

DOI:10.19651/j.cnki.emt.2108342

# 双重注意力引导的弱监督雨滴图像增强<sup>\*</sup>

蒲燕虹<sup>1,2</sup> 张金艺<sup>1,2</sup> 姜玉稀<sup>3</sup>

(1. 上海大学特种光纤与光接入网重点实验室 上海 200444; 2. 上海大学特种光纤与先进通信国际  
合作联合实验室 上海 200444; 3. 上海三思系统集成研究所 上海 201100)

**摘要:** 基于深度学习的雨滴图像增强方法普遍存在高度依赖配对样本数据集,雨滴去除后图像背景细节模糊等问题。对此,提出一种双重注意力引导的弱监督雨滴图像增强方法。该方法设计构建弱监督雨滴图像增强网络,仅需来自雨滴图像域与干净图像域的图像进行训练,可有效降低对配对样本数据集的依赖性;同时,将双重注意力引入生成网络,引导特征提取与多分支掩模生成,掩模同输入的雨滴图像融合后,获得背景清晰的干净图像,实现雨滴图像增强。实验结果表明,该方法在Raindrop数据集上PSNR达到27.0711 dB,SSIM达到0.8996,更好地保留了图像背景细节与颜色信息,证明该方法的可行性和有效性。

**关键词:** 深度学习;雨滴图像增强;弱监督;双重注意力;循环生成对抗网络

中图分类号: TP391 文献标识码: A 国家标准学科分类代码: 520.6040

## Weakly supervised raindrop image enhancement guided by dual attention

Pu Yanhong<sup>1,2</sup> Zhang Jinyi<sup>1,2</sup> Jiang Yuxi<sup>3</sup>

(1. Key Laboratory of Specialty Fiber Optics and Optical Access Networks, Shanghai University, Shanghai 200444, China;  
2. Joint International Research Laboratory of Specialty Fiber Optics and Advanced Communication, Shanghai University,  
Shanghai 200444, China; 3. Shanghai Sansi Institute for System Integration, Shanghai 201100, China)

**Abstract:** Raindrop image enhancement methods based on deep learning generally have some problems, such as highly dependent on aligned sample datasets, and blurred background detail after removing raindrops. In this regard, this paper proposes a weakly supervised raindrop image enhancement method guided by dual attention. This method designs and constructs a weakly supervised raindrop image enhancement network. It only needs images from the raindrop image domain and the clean image domain for training, which can effectively reduce the dependence on the aligned sample datasets. At the same time, dual attention is introduced into the generation network to guide the feature extraction and multi-branch masks generation. After the masks are fused with the input raindrop image, a clean image with a clear background is obtained, and the input raindrop image is enhanced. The experimental results show that the PSNR is 27.0711 dB and the SSIM is 0.8996 of the proposed method respectively on the Raindrop. The background details and color information of the image are better preserved than the previous methods, which prove the feasibility and effectiveness of the proposed method.

**Keywords:** deep learning; raindrop image enhancement; weakly supervise; dual attention; cycle generative adversarial network

## 0 引言

雨天时,附着在镜头或玻璃上的雨滴会造成图像内容、信息被遮挡或模糊,使得图像成像质量大大降低。雨滴图像增强任务旨在基于给定的雨滴图像,去除雨滴并生成干净图像<sup>[1-2]</sup>,对于户外工作的计算机视觉系统,如自动驾驶、

监控及航拍等完成后续高层视觉任务有着重要意义。

目前,基于深度学习的方法在雨滴图像增强任务中取得了最新进展<sup>[3-5]</sup>。Eigen等<sup>[3]</sup>基于卷积神经网络,学习如何将雨滴图像映射到干净图像上,然而该方法只能处理含有少量雨滴的图像,复原图像相对模糊。Qian等<sup>[4]</sup>提出注意力生成对抗网络(Attentive GAN),使用配对样本数据集

收稿日期:2021-11-15

\*基金项目:高等学校学科创新引智计划(111)项目(D20031)、十三五国家重点研发计划项目(2017YFB0403500)资助

进行强监督学习,在生成对抗网络(generative adversarial networks, GAN)中引入空间注意力,然而其注意力仅关注了雨滴区域的恢复,导致雨滴去除后图像背景细节模糊。Quan 等<sup>[5]</sup>提出利用雨滴的物理形状先验来定位雨滴,然而该方法高度依赖配对样本数据集。这些方法均需要配对好的雨滴图像和干净图像,然而建立雨滴类型多样、背景场景丰富、一一配对的大型雨滴图像数据集成本非常高。

Zhu 等<sup>[6]</sup>提出了循环生成对抗网络(cycle generative adversarial network, CycleGAN),通过训练两个生成网络和两个判别网络,将图像从一个领域转换为另一个领域,训练时输入可以是未配对样本,使用弱监督学习解决了图像翻译任务中需要大量配对样本数据的问题,减轻了采集配对样本数据集的成本<sup>[6-8]</sup>。Wei 等<sup>[9]</sup>基于 Attentive GAN 与 CycleGAN 构建了无监督雨线去除模型,利用空间注意力引导网络提取雨线信息以实现雨线图像增强。Luo 等<sup>[10]</sup>提出了基于注意的弱监督雨滴去除网络(WSRR-GAN),以类激活图作为先验,训练雨滴探测器以突出雨滴区域,然而该方法增强效果较差,存在雨滴去除后图像背景细节模糊的问题。

针对上述问题,本文提出双重注意力引导的弱监督雨滴图像增强方法。该方法通过设计构建弱监督雨滴图像增强网络,直接生成干净图像,训练时无需配对样本;针对现有方法仅关注雨滴区域导致图像背景模糊的问题,引入通道与空间双重注意力,能够更好地提取图像特征,关注雨滴区域和背景区域,从而获得背景更为清晰的干净图像。实验表明结果,所提方法在 Raindrop 数据集上的量化结果与视觉效果均优于目前主流方法,更好地保留了图像背景细节与颜色信息。

## 1 弱监督雨滴图像增强网络构建

为降低网络对于配对样本数据集的依赖性,提高网络的应用范围,本文设计构建弱监督雨滴图像增强网络,如图 1 所示。本文设计了 2 个生成网络,包括干净图像生成网络  $G$  和雨滴图像生成网络  $F$ ,网络结构由下一节阐述。利用马尔可夫判别器<sup>[11]</sup>实现 2 个判别网络,包括生成干净图像的判别网络  $D_Y$  和生成雨滴图像的判别网络  $D_X$ 。

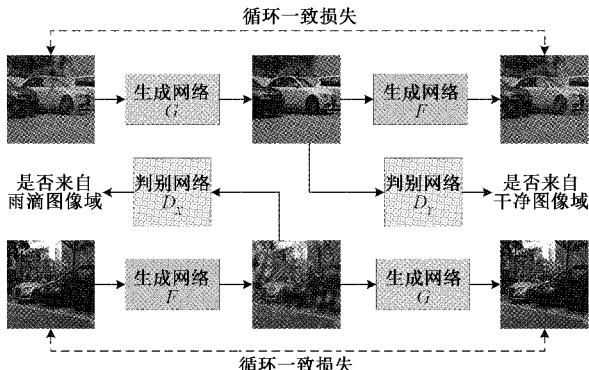


图 1 弱监督雨滴图像增强网络

将雨滴图像数据集与干净图像数据集分别视为雨滴图像域  $X$  与干净图像域  $Y$ ,每次训练从两个域中任意读取图像。 $G$  读取雨滴图像,生成虚假的干净图像。 $F$  读取干净图像,生成虚假的雨滴图像。 $D_X$  用于鉴别输入的雨滴图像是否来自  $X$ , $D_Y$  用于鉴别输入的干净图像是否来自  $Y$ 。

本文采用混合损失函数来训练所构建的弱监督雨滴图像增强网络。使用生成对抗损失  $L_{\text{GAN}}$ ,使得生成图像与真实图像难以区分, $G$  与  $D_Y$  之间的  $L_{\text{GAN}}$  为:

$$L_{\text{GAN}}(G, D_Y) = E_{y \sim p_{\text{data}}(y)} [\log D_Y(y)] + E_{x \sim p_{\text{data}}(x)} [\log(1 - D_Y(G(x)))] \quad (1)$$

式中: $E$  为期望, $x$  为雨滴图像, $y$  为干净图像, $p_{\text{data}}(x)$  和  $p_{\text{data}}(y)$  分别为雨滴图像域  $X$  与干净图像域  $Y$  的样本分布。

对于雨滴图像  $x$ ,通过  $G$  转换为干净图像  $G(x)$ ,再通过  $F$  转换为重构的雨滴图像  $F(G(x))$ , $x$  应与  $F(G(x))$  保持一致,即  $x \rightarrow G(x) \rightarrow F(G(x))$ 。本文使用循环一致损失  $L_{\text{cycle}}$  用于保证  $G$  与  $F$  生成的样本之间不互相矛盾:

$$L_{\text{cycle}}(G, F) = E_{x \sim p_{\text{data}}(x)} [\|F(G(x)) - x\|_1] + E_{y \sim p_{\text{data}}(y)} [\|G(F(y)) - y\|_1] \quad (2)$$

式中: $\|\cdot\|_1$  为 L1 函数,计算两个样本间的绝对值距离。

本文引入单位映射损失  $L_{\text{idt}}$ ,使用像素级的 L1 函数,以减少像素点控制的图像整体颜色无关域信息的改变:

$$L_{\text{idt}}(G, F) = E_{x \sim p_{\text{data}}(x)} [\|F(y) - y\|_1] + E_{y \sim p_{\text{data}}(y)} [\|G(x) - x\|_1] \quad (3)$$

因此,本文所采用的混合损失函数可以表述为:

$$L = L_{\text{GAN}} + \lambda_{\text{cycle}} \times L_{\text{cycle}} + \lambda_{\text{idt}} \times L_{\text{idt}} \quad (4)$$

式中: $\lambda_{\text{cycle}}, \lambda_{\text{idt}}$  是控制  $L_{\text{cycle}}, L_{\text{idt}}$  相对关系的参数, $\times$  表示乘法,沿用 CycleGAN<sup>[8]</sup> 的设置, $\lambda_{\text{cycle}} = 10$ , $\lambda_{\text{idt}} = 0.5$ 。

本文构建的弱监督雨滴图像增强网络,使用 2 个生成网络和 2 个判别网络不断对抗博弈,直到判别网络无法鉴别输入图像是真实图像,还是生成网络生成的虚假图像时,模型训练完成。模型训练时样本随机读取,完成从雨滴图像到干净图像的直接生成,能够实现雨滴图像增强,并有效降低对于配对样本集依赖性。

## 2 基于双重注意力引导雨滴图像增强

在计算机视觉领域,注意力让网络能够关注重点信息,且忽略无关信息<sup>[12-14]</sup>。针对使用弱监督学习使得网络难以集中在雨滴区域的问题,本文在弱监督雨滴图像增强网络的生成网络中,引入通道和空间双重注意力,引导网络实现雨滴图像增强。

以生成网络  $G$  为例,其网络架构如图 2 所示。在编码器中添加通道注意残差块,引导网络实现对于输入图像更全面细致地特征提取。在解码器中添加引入空间注意力的多分支掩模生成网络,引导网络同时关注雨滴区域与背景区域,保留图像背景细节信息。将生成的掩模与雨滴图像融合后,得到无雨滴的干净图像,实现雨滴图像增强。

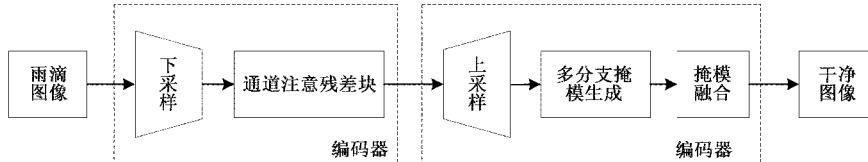


图2 生成网络G总体架构

在初步的实验中,本文也将注意力引入了判别网络,然而性能并没有改进,分析认为生成网络已经学习到了雨滴图像域与干净图像域之间最具区别的内容,因此本文所构建的判别网络基于马尔可夫判别器<sup>[11]</sup>实现。

## 2.1 通道注意力引导残差块提取特征

本文设计的生成网络,使用残差块对输入图像进行特征提取。残差块是残差网络的组成,其将输入与该卷积层的输出进行加和,具有解决随网络层数增加导致梯度消失问题的优势,已在检测、分割、识别等领域被广泛应用<sup>[15]</sup>。

首先对原始残差块进行改进,引入通道注意力,构建通道注意残差块,图3为原始残差块与通道注意残差块的基本组成。所构建的通道注意残差块,将批量标准化层改为实例标准化层,用于本文任务中,可以加速模型收敛,保持每个图像实例之间的独立;同时,添加通道注意力模块,引导残差块更好地实现特征提取。

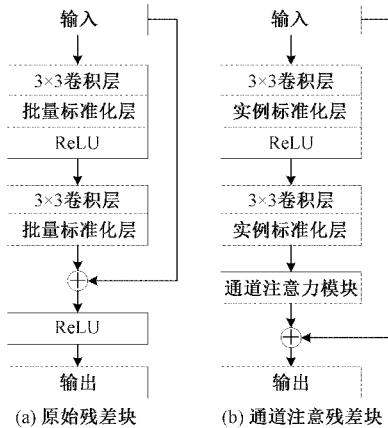


图3 原始残差块与通道注意残差块基本组成

本文对传统通道注意力<sup>[12]</sup>进行改进,重新构建通道注意力模块。文献[16]已证明全局平均池化(global average pooling, GAP)是2维离散余弦变换(2D discrete cosine transform, 2D-DCT)的一个特例,GAP与2D-DCT的最低频率分量成正比。在传统通道注意力中,仅使用GAP会丢失含大量通道信息的其他频率分量,导致特征信息利用不足。本文所设计的通道注意力模块基本组成如图4(a)所示,使用2D-DCT作为通道注意力模块的预处理操作,沿空间维度来进行特征压缩,在特征通道上响应的全局分布。

具体而言,对于输入的特征图 $F$ (通道数为 $C$ ,高度为 $H$ ,宽度为 $W$ ),首先经过2D-DCT进行预处理,融合多个频率分量,获取每个特征通道的全局特征信息。将 $F$ 按照通道

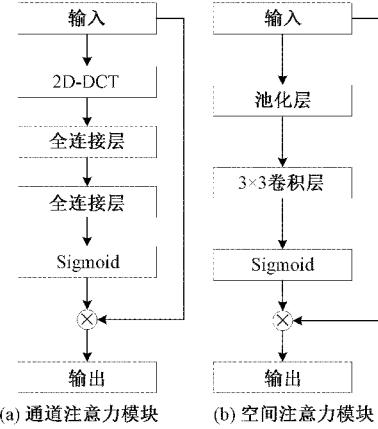


图4 通道注意力模块与空间注意力模块基本组成

维度划分为 $n$ 个部分,即 $F^i \in R^{C' \times H \times W}$  ( $i \in \{0, 1, \dots, n-1\}$ ,  $C' = C/n$ ), $n$ 必须能被 $C$ 整除,对每个部分分配相应的2D-DCT频率分量:

$$\text{Freq}^i = 2DDCT(F^i) = \sum_{h=0}^{H-1} \sum_{w=0}^{W-1} F^i_{:,h,w} B_{h,w}^{u,v} \quad (5)$$

式中: $[u, v]$ 为 $F^i$ 对应的频率分量指数, $\text{Freq}^i \in R^{C'}$ 为预处理后的 $C'$ 维向量, $B_{h,w}^{u,v}$ 为2D-DCT的基函数;本文实验中, $n$ 设置为16,能够取得更好的结果。

将预处理后的向量级联,通过第1个全连接层以降低特征维度,经过ReLU激活函数激活后,再通过第2个全连接层升回原来的维度,以更好地拟合通道间复杂的相关性,同时极大地减少了参数量和计算量。然后再经过Sigmoid激活函数,得到通道注意力channel\_att。最后,通过乘法将channel\_att逐通道加权到先前的特征 $F$ 上,完成在通道维度上对原始特征 $F$ 的重标定,得到输出特征:

$$\hat{F} = F \times \text{channel\_att} \quad (6)$$

本文使用2D-DCT代替传统通道注意力中的GAP操作,构建通道注意力模块,能够获取更多的特征信息,改善使用GAP导致特征信息利用不足的缺点。将通道注意力模块添加到原始残差块中,构成通道注意残差块,一方面降低网络特征的冗余度以提高网络特征利用率,另一方面能够对输入图像进行更全面和细致地特征提取。

## 2.2 空间注意力引导多分支掩模生成

在经过注意残差块提取图像特征的同时,网络也需要对雨滴区域的空间位置进行确定。空间注意力将输入特征图的空间信息通过空间转换,变换到另一个空间中并保留关键信息,为每个位置生成权重掩模并加权输出,以增

强特定目标区域,弱化不相关的区域<sup>[13-14]</sup>。本文引入空间注意力引导多分支掩模生成,用于突出特征图中的雨滴区域,提升雨滴区域的特征表达。

本文构建的多分支掩模生成网络结构如图 5 所示。图像内容掩模生成分支包含 1 个  $7 \times 7$  卷积层,1 个 tanh 激活函数层,引导生成多个图像内容掩模。背景注意掩模分支包含 1 个  $1 \times 1$  卷积层,输出单通道的背景特征。雨滴注意掩模生成分支包含 1 个空间注意力模块、1 个  $1 \times 1$  卷积层,输出多通道的雨滴特征。将两个注意掩模生成分支生成的特征进行拼接,然后通过 Softmax 激活函数层,引导生成背景注意掩模用于保留输入图像的背景信息,生成雨滴注意掩模关注雨滴区域。

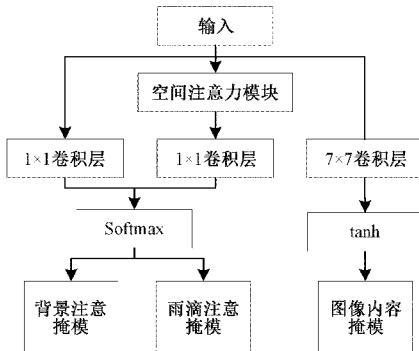


图 5 多分支掩模生成网络结构

空间注意力模块<sup>[14]</sup>的基本组成如图 4 (b)所示,首先,对输入特征图的通道进行池化操作;其次,通过  $3 \times 3$  卷积层进行特征融合;最后,使用 Sigmoid 操作来生成权重图,与原始输入特征图相乘后,使得雨滴区域得以突出。

在多分支掩模生成网络中,雨滴注意掩模表示图像内容掩模每个像素在最终输出图像中的比重,能够突出雨滴区域,而背景注意掩模则能够保留输入图像的背景信息。因此,本文所设计的多分支掩模生成网络可以同时关注雨滴区域与背景区域,从而生成更清晰的干净图像。

### 2.3 融合多分支掩模实现雨滴图像增强

经过空间注意力引导的多分支掩模生成网络后,会生成雨滴注意掩模、背景注意掩模及图像内容掩模。这些掩模跟输入的雨滴图像融合后,获得无雨滴图像。该融合过程如图 6 所示。

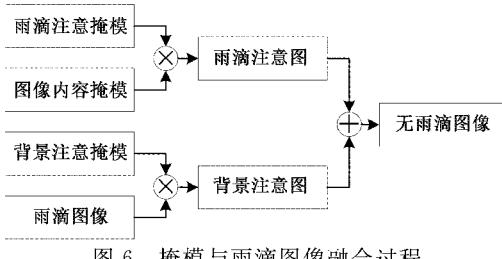


图 6 掩模与雨滴图像融合过程

图像在特征提取后,首先经过多分支掩模生成网络,通过雨滴注意掩模生成分支生成雨滴注意掩模,通过背景

注意掩模生成分支生成背景注意掩模,通过内容掩模生成分支生成多图像内容掩模。其次,雨滴注意掩模与图像内容掩模相乘生成雨滴注意图;背景注意掩模与输入的雨滴图像相乘生成背景注意图。最后,雨滴注意图同背景注意图相加后生成无雨滴图像,实现雨滴图像增强。

## 3 实验结果与分析

本文使用 Qian 等<sup>[4]</sup>公开的雨滴数据集(Raindrop)完成所有训练与测试。Raindrop 的训练集包含 861 对雨滴图像和干净图像,测试集有 test A 和 test B,分别包含 58 对对齐的图像和 249 对未完全对齐的图像。为便于模型训练与公平比较,将图像尺寸从  $720 \times 480$  缩放到  $360 \times 240$ 。使用自适应矩估计优化器来训练模型,初始学习率为 0.0002,批量训练大小为 1,总共训练 200 个 epoch。在测试阶段,将雨滴图像输入生成网络 G,即可直接输出复原图像。实验使用 NVIDIA Tesla P100 GPU,平均推理速度为 16 fps。

为验证本文方法的可行性和有效性,使用峰值信噪比(peak signal to noise ratio, PSNR)和结构相似性(structural similarity index measure, SSIM),进行量化结果对比与消融实验分析。同时,对于不同方法的结果图进行视觉效果对比,对于所提方法生成的中间注意图进行可视化展示。

### 3.1 量化结果

#### 1) 与主流方法对比

在训练样本未配对情况下,将本文方法与主流的深度学习方法进行比较,实现均来自原论文作者公开的源代码,使用 Raindrop 数据集进行训练,量化结果如表 1 所示。

表 1 与不同弱监督方法量化结果对比

方法	test A		test B	
	PSNR/dB	SSIM	PSNR/dB	SSIM
CycleGAN <sup>[6]</sup>	23.7327	0.8565	22.0053	0.8028
AGAN <sup>[17]</sup>	24.3808	0.8656	23.6914	0.8429
WSRR-GAN <sup>[10]</sup>	25.4624	0.8763	23.2445	0.8064
AttentionGAN <sup>[18]</sup>	26.5643	0.8850	24.7091	0.8597
本文方法	<b>27.0711</b>	<b>0.8996</b>	<b>24.7650</b>	<b>0.8608</b>

实验表明,本文方法在 test A 上 PSNR 达到 27.0711 dB,SSIM 达到 0.8996,在 test B 上 PSNR 达到 24.7650 dB,SSIM 达到 0.8608,均优于对比方法。特别地,与专用于雨滴图像增强的 WSRR-GAN 相比,本文方法在 test A 上 PSNR 和 SSIM 分别提升 1.6087 dB 和 0.0233,证明所提方法在雨滴图像增强任务中具有更好的性能。

#### 2) 消融实验

为验证本文方法模型各个部件设计的有效性,设计并进行了消融实验,模型推理使用 Raindrop 数据集的 test A 测试集,量化结果如表 2 所示。

表 2 消融实验

方法	PSNR/dB	SSIM
无注意力	26.564 3	0.885 0
仅通道注意力	26.888 2	0.895 3
仅空间注意力	26.701 2	0.893 7
<b>双重注意力</b>	<b>27.071 1</b>	<b>0.899 6</b>

实验表明,本文方法相比无注意力时,PSNR 提升 0.506 8 dB,SSIM 提升 0.014 6。与仅含有通道或空间注意力相比,本文方法 PSNR 和 SSIM 也均有一定提升,证明本文方法模型中各个部件设计的有效性。

### 3.2 视觉效果

#### 1) 与主流方法对比

为验证本文方法雨滴图像增强的视觉效果,将所提方法分别与弱监督学习、强监督学习的方法进行可视化比较,与弱监督学习的方法视觉效果对比如图 7 所示。从图 7 可以看出,本文方法在雨滴图像增强视觉效果更好,具有更为清晰的图像背景,而其他方法则仍有雨滴残留或留有伪影。同时,本文方法结果图与干净图像在颜色上也更加接近,更好地保留了输入图像的颜色信息。



图 7 与弱监督方法视觉效果对比,量化结果为 PSNR/SSIM

同时,将所提方法与强监督方法 Attentive GAN 进行了可视化比较,如图 8 所示。与 Attentive GAN 相比,本文方法具有更加不错的视觉效果,不仅成功地去除了雨滴,而且保留了清晰的图像背景。在第 1 列和第 2 列结果图中,本文方法雨滴图像增强效果更好,残留的伪影更少,背

景细节更加清晰,同时较好地保留了背景颜色信息,如草坪的颜色。第 3 列图像雨滴分布较为密集,雨滴去除难度较大,结果图中都含有少量伪影,但是本文方法更好地保留了雨滴图像的颜色信息,与干净图像对比颜色更相近。

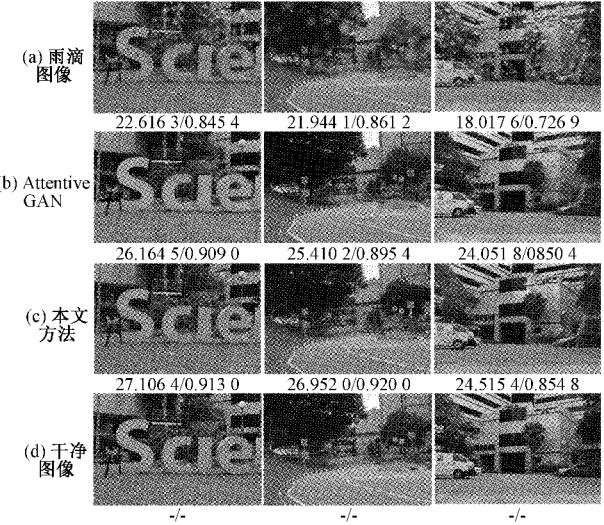


图 8 与强监督方法视觉效果对比,量化结果为 PSNR/SSIM

通过与主流方法可视化对比与分析,本文方法成功地去除了雨滴,更好地恢复了图像背景细节、保留了颜色信息。不仅在视觉效果上优于强监督方法,而且使用弱监督学习减轻了收集配对数据集的成本,提升了网络适用范围。

#### 2) 注意图可视化展示

为验证所提方法中双重注意力的有效性,本文将模型训练过程中生成的雨滴注意图和背景注意图,进行可视化展示。如图 9 所示,雨滴注意图中高亮的部分为雨滴,可

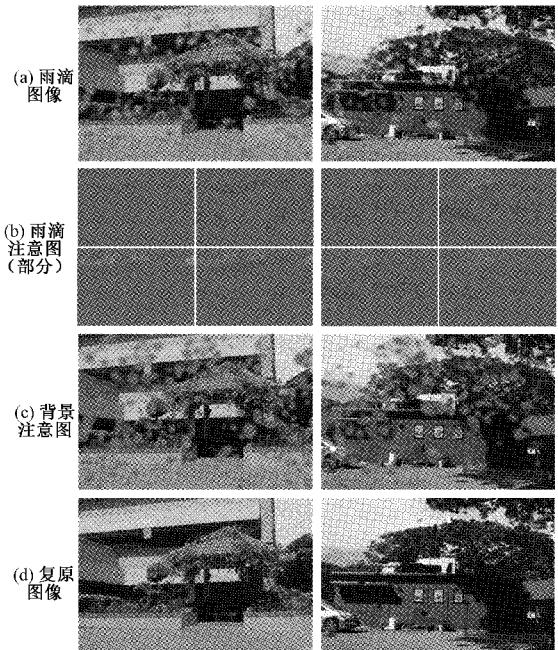


图 9 注意图可视化

可视化结果表明其很好地定位了图像中的雨滴区域;背景注意图中灰度部分为雨滴区域,其他高亮的部分为背景区域,也很好地保留了输入图像的背景区域。

从两种注意图可以看出,本文设计的双重注意力同时注意到雨滴区域和背景区域,一方面可以很好地定位雨滴区域,另一方面也可以保留背景信息,从而获得视觉效果更好的复原图像,实现雨滴图像增强。

## 4 结 论

本文提出了一种双重注意力引导的弱监督雨滴图像增强方法。该方法基于 CycleGAN 设计构建弱监督雨滴图像增强网络,有效地降低了对于配对样本数据集的依赖性;引入通道和空间双重注意力,设计通道注意残差块与多分支掩模生成网络,使得网络同时关注到雨滴和背景,在去除雨滴的同时能够保留图像背景细节信息。然而本文方法在复原雨滴分布较密集的图像时仍有少量伪影,未来可以进一步优化通道或空间注意力模块,使网络能够注意到更多所需信息,减少伪影,获得视觉效果更佳的复原图像。

## 参考文献

- [1] ALLETTO S, CARLIN C, RIGAZIO L, et al. Adherent raindrop removal with self-supervised attention maps and spatio-temporal generative adversarial networks[C]. Proc. of the IEEE/CVF International Conference on Computer Vision Workshops, 2019: 2329-2338.
- [2] WANG G, SUN C, SOWMYA A. Cascaded attention guidance network for single rainy image restoration[J]. IEEE Transactions on Image Processing, 2020, 29: 9190-9203.
- [3] EIGEN D, KRISHNAN D, FERGUS R. Restoring an image taken through a window covered with dirt or rain[C]. Proc. of the IEEE International Conference on Computer Vision, 2013: 633-640.
- [4] QIAN R, TAN R T, YANG W, et al. Attentive generative adversarial network for raindrop removal from a single image [C]. Proc. of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 2482-2491.
- [5] QUAN Y, DENG S, CHEN Y, et al. Deep learning for seeing through window with raindrops[C]. Proc. of the IEEE/CVF International Conference on Computer Vision, 2019: 2463-2471.
- [6] ZHU J Y, PARK T, ISOLA P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks [C]. Proc. of the IEEE International Conference on Computer Vision, 2017: 2223-2232.
- [7] 陈亮, 吴攀, 刘韵婷, 等. 生成对抗网络 GAN 的发展与最新应用[J]. 电子测量与仪器学报, 2020, 34(6): 70-78.
- [8] 王延年, 李文婷, 任勘. 基于生成对抗网络的单帧图像超分辨率算法[J]. 国外电子测量技术, 2020, 39(1): 26-32.
- [9] WEI Y, ZHANG Z, WANG Y, et al. DerainCycleGAN: Rain attentive CycleGAN for single image deraining and rainmaking [J]. IEEE Transactions on Image Processing, 2021, 30: 4788-4801.
- [10] LUO W, LAI J, XIE X. Weakly supervised learning for raindrop removal on a single image[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2020, 31(5): 1673-1683.
- [11] ISOLA P, ZHU J Y, ZHOU T, et al. Image-to-image translation with conditional adversarial networks[C]. Proc. of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 1125-1134.
- [12] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. Proc. of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [13] 杨梅, 贾旭, 殷浩东, 等. 基于联合注意力孪生网络目标跟踪算法[J]. 仪器仪表学报, 2021, 42(1): 127-136.
- [14] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module[C]. Proc. of the European Conference on Computer Vision (ECCV), 2018: 3-19.
- [15] HE K, ZHANG X, REN S, et al. Identity mappings in deep residual networks[C]. Proc. of the European Conference on Computer Vision (ECCV), 2016: 630-645.
- [16] QIN Z, ZHANG P, WU F, et al. Fcanet: Frequency channel attention networks[C]. Proc. of the IEEE/CVF International Conference on Computer Vision, 2021: 783-792.
- [17] TANG H, XU D, SEBE N, et al. Attention-guided generative adversarial networks for unsupervised image-to-image translation[C]. Proc. of the International Joint Conference on Neural Networks(IJCNN), 2019: 1-8.
- [18] TANG H, LIU H, XU D, et al. Attentiongan: Unpaired image-to-image translation using attention-guided generative adversarial networks [J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, DOI: 10.1109/TNNLS.2021.3105725.

## 作者简介

蒲燕虹,硕士研究生,主要研究方向为深度学习、雨滴图像增强。

E-mail: yanHong\_pu@shu.edu.cn

张金艺(通信作者),研究员,主要研究方向为人工智能、图像处理。

E-mail: zhangjinyi@shu.edu.cn

姜玉稀,工程师,博士,主要研究方向为智能图像识别、信号处理。

E-mail: jiangyuxi@sansitech.com