征差异的场景(2357 张交通场景图由 COCO 数据集提供,143 张交通场景图由本文作者使用 GoPro10BLACK 设备在西安城区及周边村镇采集),因而能有效地用于验证所提去雨算法的泛化性和鲁棒性。

#### 3.2.2 评价指标

使用精确率(P)、召回率(R)、平均精度均值(mAP)作为评价指标,三个评价指标分别定义为

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}}, \quad (9)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}}, \quad (10)$$

$$R_{mAP} = \frac{1}{n} \sum_{i=1}^n \left[ \int_0^1 P_i(R_i) d(R_i) \right], \quad (11)$$

式中: $N_{TP}$ 代表正确识别的车辆数目; $N_{FP}$ 代表错误识别的车辆数目; $N_{FN}$ 代表未被识别的车辆数目; $n$ 代表车辆类别数目, $i$ 代表第*i*个类别。mAP@0.5、mAP@

0.5:0.95 分别代表当预测框与真实框交并比为 50%、50%~95%(步长为 0.05)时,该检测结果无误。

#### 3.2.3 对比实验细节

为验证 TSPNet 对提升 YOLOv5 检测精度的有效性,选用 MCGVD 中 2000 张清晰无雨交通场景图训练 YOLOv5,训练时输入图像大小为 640×640, batchsize 设置为 32, epoch 设置为 300,初始学习率为 0.01。使用训练好的权重在 500 张合成雨天交通场景图中进行对比实验,两种具体实验方法如图 8 所示。

#### 3.2.4 实验结果

表 4 为两个方案的检测结果对比。由表 4 可得,与方案 A 相比,方案 B 的 P、R、mAP@0.5 和 mAP@0.5:0.95 分别提升了 3.0 个百分点、8.9 个百分点、7.6 个百分点和 6.7 个百分点,这表明方案 B 中的基准车辆检测器 YOLOv5 获得的车辆特征信息相较方案 A 更为丰富,表明了 TSPNet 对提升车辆检测精度的积极贡献,证明了所提去雨算法的有效性。

为更直观地证明所提车辆检测方法的优越性,选取不同场景的测试结果进行可视化展示,如图 9 所示。

由图 9(a)可得,方案 A 将被雨纹遮挡的花丛识别成了 Vehicle,方案 B 受益于 TSPNet,将花丛处的雨纹有效去除,因而并未发生误检。在图 9(b)中,方案 B



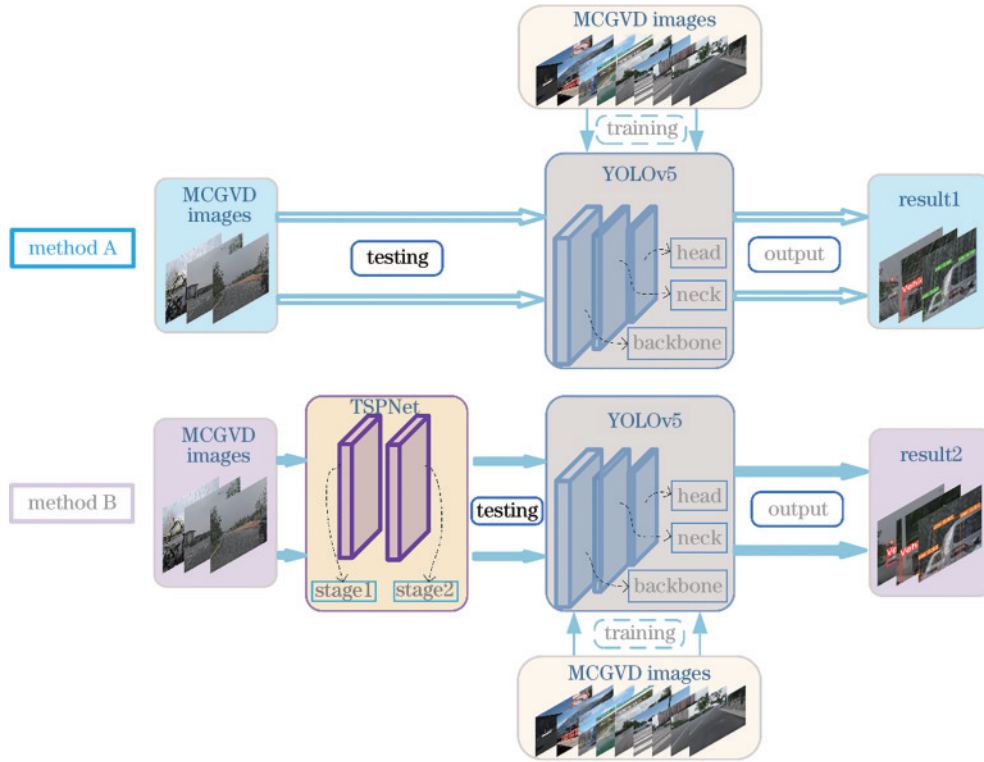


图 8 方案 A 和方案 B 的对比实验

Fig. 8 Comparative experiment of method A and method B

表 4 不同车辆检测方案的对比结果

Table 4 Comparison results of different vehicle detection methods

Method	$P$	$R$	mAP@0.5	mAP@0.5:0.95
Method A	0.765	0.464	0.577	0.355
Method B	0.795	0.553	0.653	0.422

中的 TSPNet 将车窗及车身轮廓边界处的雨纹高效去除,背景清晰可见,故车辆检测置信度为 0.96,相较方案 A 的 0.78 提升了 0.18。在图 9(c) 中,由于雨纹严重遮挡车辆背景层,方案 A 产生了漏检,并未检测出任何车辆,方案 B 由于 TSPNet 实现了对雨纹的有效感知与去除,所以车辆背景层较为清晰,因而成功检测出车




图 9 不同场景中的车辆检测结果。(a)乡村主道;(b)城市主道 1;(c)郊区主道;(d)城市辅道;(e)城市主道 2

Fig. 9 Vehicle detection results in different scenarios. (a) Rural trunk road; (b) urban trunk road 1; (c) suburb trunk road; (d) urban relief road; (e) urban trunk road 2

辆并且能保证较高的检测置信度。在图 9(d)中,方案 A 与方案 B 均可以检测出车辆,但是具有去雨模块的方案 B 的车辆检测置信度更高。在图 9(e)中,方案 B 中的 TSPNet 去雨效果明显,不仅车辆检测置信度相较于方案 A 有所提升,且缓解了漏检。综上所述,所提方案更适用于雨天交通场景车辆检测。

## 4 结 论

针对雨天交通场景下 VDS 受雨纹干扰而导致检测精度衰退的问题,提出一种雨天车辆检测的两阶段渐进式图像去雨算法,通过在多个数据集上的全面实验评估,得出以下结论。

1) 设计的图像去雨算法 TSPNet 以 LFEWB 和 EFTFB 为核心,实现了有雨图像不同尺度和不同阶段上雨纹特征信息的捕获与融合,从而完成了精准去除雨纹并恢复背景层的复杂任务,解决了现有去雨算法长期存在的雨纹残留和细节信息损失的问题。

2) 将基准车辆检测器 YOLOv5 融入所提图像去雨算法 TSPNet,完成雨天车辆的检测。先将雨天交通场景图像输入 TSPNet,然后将 TSPNet 处理后的去雨图像传至 YOLOv5 进行车辆检测,实现了车辆高精度的检测与识别。

3) 根据 ICV 的运行环境构建了混合 COCO 和 GoPro 车辆数据集(MCGVD),在 MCGVD 上的实验结果表明,雨天交通场景下,与原始算法相比,所提去雨算法对基准车辆检测器 YOLOv5 的  $P$ 、 $R$ 、 $mAP@0.5$  的增益分别为 3.0 个百分点、8.9 个百分点、7.6 个百分点,显著提升了基准车辆检测器 YOLOv5 在雨天交通场景下的车辆检测精度。

从实验评价结果可以看出,所提去雨算法对保障以计算机视觉为核心的 VDS 在雨天场景下平稳、安全、有效运行具有重要的理论参考意义,在一定程度上促进了 ICV 的进步与发展。

## 参 考 文 献

- [1] 李克强,戴一凡,李升波,等.智能网联汽车(ICV)技术的发展现状及趋势[J].汽车安全与节能学报,2017,8(1):1-14.  
Li K Q, Dai Y F, Li S B, et al. State-of-the-art and technical trends of intelligent and connected vehicles[J]. Journal of Automotive Safety and Energy, 2017, 8(1): 1-14.
- [2] 陈舒曼,陈玮,尹钟.单幅图像去雨算法研究现状及展望[J].计算机应用研究,2022,39(1):9-17.  
Chen S M, Chen W, Yin Z. Research status and prospect of single image rain removal algorithm[J]. Application Research of Computers, 2022, 39(1): 9-17.
- [3] 张雪岩,庞彦伟.基于多尺度非局部神经网络的图像去雨方法[J].激光与光电子学进展,2021,58(14):1410008.  
Zhang X Y, Pang Y W. Multiscale nonlocal neural network for single image deraining[J]. Laser &

Optoelectronics Progress, 2021, 58(14): 1410008.

- [4] 杨爱萍,王朝臣,王建,等.基于自适应感知金字塔网络的图像去雨[J].东北大学学报(自然科学版),2022,43(4):470-479.  
Yang A P, Wang C C, Wang J, et al. Image deraining based on adaptive perceptual pyramid network[J]. Journal of Northeastern University (Natural Science), 2022, 43(4): 470-479.
- [5] Sun Z M, Liu C A, Qu H Q, et al. PVformer: pedestrian and vehicle detection algorithm based on swin transformer in rainy scenes[J]. Sensors, 2022, 22(15): 5667.
- [6] 谢光达,李洋,曲洪权,等.基于改进 Transformer 的小目标车辆精确检测算法[J].激光与光电子学进展,2022,59(18):1815016.  
Xie G D, Li Y, Qu H Q, et al. Accurate detection algorithm of small target vehicles based on improved Transformer[J]. Laser & Optoelectronics Progress, 2022, 59(18): 1815016.
- [7] Ning T, Jia X K, Duan X D, et al. Vehicle detection method with low-carbon technology in haze weather based on deep neural network[J]. International Journal of Low-Carbon Technologies, 2022, 17: 1151-1157.
- [8] 院老虎,常玉坤,刘家夫.基于改进 YOLOv5s 的雾天场景车辆检测方法[J].郑州大学学报(工学版),2023,44(3):35-41.  
Yuan L H, Chang Y K, Liu J F. Vehicle detection method based on improved YOLOv5s in foggy scene[J]. Journal of Zhengzhou University (Engineering Science), 2023, 44(3): 35-41.
- [9] 王战古,高松,邵金菊,等.基于深度置信网络的多源信息前方车辆检测[J].汽车工程,2018,40(5):554-560,574.  
Wang Z G, Gao S, Shao J J, et al. Front vehicle detection with multi-source information based on deep belief network[J]. Automotive Engineering, 2018, 40(5): 554-560, 574.
- [10] 王美华,柯凡晖,梁云,等.融合 3D 注意力和 Transformer 的图像去雨网络[J].中国图象图形学报,2022,27(5):1509-1521.  
Wang M H, Ke F H, Liang Y, et al. 3D attention and Transformer based single image deraining network[J]. Journal of Image and Graphics, 2022, 27(5): 1509-1521.
- [11] 付相为,单慧琳,吕宗奎,等.基于深度学习的合成孔径雷达图像去噪算法[J].光学学报,2023,43(6):0610002.  
Fu X W, Shan H L, Lü Z K, et al. Synthetic aperture radar image denoising algorithm based on deep learning [J]. Acta Optica Sinica, 2023, 43(6): 0610002.
- [12] Luo Y, Xu Y, Ji H. Removing rain from a single image via discriminative sparse coding[C]//2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2016: 3397-3405.
- [13] 卢贝,盖杉.多尺度渐进式残差网络的图像去雨[J].中国图象图形学报,2022,27(5):1537-1553.  
Lu B, Gai S. Single image rain removal based on multi



- scale progressive residual network[J]. *Journal of Image and Graphics*, 2022, 27(5): 1537-1553.
- [14] Li Y, Tan R T, Guo X J, et al. Rain streak removal using layer priors[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 2736-2744.
- [15] Gu S H, Meng D Y, Zuo W M, et al. Joint convolutional analysis and synthesis sparse representation for single image layer separation[C]//2017 IEEE International Conference on Computer Vision (ICCV), October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 1717-1725.
- [16] Li X A, Wu J L, Lin Z C, et al. Recurrent squeeze-and-excitation context aggregation net for single image deraining[M]//Ferrari V, Hebert M, Sminchisescu C, et al. *Computer vision-ECCV 2018. Lecture notes in computer science*. Cham: Springer, 2018, 11211: 262-277.
- [17] Ren D W, Zuo W M, Hu Q H, et al. Progressive image deraining networks: a better and simpler baseline[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2020: 3932-3941.
- [18] Yasarla R, Patel V M. Uncertainty guided multi-scale residual learning-using a cycle spinning CNN for single image de-raining[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 8405-8414.
- [19] Jiang K, Wang Z Y, Yi P, et al. Multi-scale progressive fusion network for single image deraining[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 8343-8352.
- [20] 袁祎铭, 韩婷婷, 丁佳骏, 等. 基于高效通道注意力机制的龙格库塔去雨网络[J]. *计算机应用*, 2022, 42(S1): 305-309.
- Yuan Y M, Han T T, Ding J J, et al. Runge Kutta network based on efficient channel attention mechanism for image deraining[J]. *Journal of Computer Applications*, 2022, 42(S1): 305-309.
- [21] 韩冉, 曾广森, 王荣杰. 基于残差块网络的图像去雨算法[J]. *仪器仪表学报*, 2021, 41(8): 175-182.
- Han R, Zeng G M, Wang R J. An image Derain algorithm based on the residual block network[J]. *Chinese Journal of Scientific Instrument*, 2021, 41(8): 175-182.
- [22] Suin M, Purohit K, Rajagopalan A N. Spatially-attentive patch-hierarchical network for adaptive motion deblurring [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 3603-3612.
- [23] Zamir S W, Arora A, Khan S, et al. Multi-stage progressive image restoration[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 20-25, 2021, Nashville, TN, USA. New York: IEEE Press, 2021: 14816-14826.
- [24] 周浦城, 周远, 韩裕生. 视频图像去雨技术研究进展[J]. *图学学报*, 2017, 38(5): 629-646.
- Zhou P C, Zhou Y, Han Y S. Review of rain removal techniques in videos and images[J]. *Journal of Graphics*, 2017, 38(5): 629-646.
- [25] 徐波, 朱青松, 熊艳海. 视频图像去雨技术研究前沿[J]. *中国科技论文*, 2015, 10(8): 916-927.
- Xu B, Zhu Q S, Xiong Y H. The research forefront of rain removal for videos and images[J]. *China Sciencepaper*, 2015, 10(8): 916-927.
- [26] 杨泽鹏, 解凯, 李桐. 渐进式多尺度特征级联融合颜色恒常性算法[J]. *光学学报*, 2022, 42(5): 0533002.
- Yang Z P, Xie K, Li T. Progressive multi-scale feature cascade fusion color constancy algorithm[J]. *Acta Optica Sinica*, 2022, 42(5): 0533002.
- [27] Kim J H, Lee C, Sim J Y, et al. Single-image deraining using an adaptive nonlocal means filter[C]//2013 IEEE International Conference on Image Processing, September 15-18, 2013, Melbourne, VIC, Australia. New York: IEEE Press, 2014: 914-917.
- [28] Wang Q L, Wu B G, Zhu P F, et al. ECA-net: efficient channel attention for deep convolutional neural networks [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 11531-11539.
- [29] Chen L Y, Chu X J, Zhang X Y, et al. Simple baselines for image restoration[M]//Avidan S, Brostow G, Cissé M, et al. *Computer vision-ECCV 2022. Lecture notes in computer science*. Cham: Springer Nature Switzerland, 2022, 13667: 17-33.
- [30] 鲁正威, 张笃振. 一种基于 Uniformer Transformer 与 UNet 的图像降噪模型[J]. *南京师范大学学报(工程技术版)*, 2023, 23(1): 39-45, 65.
- Lu Z W, Zhang D Z. An image denoising model based on Uniformer Transformer and UNet[J]. *Journal of Nanjing Normal University (Engineering and Technology Edition)*, 2023, 23(1): 39-45, 65.
- [31] 刘言, 陈刚, 喻春雨, 等. 基于 Res2-Unet 多阶段监督的图像降噪[J]. *光学精密工程*, 2023, 31(6): 920-935.
- Liu Y, Chen G, Yu C Y, et al. Deep learning image denoising based on multi-stage supervised with Res2-Unet[J]. *Optics and Precision Engineering*, 2023, 31(6): 920-935.
- [32] 虞志军, 王国栋, 张镡月. 基于增强多尺度特征网络的图像去模糊[J]. *激光与光电子学进展*, 2022, 59(22): 2215007.
- Yu Z J, Wang G D, Zhang T Y. Image deblurring based on enhanced multi-scale feature network[J]. *Laser & Optoelectronics Progress*, 2022, 59(22): 2215007.
- [33] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[M]//Navab N, Hornegger J, Wells W M, et al. *Medical image computing and computer-assisted intervention-MICCAI 2015. Lecture notes in computer science*. Cham:

- Springer, 2015, 9351: 234-241.
- [34] Charbonnier P, Blanc-Feraud L, Aubert G, et al. Two deterministic half-quadratic regularization algorithms for computed imaging[C]//Proceedings of 1st International Conference on Image Processing, November 13-16, 1994, Austin, TX, USA. New York: IEEE Press, 2002: 168-172.
- [35] Kamgar-Parsi B, Kamgar-Parsi B, Rosenfeld A. Optimally isotropic Laplacian operator[J]. IEEE Transactions on Image Processing, 1999, 8(10): 1467-1472.
- [36] Yang W H, Tan R T, Feng J S, et al. Deep joint rain detection and removal from a single image[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 1685-1694.
- [37] Fu X Y, Huang J B, Zeng D L, et al. Removing rain from single images via a deep detail network[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 1715-1723.
- [38] Zhang H, Patel V M. Density-aware single image de-raining using a multi-stream dense network[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 695-704.
- [39] Zhang H, Sindagi V, Patel V M. Image de-raining using a conditional generative adversarial network[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2020, 30(11): 3943-3956.
- [40] Kingma D P, Ba J. Adam: a method for stochastic optimization[EB/OL]. (2014-12-22) [2023-03-29]. <https://arxiv.org/abs/1412.6980>.
- [41] Loshchilov I, Hutter F. SGDR: stochastic gradient descent with warm restarts[EB/OL]. (2016-8-13) [2023-3-29]. <https://arxiv.org/abs/1608.03983>.
- [42] Huynh-Thu Q, Ghanbari M. Scope of validity of PSNR in image/video quality assessment[J]. Electronics Letters, 2008, 44(13): 800-801.
- [43] Wang Z, Bovik A C, Sheikh H R, et al. Image quality assessment: from error visibility to structural similarity[J]. IEEE Transactions on Image Processing, 2004, 13(4): 600-612.
- [44] 何自芬, 陈光晨, 陈俊松, 等. 多尺度特征融合轻量化夜间红外行人实时检测[J]. 中国激光, 2022, 49(17): 1709002.  
He Z F, Chen G C, Chen J S, et al. Multi-scale feature fusion lightweight real-time infrared pedestrian detection at night[J]. Chinese Journal of Lasers, 2022, 49(17): 1709002.
- [45] 张寅, 朱桂熠, 施天俊, 等. 基于特征融合与注意力的遥感图像小目标检测[J]. 光学学报, 2022, 42(24): 2415001.  
Zhang Y, Zhu G Y, Shi T J, et al. Small object detection in remote sensing images based on feature fusion and attention[J]. Acta Optica Sinica, 2022, 42(24): 2415001.
- [46] Lin J P, Haberstroh F, Karsch S, et al. Applications of object detection networks in high-power laser systems and experiments[J]. High Power Laser Science and Engineering, 2023, 11(1): e7.