

特征分离和非阴影信息引导的阴影去除网络

黄颖^{1,2}, 房少杰¹, 程彬², 姜茂¹, 钱鹰¹

(1. 重庆邮电大学软件工程学院, 重庆 400065; 2. 重庆邮电大学计算机科学与技术学院, 重庆 400065)

摘要: 为了解决现有阴影去除方法中存在的性能瓶颈以及去除结果产生的色差问题, 构建了一个特征分离和非阴影信息引导的阴影去除网络 (FSNIG-ShadowNet)。在分离和重建阶段, 利用自重建监督将阴影图像分离成直射光和环境光两部分, 对光照类型和反射率进行特征解耦分离, 设计解码器对分离的特征进行重新耦合以获得无阴影图像。在细化阶段, 该网络关注阴影和非阴影的邻接区域, 设计局部区域自适应归一化模块将局部非阴影区域颜色先验传递至阴影区域以减少两区域间的色差。实验结果表明, 所提FSNIG-ShadowNet与其他优秀的方法相比取得了较有竞争力的结果。

关键词: 阴影去除; 特征分离; 自重建; 颜色先验

中图分类号: TP391

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2024099

Feature separation and non-shadow information-guided shadow removal network

HUANG Ying^{1,2}, FANG Shaojie¹, CHENG Bin², JIANG Mao¹, QIAN Ying¹

1. School of Software Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China

2. College of Computer Science and Technology, Chongqing University of Posts and Telecommunications, Chongqing 400065, China

Abstract: To tackle the performance bottlenecks and color deviation issues stemming from current shadow removal methods, a feature separation and non-shadow information guided shadow removal network (FSNIG-ShadowNet) was constructed. In the separation and reconstruction stage, the shadow image was separated into direct light and ambient light using self-reconstruction supervision, with decoupling of lighting types and reflectance. Subsequently, a decoder was employed to re-couple the separated features to yield shadow-free images. In the refinement stage, the network focused on the adjacent regions of shadow and non-shadow, incorporating a local region adaptive normalization module to transfer the color priors of local non-shadow region to shadow regions for mitigating color deviation between the two regions. Experimental results demonstrate that the proposed FSNIG-ShadowNet achieves competitive results compared to other state-of-the-art methods.

Keywords: shadow removal, feature separation, self-reconstruction, color prior

0 引言

阴影是直射光在阴影区域被遮挡而形成, 亮度和颜色会影响阴影的外观和感知。阴影可以为图像提供光照方向^[1]、场景描述^[2-3]等信息。然而图像或视频中存在的阴影不可避免地会降低下游计算机

视觉任务的性能, 如图像分解^[4]、视觉识别^[5]、目标跟踪^[6]和轨迹预测^[7]等。因此, 阴影去除作为图像预处理类问题一直被广泛研究, 但在复杂场景下去除结果的阴影区域仍然存在伪影和色差等诸多问题。目前, 阴影去除方法可以大致分为基于图像先

收稿日期: 2024-01-03; 修回日期: 2024-05-06

基金项目: 国家自然科学基金重点项目(No.62331008)

Foundation Item: The National Natural Science Foundation Key Project of China (No.62331008)

验的传统方法和基于深度学习的方法。

早期基于图像先验的传统方法依赖于物理成像模型,从图像梯度^[8-9]角度:Finlayson等^[8]绘制阴影梯度,通过识别阴影边缘,利用积分产生彩色图像以去除阴影;Liu等^[9]通过消除阴影光照变化引起的梯度,对纹理特征进行采样实现阴影去除。从图像强度^[10-12]角度:Gong等^[10]允许用户简单地标出图像中的大致阴影区域和照明区域,该方法会放大由光照变化引起的阴影边缘的强度差异,以此来计算融合图像,最后将半影区域输入归一化处理框架中以实现阴影去除;刘艳丽等^[11]利用光照和颜色空间检测阴影,计算抠取比例因子照亮阴影区域;Arbel等^[12]将阴影去除问题视为估计阴影表面形状以及纹理曲面强度重建问题。从颜色传递^[13-14]角度:Wu等^[13]通过估算阴影掩膜并计算颜色传递函数、纹理梯度和阴影平滑度来保持阴影区域中的纹理以实现阴影去除;Guo等^[14]利用匹配区域预测照明模型参数对像素进行重新照明以恢复无阴影图像。然而,由于物理模型本身过于理想化,且物理模型强调整体一致性,与实际阴影的物理性质仍然存在一定的误差,并且传统方法过度依赖图像先验,因此,传统方法在复杂场景下的阴影去除结果通常存在较大的伪影和色差问题。

近年来,随着大规模阴影去除数据集的公布^[15-16],使用深度学习进行阴影去除的方法性能超越了早期基于图像先验的传统方法,并取得了显著的成果。

特征层面。方向感知空间上下文(DSC, direction-aware spatial context)^[17]与上下文感知网络(CANet, context-aware network)^[18]通过挖掘阴影图像的上下文特征来去除阴影,其中,DSC凭借通用的网络结构能够实现阴影的检测和去除,而CANet通过计算阴影和无阴影区域匹配块,在特征空间中将非阴影区域的信息传递至阴影区域实现阴影去除。同样是利用非阴影区域特征,风格引导的阴影去除网络(SG-ShadowNet, style-guided shadow removal network)^[19]将阴影去除视为风格迁移问题,利用非阴影区域颜色先验保证了阴影去除结果整体的颜色协调性。CANet和SG-ShadowNet旨在缓解阴影去除结果中存在的色差问题,但CANet中特征转移机制的有效性依赖于相似度的匹配块,相似度低将影响阴影去除效果,SG-ShadowNet使

用的所有非阴影区域颜色先验并非会对缓解色差问题起积极作用。

模型框架层面。先进的网络能够提高阴影去除的整体性能,双射映射网络(BMNet, bijective mapping network)^[20]利用可逆框架,通过阴影生成的反向映射进行阴影去除,然而可逆框架对半影不敏感,半影较多的区域阴影去除结果中存在伪影。ShadowDiffusion^[21]通过对阴影生成的过程信息进行提取,以扩散的方式对阴影区域进行恢复,但与其他网络相比会耗费更多的采样时间。

非配对数据集训练层面。Mask-ShadowGAN和域分类引导阴影去除网络(DC-ShadowNet, domain-classifier guided shadow removal network)等^[22-25]利用生成对抗网络对未配对数据集进行训练来去除阴影的方法,在一定程度上消除了对配对数据集的依赖,避免了配对数据集存在的色差问题^[26],但由于缺乏有效的监督,结果通常存在伪影。

上述这些方法忽略了阴影形成的事实:光照和反射率决定像素值,在反射率相同或接近的情况下,阴影和非阴影的区别在于不同的光照;在光照相同或接近的情况下,阴影和非阴影的区别在于不同的反射率;在像素值相同的情况下,也会存在不同的光照和反射率的情况,因而不能直接断定同为阴影区域或者非阴影区域。上述方法要求单一的网络(或模块)同时学习直射光和环境光的复杂关系映射,由于这两类特征域的信息交织在一起,无法区分直射光和环境光,同一个网络(或模块)很难兼顾直射光和环境光的恢复。虽然Le等^[26]结合深度学习,利用简化的阴影光照模型来估计模型参数并预测阴影程度因子矩阵(Matte)以实现阴影去除,但由于提出的光照模型是线性的,而实际阴影的形成是一个非线性的过程,同时网络也并未对直射光和环境光进行区分,因此,阴影去除的性能存在瓶颈。

阴影既与非阴影相对,又不能离开非阴影而单独存在,因此非阴影区域是指导阴影区域的颜色恢复以及保证阴影区域内外颜色一致性的重要先验。Chen等^[18]和Wan等^[19]利用非阴影区域的颜色先验传递至阴影区域来保持阴影区域和非阴影区域的颜色一致性。但直接使用所有非阴影区域的颜色先验来引导阴影区域的颜色是不合理的,距离阴影区域越近的非阴影区域,颜色分布越接近,反之越

远离。

为了解决上述提到的阴影去除存在的性能瓶颈以及现有方法没有合理利用非阴影区域颜色先验导致去除结果仍存在色差等问题。将阴影图像的直射光和环境光特征进行分离,使网络更好地学习直射光和环境光的映射,从而更好地去除阴影,与此同时,采用更合理的局部非阴影颜色先验来调整阴影区域的颜色以减少其内外色差。

综上所述,本文提出了一种两阶段特征分离和非阴影信息引导的阴影去除网络(FSNIG-ShadowNet, feature separation and non-shadow information guided shadow removal network)。首先以直射光和环境光的角度对阴影图像进行特征分离,并对光照类型和反射率进行特征解耦分离,利用分离好的特征结合联合解码器进行阴影初步去除,从而更准确地进行直射光和环境光之间的映射。同时通过局部非阴影颜色先验引导模块对去除结果阴影区域的颜色进行修正,保证阴影区域映射到非阴影区域后的非阴影与原图像中非阴影之间的一致性,并生成高质量的无阴影图像。初步阶段,受传统光照模型^[27]启发,本文设计了特征分离和重建模块(SR Block, separation and reconstruction block),该模块采用特殊的非对称和参数共享的编解码器结构对阴影和无阴影图像的直射光和环境光特征分别进行映射,并利用阴影图像和无阴影图像作为自重建的监督,使解码器学习反射率参数以重建自身,使编码器能够自适应地编码直射光和环境光特征;细化阶段,网络对阴影初步去除的结果进行了细化。具体而言,网络通过对数据集中的掩膜进行形态学操作,获得阴影边界范围掩膜,让其指导网络学习阴影边界周围的映射关系,以修正阴影初步去除结果中存在的伪影。同时,网络还利用局部区域自适应归一化(LRANorm, local region adaptive normalization)修正阴影区域的均值和方差来缓解阴影初步去除结果中阴影区域和非阴影区域存在的色差问题。与其他使用非阴影区域颜色先验方法^[18-19,28]不同的是,本文使用阴影区域外围的局部非阴影像素作为颜色传递的先验,提高了颜色先验的准确性和有效性。

综上所述,本文的贡献如下。

1) 从分离直射光和环境光的角度,将阴影去除从学习阴影至无阴影的复杂映射问题转换为学习

直射光和环境光的单一映射问题。网络在分离和重建阶段使用SR Block自适应地将图像分离成直射光和环境光特征。

2) 在细化阶段使用LRANorm,在一定程度上缓解了阴影初步去除结果中存在的伪影和色差问题。

3) 将两者进行集成,本文提出了一种新颖的两阶段FSNIG-ShadowNet。本文所提方法在ISTD (dataset with image shadow triplets)、AISTD (adjusted ISTD) 和SRD (dataset for shadow removal) 3个基准数据集上进行了广泛的实验,与其他优秀的方法相比取得了较有竞争力的结果。

1 相关工作

1.1 阴影去除

早期的阴影去除方法大多基于物理光照模型,从图像梯度^[8-9]、图像强度^[10-12]和颜色传递^[13-14]等角度实现阴影去除。但由于方法大多是在理想情况下推导得出,因此在实际复杂的场景中很难达到理想的阴影去除效果。近期,由于大规模公开可用的阴影数据集的出现,基于深度学习的阴影去除方法超过了传统的物理方法,达到了优秀的阴影去除效果。Chen等^[18]挖掘阴影区域和非阴影区域的上下文信息,在特征空间中将非阴影区域的信息传递到阴影区域以实现阴影去除。吴文等^[29]利用低尺度信息并基于生成对抗网络来去除阴影,并使用自适应衰减因子恢复图像纹理细节。Liu等^[30]设计了一个亮度引导网络来补偿阴影图像亮度通道中的亮度,从而指导颜色通道中颜色的恢复。Le等^[26]利用深度学习网络估计物理光照模型线性映射参数实现阴影去除。Wan等^[19]从风格迁移的角度利用区域归一化保证了阴影区域内外颜色的一致性。传统方法和深度学习方法对比如表1所示。

但上述这些方法没有考虑到直射光被遮挡与阴影的形成高度相关,光照和反射率对于场景渲染至关重要^[31]。虽然Le等^[26]从光照模型角度对阴影进行建模,使用简化的光照模型,利用网络学习阴影图像至无阴影图像的线性变换参数来去除阴影。但该方法本身并没有对直射光和环境光进行区分,而是同质化的学习直射光和环境光的复杂映射,导致网络无法有效学习直射光和环境光的差异,如何区分直射光和环境光并使其有效分离是目前存在的主要问题。针对这一问题,本文设计出特征分离和重

表1 传统方法和深度学习方法对比

| 类别 | 主要方法 | 主要思路 | 分离环境光和直射光 | 先验 | 阴影边界处理 | 色差处理 |
|------------|------------------------|--------------|-----------|----|------------|---------|
| 传统方法 | Liu等 ^[9] | 梯度(泊松方程) | 否 | 手工 | 手工标注 | — |
| | Arbel等 ^[12] | 强度(估计阴影比例因子) | 否 | 手工 | 边界平滑 | — |
| | Guo等 ^[14] | 颜色传递(估计阴影系数) | 否 | 自动 | 边界平滑 | — |
| 深度学习 方法 | Chen等 ^[18] | 上下文信息 | 否 | 自动 | — | 上下文特征转移 |
| | 吴文等 ^[29] | 生成对抗 | 否 | 自动 | 阴影邻域指导条件映射 | — |
| | Liu等 ^[30] | 亮度引导 | 否 | 自动 | — | — |
| | Le等 ^[26] | 估计光照模型参数 | 否 | — | 阴影Matte | — |
| | Wan等 ^[19] | 风格迁移 | 否 | 自动 | — | 区域归一化 |
| | FSNIG-ShadowNet(本文) | 特征分离和颜色传递 | 是 | 自动 | 阴影邻域指导条件映射 | 区域归一化 |

建模块,能自适应地实现对直射光和环境光的分离,将复杂映射问题转化为单一映射问题,最大限度地提高了网络阴影去除性能。

1.2 区域归一化

特征归一化层能够加速网络收敛、提升模型的泛化能力。在之前的工作中,网络训练主要使用的是批量归一化^[32](BN, batch normalization)、实例归一化^[33](IN, instance normalization)和层归一化^[34](LN, layer normalization)等方法。但上述归一化方法没有考虑到图像不同区域对归一化的影响,由于图像不同区域会引起均值和方差的差异,上述方法在划分不同区域的任务下性能有限,均值和方差会产生偏移。

Yu等^[35]首次提出区域归一化并将其应用于图像修复任务中。区域归一化可以有效解决低级计算机视觉任务中均值和方差产生偏移的问题,近年来在具有区域划分的任务中得到了广泛研究^[19,28,35-36]。在图像修复任务中,Yu等^[35]将图像划分为损坏区域和未损坏区域,对两区域分别进行归一化,利用未损坏区域指导损坏区域的修复;在图像合成任务中,Ling等^[36]将合成图像划分为前景和背景,将背景的风格自适应地应用至前景,保证图像整体风格的一致性。

阴影去除任务也具有区域的划分,即阴影区域和非阴影区域。近期,区域归一化也陆续应用于阴影去除任务中^[19,28],这些方法通过将所有非阴影区域的颜色先验传递至阴影区域,利用非阴影区域的均值和方差指导阴影区域颜色的恢复。但非阴影区域中可能存在与阴影区域不同的背景,所有非阴影区域与实际无阴影图像的阴影区域的均值和方差存在较大偏移,因此,使用所有非阴影区域的颜色

先验会对阴影区域的颜色恢复做出错误指导。而阴影区域外围局部非阴影区域的均值和方差更加接近于实际无阴影图像的阴影区域。针对这一问题,本文将采用阴影区域外围局部非阴影区域的颜色先验来恢复阴影区域的颜色。

2 提出的方法

2.1 整体架构

现有的阴影去除方法往往缺少从光照模型的角度分析阴影形成的原因,忽略了阴影的形成与直射光被遮挡高度相关,网络没有有效地区分直射光和环境光,导致网络在去除过程中,无法对混杂在一起的直射光和环境光特征做统一处理。同时,现有利用非阴影区域引导阴影区域颜色恢复的方法在一些场景中会引入错误的颜色信息。为解决上述问题,本文提出了FSNIG-ShadowNet,架构如图1所示。FSNIG-ShadowNet架构与近些年使用生成对抗网络的方法类似^[29,37]。网络整体通过训练生成器和鉴别器对阴影去除结果的分布进行约束,其中阴影图像经过生成器的2个阶段最终生成无阴影图像。

在初步阶段,阴影图像 I_S 和无阴影图像 I_{SF} 作为网络输入,与阴影掩膜 M 通道叠加一同输入SR Block,分离图像的直射光、环境光以及环境光衰减量等特征。其中成对的阴影图像与无阴影图像作为特征分离的约束能够指导编码器自适应地学习特征分离的参数。SR Block输出得到分离后的环境光衰减量特征 F_a^S 和环境光特征 F_e^S ,两特征经过阴影去除解码器 J_{S2SF} 解码获得粗糙的无阴影图像 I_C ,其中解码器 J_{S2SF} 是基于U-Net上采样部分设计的。上述流程可以表示为

$$(F_a^S, F_e^S) = \text{SR}(\text{Concat}[I_S, M], \text{Concat}[I_{SF}, M]) \quad (1)$$

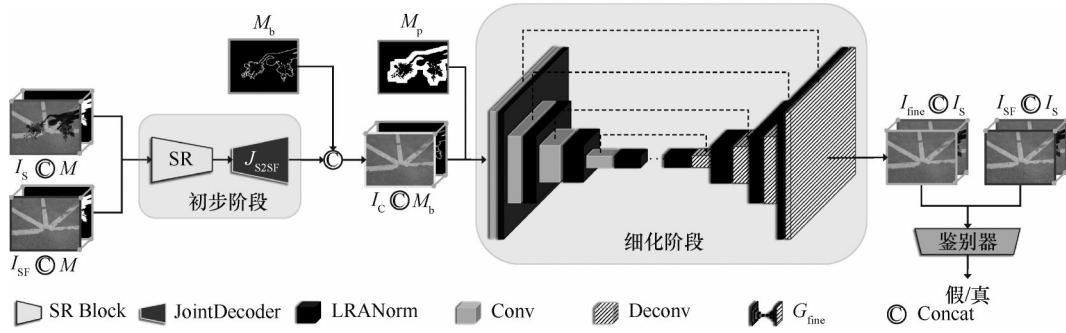


图1 FSNIQ-ShadowNet架构

$$I_c = J_{S2SF}(F_a^S, F_c^S) \quad (2)$$

其中，Concat表示通道叠加， M 表示阴影掩膜，SR表示SR Block。SR Block用于分离阴影图像和无阴影图像的直射光和环境光特征，详细内容将在2.2节介绍。

在细化阶段，网络对阴影初步去除结果 I_c 存在的伪影和色差问题进行修复。伪影的形成是由于阴影掩膜不能准确地描述阴影边缘处的细节。如图2所示，为了专注于阴影边缘伪影的修复，通过膨胀的方式获得阴影区域边界掩膜 M_b 。同时，为了利用局部非阴影区域先验指导阴影区域颜色的恢复，也使用膨胀的方式获取局部非阴影区域先验掩膜 M_p 。

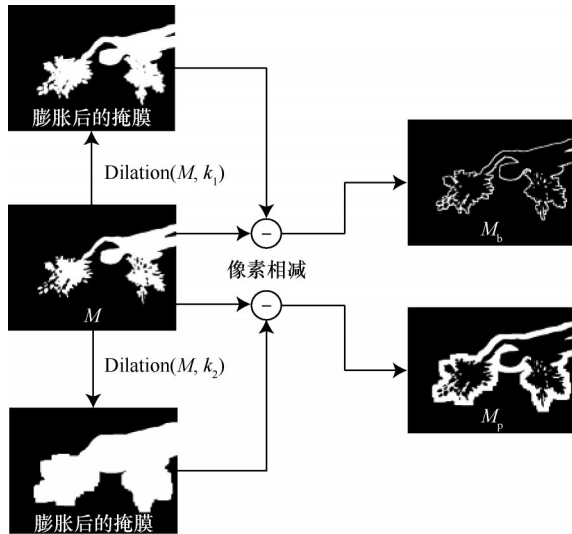


图2 通过形态学操作生成阴影区域边界掩膜 M_b 和非阴影区域先验掩膜 M_p

$$M_b = \text{Dilation}(M, k_1) - M \quad (3)$$

$$M_p = \text{Dilation}(M, k_2) - M \quad (4)$$

其中， M_b 表示阴影区域边界掩膜， M_p 表示局部非阴影区域先验掩膜，Dilation表示膨胀函数， k_1 和 k_2 表示形态学操作卷积核大小，即膨胀系数。

接下来，将阴影初步去除结果 I_c 与阴影区域边

界掩膜 M_b 通道叠加输入细化生成器中，该生成器除了使用Wang等^[16]的生成器结构外，还嵌入了LRANorm，通过多尺度的方式指导阴影区域进行颜色恢复。上述流程可以表示为

$$I_{\text{fine}} = G_{\text{fine}}(\text{Concat}[I_c, M_b], M_p) \quad (5)$$

其中， G_{fine} 表示细化生成器， I_{fine} 表示细化的无阴影图像。

鉴别器直接使用Wang等^[16]设计的鉴别器对生成器生成的无阴影图像进行判别。

2.2 特征分离和重建模块

受传统光照模型^[27]启发，在波长 λ 下，无阴影图像在三原色（RGB, red green blue）空间的像素 i 的反射强度可以表示为

$$I_i^{\text{SF}}(\lambda) = L_i^c(\lambda)R_i(\lambda) + L_i^d(\lambda)R_i(\lambda) \quad (6)$$

其中， $I_i^{\text{SF}}(\lambda)$ 表示像素 i 的反射强度， $L_i^c(\lambda)$ 和 $L_i^d(\lambda)$ 分别表示环境光和直射光， $R_i(\lambda)$ 表示反射率。

当直射光被遮挡时，由于缺少了直射光和部分环境光，遮挡区域形成了阴影，在波长 λ 下，阴影区域中像素 i 的反射强度可以表示为

$$I_i^S(\lambda) = a_i(\lambda)L_i^c(\lambda)R_i(\lambda) \quad (7)$$

其中， $a_i(\lambda)$ 表示在像素 i 处环境光的衰减因子。

将式(6)和式(7)进行变形，得到

$$I_i^{\text{SF}}(\lambda) = R_i(\lambda)(L_i^c(\lambda) + L_i^d(\lambda)) \quad (8)$$

$$I_i^S(\lambda) = R_i(\lambda)(L_i^c(\lambda) + (a_i(\lambda) - 1)L_i^c(\lambda)) \quad (9)$$

为了合理地区分环境光和直射光，本文将利用神经网络来模拟式(8)和式(9)的过程，通过训练3个编码器分别编码环境光 $L_i^c(\lambda)$ 、直射光 $L_i^d(\lambda)$ 和环境光衰减量 $(a_i(\lambda) - 1)L_i^c(\lambda)$ ，并训练单独的解码器模拟反射率 $R_i(\lambda)$ 的影响。

本文设计了特征分离和重建模块来模拟上述过程，如图3所示。该模块采用非对称和参数共享的编解码器结构，编码器和解码器分别使用的是Wang等^[16]的生成器的下采样和上采样结构。对于

给定的阴影图像和无阴影图像,能利用自重建监督自适应地将其分离成环境光和直射光(环境光衰减量)。具体来说,该模块共享参数的编码器 E_C 编码阴影图像和无阴影图像的环境光特征,使用2个独立的编码器 E_S 和编码器 E_{SF} 分别编码环境光衰减量特征和直射光特征,并利用联合解码器 J_{SR} 学习反射率参数,对编码得到的特征进行解码实现自重建。上述流程可以表示为




图3 特征分离和重建模块

$$F_a^S = E_S(I_S), F_c^S = E_C(I_S) \quad (10)$$

$$F_d^{SF} = E_{SF}(I_{SF}), F_c^{SF} = E_C(I_{SF}) \quad (11)$$

$$\tilde{I}_S = J_{SR}(F_c^S + F_a^S) \quad (12)$$

$$\tilde{I}_{SF} = J_{SR}(F_c^{SF} + F_d^{SF}) \quad (13)$$

其中, \tilde{I}_S 和 \tilde{I}_{SF} 分别表示自重建得到的阴影图像和无阴影图像。 F_c^S 和 F_c^{SF} 分别对应式(8)和式(9)中的 $L_i^c(\lambda)$, 用于编码无阴影图像和阴影图像的环境光特征。 F_d^{SF} 对应式(8)中的 $L_i^d(\lambda)$, 用于编码无阴影图像的直射光特征, F_a^S 对应式(9)中的 $(a_i(\lambda) - 1)L_i^c(\lambda)$, 用于编码环境光衰减量特征。分离后的特征 F_a^S 和 F_c^S 后续被输入阴影去除解码器 J_{S2SF} 中获得无阴影图像 I_C , 过程如式(2)所示。

在自重建过程中,由于环境光特征同时被共享特征编码器 E_C 编码,编码的特征是相似的,阴影图像和无阴影图像的环境光特征分别与其直射光特征和环境光衰减量特征叠加至联合解码器 J_{SR} 解码以重建阴影图像和无阴影图像。在这个过程中,联合解码器 J_{SR} 自适应地学习得到反射率参数,将环境光和直射光特征进行自适应地分离。

2.3 局部区域自适应归一化模块

非阴影区域可以为阴影区域提供丰富的颜色先验,现有的方法利用所有非阴影区域颜色先验来保证阴影区域与其颜色一致性。但使用所有非阴影区域的颜色先验是不合理的,距离阴影区域越近的非阴影区域与实际无阴影图像对应的阴影区域颜色分

布越接近,反之越远离。

为保证阴影去除的颜色一致性,通常根据非阴影区域的均值和方差来约束,本文对 ISTD^[16] 数据集中图像各个区域的均值和方差进行统计,各区域的范围说明如图4所示,其中, $R_{SF,S}$ 表示无阴影图像中与阴影图像对应的阴影区域, $R_{S,SF}$ 表示阴影图像中所有非阴影区域, $R_{S,LSF}$ 表示阴影图像中的局部非阴影区域。合理的先验需要保证其与 $R_{SF,S}$ 的均值和方差分布近似。如图5所示,观察到 $R_{S,SF}$ 与 $R_{SF,S}$ 的均值和方差存在显著差异,而 $R_{S,LSF}$ 与 $R_{SF,S}$ 的均值和方差分布更为相近,这验证了使用局部非阴影区域 $R_{S,LSF}$ 作为先验的优势。




图4 3种计算均值和方差区域的范围说明




图5 不同区域范围内图像均值和方差分布

与此同时,为了确定局部非阴影区域的范围,本文逐一增加掩膜膨胀系数 k_2 , 计算 $R_{SF,S}$ 分别与 $R_{S,SF}$ 、 $R_{S,LSF}$ 的均值和方差的距离均值,并将其进行可视化,均值和方差的距离均值分别表示为

$$D_{S_{SF|S}_{LSF}}^{\text{mean}} = \text{Mean} \left(\sum_{i=1}^n |R_{SF,S}^{\text{mean}} - R_{S_{SF|S}_{LSF}}^{\text{mean}}| \right) \quad (14)$$

$$D_{S_{SF|S}_{LSF}}^{\text{std}} = \text{Mean} \left(\sum_{i=1}^n |R_{SF,S}^{\text{std}} - R_{S_{SF|S}_{LSF}}^{\text{std}}| \right) \quad (15)$$

其中, Mean 表示平均操作, n 表示 ISTD 数据集图像个数, D^{mean} 和 D^{std} 分别表示 $R_{SF,S}$ 和 $R_{S,SF}$ 、 $R_{SF,S}$ 和 $R_{S,LSF}$ 的均值和方差的距离均值, R^{mean} 和 R^{std} 分别表

示图像特定区域内像素的均值和方差。如图 6 所示, 以 R_{S_SF} 作为对照组, 在掩膜膨胀的过程中, 最初距离均值较大, 当膨胀系数 $k_2 = 4$ 时, 距离均值最小, 之后随着掩膜膨胀程度不断加深, R_{SF_S} 和 R_{S_SF} 的距离均值逐渐接近。




图 6 不同膨胀系数 R_{SF_S} 分别与 R_{S_SF} 和 R_{S_LSF} 均值和方差的距离均值

由于阴影区域像素均值和方差与整幅图像相比存在较大偏移, 常规的 BN 只能确保特征输入输出间整体分布的一致性, 并不能对两区域间特征进行约束, 因此使用 BN 来重建优质的无阴影图像比较困难。为了解决这个问题, 本文提出了 LRANorm 模块来缓解去除结果阴影区域与非阴影区域存在的色差, 它通过合理利用非阴影区域颜色先验自适应地学习阴影区域的均值和方差, 大致保证了 2 个区域颜色分布的一致性, 进而缓解色差问题。

LRANorm 模块的整体流程如图 7 所示。首先, 将卷积层输出的中间特征 F_{in} 输入一个 3×3 的卷积层中, 在阴影掩膜 M 的引导下, 输出的特征被划分为阴影区域和非阴影区域 2 个部分。

$$F_S = \text{Conv}_3(F_{in}) \otimes M \quad (16)$$

$$F_{SF} = \text{Conv}_3(F_{in}) \otimes (1 - M) \quad (17)$$

其中, F_S 表示阴影区域特征, F_{SF} 表示非阴影区域特征, Conv_3 表示 3×3 的卷积层, \otimes 表示像素相乘。

然后, 对阴影区域特征 F_S 和非阴影区域特征 F_{SF} 进行区域归一化^[35], 归一化过程分别表示为

$$F_S^{\text{Norm}} = \frac{F_S \otimes M - \mu_S}{\sqrt{\delta_S^2 + \varepsilon}} \quad (18)$$

$$F_{SF}^{\text{Norm}} = \frac{F_{SF} \otimes (1 - M) - \mu_{SF}}{\sqrt{\delta_{SF}^2 + \varepsilon}} \quad (19)$$

$$F_S^{\text{Norm}} = F_S^{\text{Norm}} + F_{SF}^{\text{Norm}} \quad (20)$$

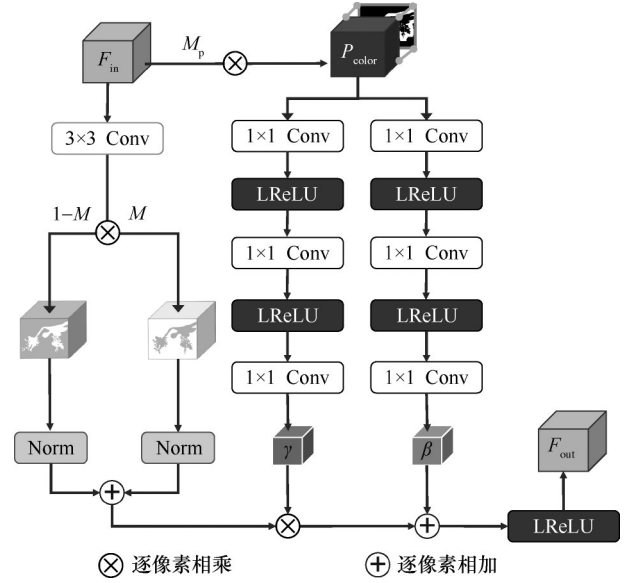


图 7 LRANorm 模块的整体流程

其中, F_S^{Norm} 和 F_{SF}^{Norm} 分别表示阴影区域和非阴影区域归一化之后的特征, F^{Norm} 表示区域归一化后的结果, M 表示阴影掩膜, μ_S 和 δ_S^2 分别表示特征阴影区域通道的均值和方差, μ_{SF} 和 δ_{SF}^2 分别表示特征非阴影区域通道的均值和方差。为防止式(18)和式(19)中分母为 0, 将 ε 设置为 1×10^{-5} 。

局部非阴影区域先验 P_{color} 由卷积层输出的中间特征 F_{in} 与局部非阴影区域先验掩膜 M_p 相乘获得。与使用所有非阴影区域先验的方法相比, 由于获取的是阴影区域外围局部的颜色先验, 在一定程度上减小了颜色分布误差和计算负荷。之后, 将 P_{color} 与 M_p 通道叠加分别输入 2 个结构相同的卷积模块以学习仿射参数 γ 和 β , 该模块由 3 个 1×1 卷积层和 2 个 LeakyReLU^[38] 函数组成, 生成的 γ 和 β 通过对 F^{Norm} 做仿射变换, 经过 LeakyReLU 得到最后的特征输出 F_{out} , 上述流程可以表示为

$$P_{\text{color}} = F_{in} \otimes M_p \quad (21)$$

$$\gamma = \text{Conv}_1(\text{LReLU}(\text{Conv}_1(\text{Concat}[P_{\text{color}}, M_p])))_{\times 2} \quad (22)$$

$$\beta = \text{Conv}_1(\text{LReLU}(\text{Conv}_1(\text{Concat}[P_{\text{color}}, M_p])))_{\times 2} \quad (23)$$

$$F_{\text{out}} = \text{LReLU}(\gamma \otimes F^{\text{Norm}} + \beta) \quad (24)$$

其中, Conv_1 表示 1×1 的卷积层, LReLU 表示 LeakyReLU 函数。

2.4 损失函数

为了更好地拟合网络参数, FSNIG-ShadowNet 通过总损失函数 L 进行约束, 总损失函数包含以下

4个部分: 自重建损失 L_{SR} 、粗糙损失 L_{coarse} 、细化损失 L_{fine} 和生成对抗损失 L_{adv} 。总损失函数 L 可以表示为

$$L = \lambda_1 L_{SR} + \lambda_2 L_{coarse} + \lambda_3 L_{fine} + \lambda_4 L_{adv} \quad (25)$$

其中, $\lambda_1 \sim \lambda_4$ 是损失函数的超参数, 本文参考文献[16]并根据其经验将上述超参数分别设置为10、10、10和0.1。各类损失函数描述如下。

1) 自重建损失

在SR Block中, 自重建损失通过优化自重建解码器输出与两输入之间的L1距离, 促使不同编码器编码不同的特征, 可以表示为

$$L_{SR} = \|\tilde{I}_S - I_S\|_1 + \|\tilde{I}_{SF} - I_{SF}\|_1 \quad (26)$$

2) 粗糙损失

在初步阶段, 粗糙损失用于优化初步阴影去除结果与真实无阴影图像之间的L1距离, 可以表示为

$$L_{coarse} = \|I_C - I_{SF}\|_1 \quad (27)$$

3) 细化损失

在细化阶段, 细化损失用于优化细化结果与真实无阴影图像之间的L1距离, 可以表示为

$$L_{fine} = \|I_{fine} - I_{SF}\|_1 \quad (28)$$

4) 生成对抗损失

将阴影图像 I_S 分别与阴影去除结果 I_{fine} 和实际无阴影图像 I_{SF} 组成图像对。将图像对分别输入鉴别器 D 进行判别, 将含有阴影去除结果的图像对判别为假, 将含有真实无阴影图像的图像对判别为真。在对抗训练的过程中, 促使生成器生成更加真实的无阴影图像。生成对抗损失可以表示为

$$L_{adv} = E_{(I_S, I_{SF}, I_{fine})} [(\log(D(I_S, I_{SF}))) + \log(1 - D(I_S, I_{fine}))] \quad (29)$$

3 实验

3.1 实验设置

3.1.1 数据集

本文在3个具有代表性的阴影去除数据集ISTD、AISTD和SRD上训练和评估FSNIG-ShadowNet, 并在Vicente等[39]和Zhu等[40]公开的阴影检测数据集上验证FSNIG-ShadowNet的泛化性能。ISTD和AISTD数据集总共包含1870个阴影、阴影掩膜和无阴影图像的三元组, 其中1330个三元组用于训练, 其余540个用于测试。由于ISTD数据集中阴影和无阴影图像的非阴影区域存

在较大色差, Le等[26]将其无阴影图像进行色彩调整, 得到AISTD数据集。SRD数据集包含2680个训练对和408个测试对, 由于没有真实的阴影掩膜, 本文使用由双层次聚合网络(DHAN, dual hierarchical aggregation network)[41]生成的公共阴影掩膜进行训练和测试。在评估泛化性能的实验中, 本文采用了2个阴影检测数据集进行测试, 选用Vicente等[39]提供的638个测试数据集以及Zhu等[40]提供的110个测试数据集对网络泛化性能进行评估。

3.1.2 评价指标

在Lab空间中通过计算网络生成的结果和真实图像之间的均方根误差(RMSE, root mean squared error)来评估模型的性能, RMSE值越低越好。需要说明的是, RMSE是根据阴影和非阴影区域所有图像的所有像素计算均值得出。此外, 本文还通过计算RGB颜色空间中的峰值信噪比(PSNR, peak signal-to-noise ratio)和结构相似度(SSIM, structure similarity index measure)来评估本文方法的阴影去除效果, PSNR和SSIM值越高越好。

3.1.3 实施细节

本文提出的FSNIG-ShadowNet通过PyTorch实现, 并在“RTX2080Ti GPU”上进行训练和评估。对于掩膜的膨胀系数, k_1 设置为9, k_2 设置为4。在训练过程中, 对于ISTD、AISTD和SRD数据集, 将图像的尺寸缩放至286, 并将其随机裁剪为256, 批量大小设置为4, 迭代轮次设置为2000。对于这3个数据集, 都采用了初始学习率为0.0002的Adam优化器, 并使用ReduceLRonPlateau策略对学习率进行衰减。

3.2 定量评价

表2~表4展示了FSNIG-ShadowNet在ISTD、AISTD和SRD数据集上的阴影去除定量比较结果, 并将FSNIG-ShadowNet与最先进的阴影去除方法进行比较, 包括DSC[17]、DHAN[41]、自动曝光(Auto-Exposure)[42]、SG-ShadowNet[19]、BMNet[20]、清洁导航阴影网络(CNSNet, cleanness-navigated-shadow network)[28]和ShadowDiffusion[21]。为了公平比较, 表2~表4中的数据均使用作者提供的阴影去除结果, 并由Liu等[24]提供的测试指标代码计算得出; 对于作者没有提供阴影去除结果的方法, 直接引用作者原文的数据, 并用“*”进行标注。

表 2 ISTD 数据集上 FSNIG-ShadowNet 与其他方法的定量比较

| 方法 | RMSE | | | PSNR/dB | | | SSIM | | |
|---------------------------------|-------------|-------------|-------------|--------------|--------------|--------------|--------------|--------------|--------------|
| | All | NS | S | All | NS | S | All | NS | S |
| 输入图像 | 10.88 | 7.09 | 32.10 | 20.56 | 27.32 | 22.40 | 0.893 | 0.976 | 0.936 |
| DSC ^[17] | 5.59 | 5.04 | 8.72 | 29.00 | 31.26 | 34.64 | 0.944 | 0.969 | 0.984 |
| DHAN ^[41] | 5.66 | 5.30 | 7.49 | 29.11 | 31.05 | 35.53 | 0.954 | 0.971 | 0.988 |
| Auto-Exposure ^[42] | 5.89 | 5.51 | 7.91 | 27.19 | 28.61 | 34.71 | 0.846 | 0.880 | 0.975 |
| BMNet ^[20] | 5.02 | 4.59 | 7.60 | 30.28 | 32.80 | 35.61 | 0.959 | 0.976 | 0.988 |
| CNSNet* ^[28] | 4.61 | 4.23 | <u>6.56</u> | 30.29 | 32.15 | <u>36.67</u> | 0.965 | 0.979 | 0.991 |
| ShadowDiffusion ^[21] | 4.32 | 3.97 | 6.12 | 31.57 | 33.46 | 37.67 | 0.957 | 0.973 | <u>0.989</u> |
| FSNIG-ShadowNet(本文) | <u>4.57</u> | <u>4.15</u> | 6.75 | <u>30.67</u> | <u>33.21</u> | 36.46 | <u>0.963</u> | <u>0.978</u> | <u>0.989</u> |

表 3 SRD 数据集上 FSNIG-ShadowNet 与其他方法的定量比较

| 方法 | RMSE | | | PSNR/dB | | | SSIM | | |
|---------------------------------|-------------|-------------|-------------|--------------|--------------|--------------|--------------|--------------|--------------|
| | All | NS | S | All | NS | S | All | NS | S |
| 输入图像 | 13.83 | 4.54 | 36.62 | 18.26 | 31.68 | 18.98 | 0.837 | 0.981 | 0.872 |
| DSC ^[17] | 5.00 | 3.61 | 8.60 | 29.89 | 34.94 | 32.20 | 0.943 | 0.985 | 0.969 |
| DHAN ^[41] | 4.61 | 3.63 | 6.94 | 30.74 | 35.06 | 33.84 | 0.958 | 0.985 | 0.980 |
| Auto-Exposure ^[42] | 6.25 | 5.48 | 8.33 | 27.97 | 30.84 | 32.44 | 0.902 | 0.950 | 0.968 |
| SG-ShadowNet ^[19] | 4.23 | 3.20 | 6.83 | 31.39 | 36.43 | 33.88 | 0.960 | 0.988 | 0.981 |
| BMNet ^[20] | 4.18 | 3.32 | 6.37 | 31.97 | 36.35 | 35.26 | 0.965 | 0.989 | 0.984 |
| CNSNet* ^[28] | 4.29 | 3.29 | 6.92 | 31.69 | 35.69 | 35.10 | — | — | — |
| ShadowDiffusion ^[21] | 3.74 | <u>3.18</u> | 5.09 | 33.46 | 37.03 | 37.10 | 0.965 | 0.986 | 0.984 |
| FSNIG-ShadowNet(本文) | <u>4.02</u> | 3.08 | <u>6.13</u> | <u>32.29</u> | <u>36.85</u> | <u>35.53</u> | 0.965 | 0.989 | 0.984 |

表 4 AISTD 数据集上 FSNIG-ShadowNet 与其他方法的定量比较

| 方法 | RMSE | | |
|---------------------------------|-------------|-------------|-------------|
| | All | NS | S |
| 输入图像 | 8.40 | 2.42 | 36.95 |
| DSC ^[17] | 3.77 | 3.04 | 7.49 |
| Auto-Exposure ^[42] | 4.23 | 3.77 | 6.55 |
| SG-ShadowNet ^[19] | 3.41 | 2.92 | 5.93 |
| BMNet ^[20] | 2.97 | <u>2.45</u> | 5.62 |
| CNSNet* ^[28] | 2.98 | 2.47 | 5.60 |
| ShadowDiffusion ^[21] | <u>2.90</u> | 2.46 | 5.18 |
| FSNIG-ShadowNet(本文) | 2.86 | 2.34 | <u>5.53</u> |

表 2~表 4 中, All 表示整幅图像, NS 表示无阴影区域, S 表示阴影区域, 第 1 行(输入图像)显示了阴影图像与真值之间的 RMSE、PSNR 和 SSIM 值, 加粗字体表示每列最优结果, 带下划线字体表示每列次优结果。由于篇幅限制, AISTD 数据集仅展示 RMSE 的比较结果。表 2~表 4 中的结果表明, 在 ISTD 和 SRD 数据集上, FSNIG-ShadowNet 性能仅次于 ShadowDiffusion, 然而, ShadowDiffusion 存在采样耗时的问题, 导致阴影去除结果需要花费更多的时间。在 AISTD 数据集上, FSNIG-ShadowNet 基本取得了最佳的性能。与 BMNet 相比, FSNIG-ShadowNet 在 ISTD 数据集上对于整幅图像、阴影区域和无阴影区域, RMSE 分别降低了

0.45、0.44 和 0.85, PSNR 分别提高了 0.39 dB、0.41 dB 和 0.85 dB; 在 SRD 数据集上 RMSE 分别降低了 0.16、0.24 和 0.24, PSNR 分别提高了 0.32 dB、0.5 dB 和 0.27 dB, SSIM 与其持平。在 AISTD 数据集上, RMSE 分别降低了 0.11、0.11 和 0.09。FSNIG-ShadowNet 在这 3 个数据集上无论是对整幅图像, 还是对阴影区域和无阴影区域, 与其他优秀的方法相比均取得了较有竞争力的阴影去除性能。

3.3 定性评价

为了更直观地展示 FSNIG-ShadowNet 的阴影去除性能, 图 8 展示了在 AISTD 和 SRD 数据集上最先进的方法和本文方法的可视化比较结果。在绝大多数场景下, ShadowDiffusion 能表现出与本文方法相媲美的性能。但在第 5 行的场景中, ShadowDiffusion 不仅没有彻底去除阴影, 反而将非阴影区域进行错误提亮。同时, ShadowDiffusion 的阴影去除效果还受输入阴影图像分辨率的影响, 可视化结果如图 9 所示, 当以 256×256 分辨率作为输入时, 阴影能得到有效去除, 当使用 640×480 原图分辨率作为输入时, 模型性能急剧下降, 输出结果仍具有较多的阴影残留。反观本文方法对输入图像的尺寸不敏感, 仍然具有稳定的阴影去除性能。在图 8 中对于除 ShadowDiffusion 外的其他方法, 在第




图 8 在 AISTD 和 SRD 数据集上最先进的方法和本文方法的可视化比较结果

1 行的场景中, 阴影区域内外均存在色差, 虽然 SG-ShadowNet 通过引入所有非阴影信息来指导阴影区域的颜色恢复, 但在这个过程中错误引入了左上角的红色区域信息, 使阴影区域整体偏黄。对于第 2 行的场景, 其他方法均存在明显的边界伪影。由于 FSNIG-ShadowNet 考虑到环境光和直射光对于阴影去除结果的影响, 通过对两者进行分离, 同时利用局部非阴影区域信息, 避免引入非阴影区域过多的错误信息, 在显著提高网络性能的同时, 能够减少边界伪影和保证阴影区域内的颜色一致性。

3.4 消融实验

本节将从模块有效性、非阴影区域先验范围这两个方面对 FSNIG-ShadowNet 的各类变体进行评估, 并在 AISTD 数据集上进行消融实验, 以验证 FSNIG-ShadowNet 设计的有效性。




图 9 在 256×256 和 640×480 原图分辨率下本文方法与 ShadowDiffusion 的可视化比较

3.4.1 模块有效性分析

为了验证本文设计的 SR Block 和 LRANorm 模块的有效性, 本文设计了 3 组消融实验。1) 单独对 SR Block 进行替换, 将其替换成 Wang 等^[16]的生成器的下采样部分。2) 单独对 LRANorm 模块进行替换, 将其替换成其他归一化层, 即 BN^[32]、RN (region normalization)^[35]、RAIN (region-aware adaptive instance normalization)^[36]、SRPNorm (spatially region-aware prototypical normalization)^[19]和 SOAN

(shadow-oriented adaptive normalization) [28]。3) 对 SR Block 和 LRANorm 模块同时进行替换并作为对照组, 其中将 SR Block 替换成 Wang 等[16]的生成器的下采样部分, 将 LRANorm 替换成 BN。

模块有效性的消融研究结果如表 5 所示, 其中, w/o 表示没有使用该模块, w/表示使用该模块。结果显示, 对照组阴影去除性能最差。同时, 单独使用 SR Block 和 LRANorm 模块的变体后, 模型的性能均存在不同程度的降低, 具体来说, 将 SR Block 替换后, 网络无法对光照进行有效分离, 使网络性能存在瓶颈, 非阴影区域性能下降。将 LRANorm 替换后, 由于 BN 并不是根据区域划分来设计的, 并且 RN 和 RAIN 会导致阴影区域和非阴影区域信息交互异常[19], 两者的性能会受到相互影响。而 SRPNorm 通过 2 次仿射变换间接地将非阴影区域风格传递至阴影区域, 没有充分利用非阴影区域先验信息。SOAN 在仅使用阴影掩膜作为先验信息的情况下, 直接使用非阴影区域的均值和方差对阴影区域做仿射变换, 没有动态地利用先验信息学习仿射参数, 导致网络性能下降。与其他归一化的方法相比, LRANorm 获得了最佳的阴影去除性能。此外, 本文方法还展示了部分消融实验变体的可视化比较, 如图 10 所示。w/o LRANorm 使用 BN 进行替换, 当网络没有进行特征分离和利用局部非阴影区域先验时, 阴影区域边界存在伪影, 同时阴影区域的内外也存在明显色差。

表 5 模块有效性的消融研究结果

| 模块 | 类别 | RMSE | | |
|---------------------|-------------|-------------|-------------|-------------|
| | | All | NS | S |
| w/o all | 均替换 | 3.08 | 2.49 | 6.08 |
| w/o SR Block | 替换 SR Block | 2.95 | 2.43 | 5.60 |
| w/ BN[32] | | 3.01 | 2.43 | 5.93 |
| w/ RN[35] | | 3.02 | 2.46 | 5.90 |
| w/ RAIN[36] | 替换 LRANorm | 3.00 | 2.44 | 5.85 |
| w/ SRPNorm[19] | | 2.91 | 2.35 | 5.75 |
| w/ SOAN[28] | | 3.03 | 2.49 | 5.82 |
| FSNIG-ShadowNet(本文) | 均不替换 | 2.86 | 2.34 | 5.53 |

3.4.2 非阴影区域先验范围分析

本节研究不同非阴影区域范围下非阴影区域先验对阴影区域颜色恢复的影响, 同时为了证明局部非阴影区域先验相比于所有非阴影先验的合理性, 本文设计不同的掩膜膨胀系数 k_2 和利用所有非阴影区域分别对 FSNIG-ShadowNet 进行训练。非阴影

区域范围的消融研究结果如表 6 所示。结果显示, 当掩膜膨胀系数 $k_2=4$ 时, 模型性能最佳, 因此在实验中设置 $k_2=4$ 。与此同时, 当引入所有非阴影区域信息指导阴影区域颜色恢复时, 模型实际性能下降, 这是因为非阴影区域存在不合理的先验指导, 使阴影区域颜色恢复不佳。




图 10 SR Block 和 LRANorm 有效性可视化比较结果

表 6 非阴影区域范围的消融研究结果

| k_2 | RMSE | | |
|----------|--------------------|--------------------|--------------------|
| | All | NS | S |
| all | 3.03(+0.17) | 2.44(+0.10) | 6.05(+0.52) |
| 1 | 3.00(+0.14) | 2.44(+0.10) | 5.88(+0.35) |
| 4 | 2.86(+0.00) | 2.34(+0.00) | 5.53(+0.00) |
| 10 | 2.88(+0.02) | 2.34(+0.00) | 5.63(+0.10) |
| 20 | 2.89(+0.03) | 2.36(+0.02) | 5.60(+0.07) |
| 30 | 2.93(+0.07) | 2.39(+0.05) | 5.70(+0.17) |

3.5 泛化性能

为了进一步验证 FSNIG-ShadowNet 的泛化性能, 本文将训练好的模型在 Vicente 等[39]和 Zhu 等[40]公开的阴影检测数据集上进行测试, 并与 Auto-Exposure[42]、SG-ShadowNet[19]和 BMNet[20]进行比较, 以体现 FSNIG-ShadowNet 优秀的泛化性能, 以上方法均使用 AISTD 数据集进行训练。可视化比较结果如图 11 所示。从图 11 中可以看出, 与其他方法相比, FSNIG-ShadowNet 去除结果的伪影和色差均得到很好的控制。




图 11 在 AISTD 数据集上最先进的方法和本文方法的可视化比较结果

4 结束语

本文提出了一种两阶段的特征分离和非阴影信息引导的阴影去除网络,利用多编码器分离环境光和直射光的思想,将学习复杂映射转化为学习环境光和直射光的单一映射问题。与其他使用光照模型的方法相比,网络整个过程是非线性的,能够自适应地分离环境光和直射光。进一步地,引入了局部区域自适应归一化模块更准确地利用非阴影区域颜色先验,保证了阴影去除后区域内外的颜色一致性。实验结果表明,本文提出的FSNIG-ShadowNet有效提高了阴影去除的效果,具有较好的阴影去除性能。

此外,本文方法也存在若干不足之处。首先,本文方法依赖于掩膜,掩膜的精确程度对于阴影去除结果有很大的影响。其次,生成局部非阴影区域的膨胀系数是根据ISTD数据集的统计结果以及消融实验计算出来的固定值。由于SRD数据集掩膜的不精确,无法基于统计计算出最优的膨胀系数,因此无法确定最优局部非阴影区域。在未来的工作中,将设法跳脱掩膜的限制,研究更好的区域一致性指标,动态地指导阴影区域颜色的恢复。

参考文献:

- [1] LALONDE J F, EFROS A A, NARASIMHAN S G. Estimating the natural illumination conditions from a single outdoor image[J]. *International Journal of Computer Vision*, 2012, 98(2): 123-145.
- [2] WEHRWEIN S, BALA K, SNAVELY N. Shadow detection and sun direction in photo collections[C]//*Proceedings of the 2015 International Conference on 3D Vision*. Piscataway: IEEE Press, 2015: 460-468.
- [3] OKABE T, SATO I, SATO Y. Attached shadow coding: estimating surface normals from shadows under unknown reflectance and lighting conditions[C]//*Proceedings of the 2009 IEEE 12th International Conference on Computer Vision*. Piscataway: IEEE Press, 2009: 1693-1700.
- [4] LI Z Q, SNAVELY N. Learning intrinsic image decomposition from watching the world[C]//*Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Piscataway: IEEE Press, 2018: 9039-9048.
- [5] LONG C J, HUA G. Correlational Gaussian processes for cross-domain visual recognition[C]//*Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway: IEEE Press, 2017: 4932-4940.
- [6] MIKIC I, COSMAN P C, KOGUT G T, et al. Moving shadow and object detection in traffic scenes[C]//*Proceedings of the 15th International Conference on Pattern Recognition*. Piscataway: IEEE Press, 2000: 321-324.
- [7] ZHANG Q Z, HU S T, SUN J C, et al. On adversarial robustness of trajectory prediction for autonomous vehicles[C]//*Proceedings of the 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway: IEEE Press, 2022: 15138-15147.
- [8] FINLAYSON G D, HORDLEY S D, LU C, et al. On the removal of shadows from images[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2006, 28(1): 59-68.
- [9] LIU F, GLEICHER M. Texture-consistent shadow removal[C]//*European Conference on Computer Vision*. Berlin: Springer, 2008: 437-450.
- [10] GONG H, COSKER D P. Interactive shadow removal and ground truth for variable scene categories[C]//*Proceedings of the British Machine Vision Conference (BMVC)*. Durham: British Machine Vision Association, 2014: 1-11.
- [11] 刘艳丽, 石俊, 张严辞. 一种单幅室外图像的阴影去除算法[J]. *软件学报*, 2012, 23(2): 168-175.
- [12] LIU Y L, SHI J, ZHANG Y C. Shadow removal based on single outdoor image[J]. *Journal of Software*, 2012, 23(2): 168-175.
- [13] ARBEL E, HEL-OR H. Shadow removal using intensity surfaces and texture anchor points[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2011, 33(6): 1202-1216.
- [14] WU T P, TANG C K. A Bayesian approach for shadow extraction from a single image[C]//*Proceedings of the Tenth IEEE International Conference on Computer Vision (ICCV)*. Piscataway: IEEE Press, 2005: 480-487.
- [15] GUO R Q, DAI Q Y, HOIEM D. Single-image shadow detection and removal using paired regions[C]//*Proceedings of the 2011 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway: IEEE Press, 2011: 2033-2040.
- [16] QU L Q, TIAN J D, HE S F, et al. DshadowNet: a multi-context embedding deep network for shadow removal[C]//*Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway: IEEE Press, 2017: 2308-2316.
- [17] WANG J F, LI X, YANG J. Stacked conditional generative adversarial networks for jointly learning shadow detection and shadow removal[C]//*Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Piscataway: IEEE Press, 2018: 1788-1797.
- [18] HU X W, FU C W, ZHU L, et al. Direction-aware spatial context features for shadow detection and removal[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, 42(11): 2795-2808.
- [19] CHEN Z P, LONG C J, ZHANG L, et al. CANet: a context-aware network for shadow removal[C]//*Proceedings of the 2021 IEEE/CVF International Conference on Computer Vision (ICCV)*. Piscataway: IEEE Press, 2021: 4723-4732.
- [20] WAN J, YIN H, WU Z Y, et al. Style-guided shadow removal[C]//*European Conference on Computer Vision*. Berlin: Springer, 2022: 361-378.
- [21] ZHU Y R, HUANG J, FU X Y, et al. Bijective mapping network for shadow removal[C]//*Proceedings of the 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway: IEEE Press, 2022: 5617-5626.
- [22] GUO L Q, WANG C, YANG W H, et al. ShadowDiffusion: when degradation prior meets diffusion model for shadow removal[C]//*Proceedings of the 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway: IEEE Press, 2023: 14049-14058.
- [23] HU X W, JIANG Y T, FU C W, et al. Mask-ShadowGAN: learning to remove shadows from unpaired data[C]//*Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision (ICCV)*. Piscataway: IEEE Press, 2019: 2472-2481.

- [23] JIN Y Y, SHARMA A, TAN R T. DC-ShadowNet: single-image hard and soft shadow removal using unsupervised domain-classifier guided network[C]//Proceedings of the 2021 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway: IEEE Press, 2021: 5007-5016.
- [24] LIU Z H, YIN H, WU X Y, et al. From shadow generation to shadow removal[C]//Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2021: 4925-4934.
- [25] LE H, SAMARAS D. From shadow segmentation to shadow removal[C]//European Conference on Computer Vision. Berlin: Springer, 2020: 264-281.
- [26] LE H, SAMARAS D. Shadow removal via shadow image decomposition[C]//Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway: IEEE Press, 2019: 8577-8586.
- [27] SHOR Y, LISCHINSKI D. The shadow meets the mask: pyramid-based shadow removal[J]. Computer Graphics Forum, 2008, 27(2): 577-586.
- [28] YU Q H, ZHENG N S, HUANG J, et al. CNSNet: a cleanliness-navigated-shadow network for shadow removal[C]//European Conference on Computer Vision. Berlin: Springer, 2023: 221-238.
- [29] 吴文, 万毅. 基于低尺度细节恢复的单幅图像阴影去除方法[J]. 电子学报, 2020, 48(7): 1293-1302.
WU W, WAN Y. Single image shadow removal using low-scale detail recovering[J]. Acta Electronica Sinica, 2020, 48(7): 1293-1302.
- [30] LIU Z H, YIN H, MI Y, et al. Shadow removal by a lightness-guided network with training on unpaired data[J]. IEEE Transactions on Image Processing: A Publication of the IEEE Signal Processing Society, 2021, 30: 1853-1865.
- [31] 王潇, 尧思远, 代朋纹, 等. 基于阴影和周边区域色差的光照条件和光谱反射率计算方法[J]. 电子学报, 2023, 51(8): 2098-2109.
WANG X, YAO S Y, DAI P W, et al. Estimating illumination condition and spectral reflectance based on the color variation between shadowed region and its surrounding regions[J]. Acta Electronica Sinica, 2023, 51(8): 2098-2109.
- [32] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift[C]//Proceedings of the 32nd International Conference on International Conference on Machine Learning. New York: ACM Press, 2015: 448-456.
- [33] HUANG X, BELONGIE S. Arbitrary style transfer in real-time with adaptive instance normalization[C]//Proceedings of the 2017 IEEE International Conference on Computer Vision (ICCV). Piscataway: IEEE Press, 2017: 1510-1519.
- [34] XU J, SUN X, ZHANG Z, et al. Understanding and improving layer normalization[C]//Proceedings of the Annual Conference on Neural Information Processing Systems. Massachusetts: MIT Press, 2019: 4383-4393.
- [35] YU T, GUO Z Y, JIN X, et al. Region normalization for image inpainting[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 12733-12740.
- [36] LING J, XUE H, SONG L, et al. Region-aware adaptive instance normalization for image harmonization[C]//Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2021: 9357-9366.
- [37] ZHANG L, LONG C J, ZHANG X L, et al. RIS-GAN: explore residual and illumination with generative adversarial networks for shadow removal[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 12829-12836.
- [38] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.
- [39] VICENTE T F Y, HOU L, YU C P, et al. Large-scale training of shadow detectors with noisily-annotated shadow examples[C]//European Conference on Computer Vision. Berlin: Springer, 2016: 816-832.
- [40] ZHU J J, SAMUEL K G G, MASOOD S Z, et al. Learning to recognize shadows in monochromatic natural images[C]//Proceedings of the 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2010: 223-230.
- [41] CUN X D, PUN C M, SHI C. Towards ghost-free shadow removal via dual hierarchical aggregation network and shadow matting GAN[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 10680-10687.
- [42] FU L, ZHOU C Q, GUO Q, et al. Auto-exposure fusion for single-image shadow removal[C]//Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2021: 10566-10575.


[作者简介]



黄颖 (1978-), 男, 湖南岳阳人, 博士, 重庆邮电大学副教授, 主要研究方向为图像处理、图像融合、图像质量评估、计算成像、智能信息处理与模式识别等。



房少杰 (1999-), 男, 四川德阳人, 重庆邮电大学硕士生, 主要研究方向为图像处理、深度学习和阴影去除等。



程彬 (1999-), 男, 江西上饶人, 重庆邮电大学硕士生, 主要研究方向为图像增强、深度学习等。

姜茂 (1999-), 女, 重庆人, 重庆邮电大学硕士生, 主要研究方向为图像处理、深度学习和图像去噪等。

钱鹰 (1968-), 男, 上海人, 博士, 重庆邮电大学教授、硕士生导师, 主要研究方向为数字图像处理、机器视觉与图像认知、医学成像和信息处理等。