文章编号:1673-0291(2026)04-0129-13 DOI:10.11860/j.issn.1673-0291.20250165

结合BCIMNet与分阶段训练策略的沙尘图像复原方法

牛宏侠[a,b],谢左宜[a,b],侯 涛[a]

(兰州交通大学 a.自动化与电气工程学院,b.甘肃省高原交通信息工程及控制重点实验室,兰州 730070)

摘 要:针对沙尘天气造成图像质量严重退化,导致计算机视觉系统鲁棒性、可靠性下降,且沙尘图像配对样本稀缺、公开标注数据集不足,制约深度学习方法应用的问题,提出一种结合改进网络与分阶段训练策略的沙尘图像复原方法.首先,将水平/垂直-强度(Horizontal/Vertical-Intensity, HVI)颜色空间扩展为融入沙尘维度的水平/垂直-强度-沙尘(Horizontal/Vertical-Intensity Dust, HVID)颜色空间,通过色偏校正与颜色调节机制精准表征沙尘退化特征;其次,改进色彩与强度解耦网络(Color and Intensity Decoupling Network, CIDNet)的主干结构,引入稀疏嵌套跳跃连接(Sparse Nested Skip Connections, SNSC)与双向耦合交互模块(Bidirectional Coupled Interaction Module, BCIM),构建双向耦合交互网络(Bidirectional Coupled Interaction Module Network,BCIMNet),以强化跨尺度特征融合与空间-通道协同表达能力;再次,在训练阶段基于合成样本构建训练对,设计先验引导的伪标签分阶段学习框架,借助传统方法与改进网络逐步生成伪标签,实现合成域到真实域的跨域适应;最后,在推理阶段结合HVI先验的轻量化后处理,缓解伪标签带来的潜在色彩偏置.研究结果表明:所提方法在真实沙尘图像清晰化任务中显著优于现有主流方法;相比基础模型水平/垂直-强度色彩与强度解耦网络(Horizontal/Vertical-Intensity Color and Intensity Decoupling Network, HVI-CIDNet),自然图像质量评估器(Natural Image Quality Evaluator, NIQE)、感知图像质量评估器(Perception based Image Quality Evaluator, PIQE)与无参考图像空间质量评估器(Blind/Referenceless Image Spatial Quality Evaluator, BRISQUE)的优化幅度分别达到55.8%、47.9%和46.1%.该方法可为沙尘场景下的图像增强与高层视觉任务的完成提供有效的技术支撑.

关键词:计算机视觉;沙尘图像清晰化;HVI颜色空间;伪标签学习;跨域适应;特征交互

中图分类号:TP391.4 **文献标志码**:A

Sand-dust image restoration method combining BCIMNet and staged training strategy

Niu Hongxia[a,b], *Xie Zuoyi*[a,b], *Hou Tao*[a]

(a.School of Automation and Electrical Engineering, b.Gansu Key Laboratory of Plateau Traffic Information Engineering and Control, Lanzhou Jiaotong University, Lanzhou 730070, China)

Abstract: Sand-dust weather can severely degrade image quality, thereby reducing the robustness and

收稿日期:2025-10-16;**修回日期**:2026-01-15

基金项目:甘肃省自然科学基金(23JRRA850);甘肃省高校产业支撑计划项目(2023CYZC-32);甘肃省重点研发计划-工业类项目(23YFGA0049);兰州市人才创新创业项目(2023-RC-13)

Foundation items: Natural Science Foundation of Gansu Province (23JRRA850); Industry Support Program for Higher Education Institutions of Gansu Province (2023CYZC-32); Key Research and Development Program of Gansu Province-Industrial Project (23YFGA0049); Lanzhou Talent Innovation and Entrepreneurship Project (2023-RC-13)

第一作者:牛宏侠(1978—),女,辽宁锦州人,副教授,硕士.研究方向为智能控制.**email**:nhx56055@mail.lzjtu.cn.

引用格式:牛宏侠,谢左宜,侯涛.结合BCIMNet与分阶段训练策略的沙尘图像复原方法[J].北京交通大学学报,2026,50(4):129-141.
Niu Hongxia, Xie Zuoyi, Hou Tao. Sand-dust image restoration method combining BCIMNet and staged training strategy[J]. Journal of Beijing Jiaotong University, 2026, 50(4): 129-141. (in Chinese)

reliability of computer vision systems. Moreover, the scarcity of paired sand-dust images and publicly available annotated datasets limits the application of deep learning methods. To address these issues, a sand-dust image restoration method integrating an improved network with a staged training strategy is proposed. First, the Horizontal/Vertical-Intensity (HVI) color space is extended by incorporating a dust dimension to form the Horizontal/Vertical-Intensity-Dust (HVID) color space, which accurately represents sand-dust degradation through color-cast correction and color adjustment. Second, the backbone of the Color and Intensity Decoupling Network (CIDNet) is enhanced with Sparse Nested Skip Connections (SNSC) and a Bidirectional Coupled Interaction Module (BCIM), yielding the Bidirectional Coupled Interaction Module Network (BCIMNet). This architecture improves cross-scale feature fusion and joint spatial-channel feature representation. Third, training pairs are constructed from synthetic samples, and a prior-guided staged pseudo-label learning framework is developed. Traditional methods and the enhanced network are used to progressively generate pseudo-labels, enabling domain adaptation from synthetic to real data. Finally, lightweight post-processing based on HVI priors is applied during inference to mitigate potential color bias introduced by the pseudo-labels. The results show that the proposed method significantly outperforms mainstream methods in restoring real sand-dust images. Relative to the baseline Horizontal/Vertical-Intensity Color and Intensity Decoupling Network(HVI-CIDNet) model, the Natural Image Quality Evaluator (NIQE), Perception-based Image Quality Evaluator (PIQE), and Blind/Referenceless Image Spatial Quality Evaluator (BRISQUE) scores decrease by 55.8%, 47.9%, and 46.1%, respectively. The proposed method provides effective technical support for image enhancement and high-level vision tasks in sand-dust environments.

Keywords: computer vision; sand-dust image restoration; HVI color space; pseudo-label learning; cross-domain adaptation; feature interaction

沙尘天气作为一种常见的大气环境问题,广泛分布于干旱和半干旱地区,对人类生产生活及生态环境造成了严重影响.在视觉感知层面,沙尘会引起明显的色彩偏移、亮度衰减和对比度降低,使图像呈现模糊与偏色等退化现象.这些问题不仅削弱了图像的视觉质量,也对后续的计算机视觉任务造成了不利影响.因此,研究沙尘图像的恢复与增强具有重要的理论意义和实际应用价值.

针对沙尘图像清晰化问题,现有研究主要分为3个方面:基于视觉感知的增强方法、基于物理模型的复原方法及基于数据驱动的深度学习方法.

基于视觉感知的图像增强方法依托人类视觉系统的感知特性,旨在提升图像的主观视觉质量,使其更加清晰自然.此类方法通常通过调节对比度、亮度与色彩饱和度来弥补沙尘造成的视觉退化,从而增强图像的可视性与信息表达能力.文献[1]提出保持颜色分量均值的RGB色彩平衡方法(RGB Color balance method, RGBCbm)来校正色偏,并结合相对全局直方图拉伸与Lab模型实现增强;文献[2]在RGB空间中采用自适应灰度世界-蓝通道算法(Adaptive Gray World-Blue channel, AGW-B)去除色偏,再在色调-饱和度-亮度(Hue-Saturation-Intensity, HSI)颜色空间中利用归一化亮度与饱和度校正的限制对比度自适应直方图均衡算法(Contrast Limited Adaptive Histogram Equalization with Normalized Intensity and Saturation Correction, CLAHE-NISC)增强图像.然而,此类方法在复杂环境下容易引入过度增强、色彩失真及边缘伪影,影响图像的真实性与可靠性.

基于物理模型的图像复原方法则依赖成像退化机理,通常基于大气散射模型(Atmospheric Scattering Model, ASM),通过先验信息反演退化过程以恢复清晰图像.文献[3]通过红绿通道逐像素估计透射率并结合蓝通道对其进行补偿,再利用通道间最小绝对强度差异估计环境光,最终基于ASM恢复图像;文献[4]结合颜色校正与复合通道先验策略,并辅以颜色补偿、自适应伽马校正和透射率估计以提升恢复效果.然而,该类方法依赖理想化假设和特定先验,若实际条件不满足,通常难以保证复原质量.

与上述两种传统方法不同,基于数据驱动的深度学习方法依托神经网络的强大学习能力,能够直接从数据中学习沙尘图像与清晰图像之间的映射关系.文献[5]构建基于多尺度信息交互的端到端网

络实现图像清晰化;文献[6]设计结合多尺度信息与色调-饱和度-明度颜色空间(Hue-Saturation-Value, HSV)的去沙尘算法;文献[7]引入基于多级联注意力交互的增强方法.深度学习方法近年来在去雾、去雨等图像恢复任务中展现出显著成效,但受限于缺乏大规模真实沙尘配对数据集,直接进行有监督训练仍存在挑战.针对这一问题,部分研究尝试使用合成数据弥补真实数据不足,或采用无监督方法实现沙尘图像清晰化.文献[8]采用潜在内容引导的对抗性重建(Latent-content Guided Adversarial Sand-dust Image Reconstruction, LGASR)策略;文献[9]利用基于 ASM 的零样本学习方法实现无监督恢复.尽管此类方法在一定程度上提高了模型的泛化能力,但在真实沙尘场景中仍容易出现色彩偏差、细节缺失或结构失真.因此,如何在有限真实数据条件下实现高质量的沙尘图像清晰化,依然是亟待解决的难点.

本文提出一种融合改进水平/垂直-强度色彩与强度解耦网络(Horizontal/Vertical-Intensity Color and Intensity Decoupling Network, HVI-CIDNet)[10]和先验引导伪标签分阶段训练策略[11]的沙尘图像清晰化方法.在颜色空间改进方面,扩展水平/垂直-强度(Horizontal/Vertical-Intensity, HVI)颜色空间为水平/垂直-强度-沙尘(Horizontal/Vertical-Intensity Dust, HVID)颜色空间,引入色偏校正与颜色调节因子 D,针对沙尘特有的光谱偏置与亮度衰减特性精准建模;在网络结构优化方面,在色彩与强度解耦网络(Color and Intensity Decoupling Network, CIDNet)中引入稀疏嵌套跳跃连接(Sparse Nested Skip Connection, SNSC)与双向耦合交互模块(Bidirectional Coupled Interaction Module, BCIM)构建双向耦合交互网络(Bidirectional Coupled Interaction Module Network, BCIMNet),通过稀疏嵌套连接增强跨尺度融合,借助双向耦合交互实现空间-通道协同建模;在跨域训练策略方面,针对真实配对数据稀缺问题,设计"合成预训练-伪标签微调-先验后处理"的 3 阶段学习框架,实现从合成域到真实域的有效迁移;在系统验证方面,依托真实沙尘数据集,从客观指标与主观感知双维度完成方法有效性验证.

1　本文方法

1.1　框架概述

本文方法的整体结构如图 1 所示.HVID 模块在传统 HVI 颜色空间的基础上引入沙尘颜色调节因子 D,通过色偏校正与颜色调节机制对沙尘退化特征进行建模:首先,将 RGB 沙尘图像映射至 HVI 空间以分离强度信息(I 分支)与色度特征(HV 分支),利用 D 对沙尘图像色彩失真与偏差进行补偿,从而形成更适于表征沙尘图像退化特性的特征.然后,将退化特征输入 BCIMNet,以实现对亮度与结构细节的恢复,再利用逆变换模块(Perceptual-invert HVI Transformation, PHVIT),将增强后的特征重新转换为 RGB 域,从而得到清晰图像.最后,为提升模型在真实沙尘场景下的泛化能力,进一步引入伪标签驱动的训练策略.该策略通过融合合成样本与伪标签样本,构建辅助监督信号,从而缓解真实配对清晰图像稀缺带来的训练不足问题,并在整体框架

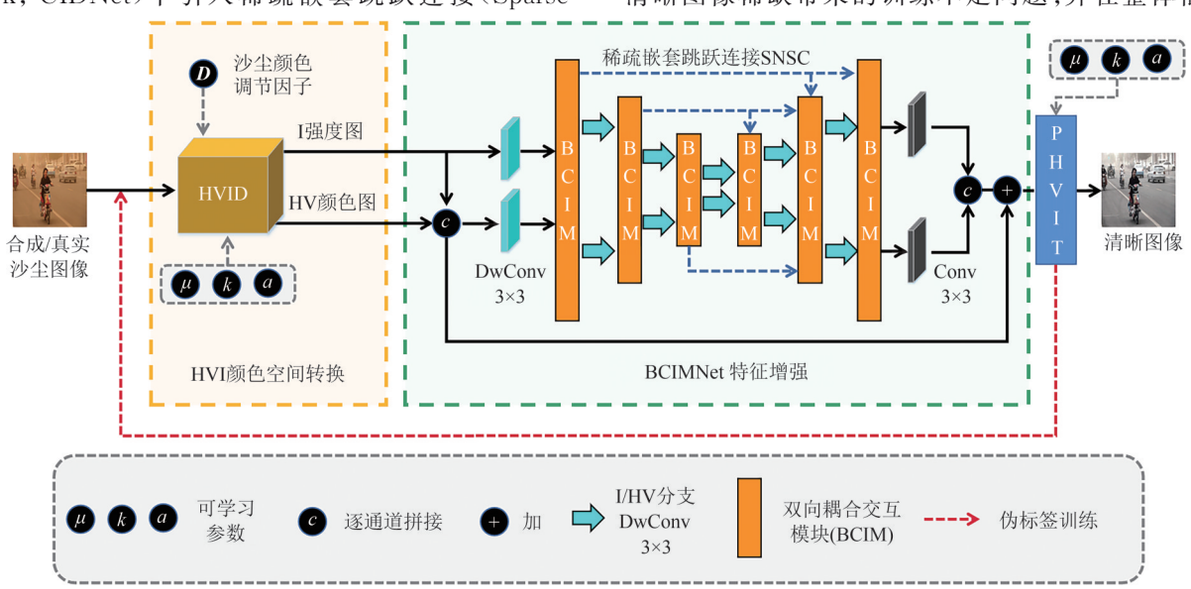


图 1　本文方法整体结构

Fig.1　Overall architecture of the proposed method

中作为训练阶段的关键步骤嵌入.

1.2 HVI颜色空间的扩展

在沙尘图像清晰化任务中,输入图像通常伴随明显的色彩偏移、细节模糊以及亮度对比度不足等退化特征.传统的RGB颜色空间中,颜色分量与亮度分量高度耦合,直接在该空间中进行增强处理往往会导致色彩失真或亮度过度放大,难以实现针对性优化.相比之下,HSV颜色空间能够在一定程度上解耦色相、饱和度与亮度,因此在图像增强领域被广泛采用.然而,已有研究表明,在低亮度或存在大面积阴影的复杂场景中,HSV空间可能引入红色不连续噪声和黑色平面伪影,限制其在退化图像恢复中的应用效果[12].为解决该问题,基于HSV空间的构建思路,引入HVI颜色空间[10].

HVI首先基于Max-RGB理论[13],将RGB色彩模型3个通道中的最大值定义为强度分量$\boldsymbol{I}$,其表达式为

$$\boldsymbol{I}=\max(C) \tag{1}$$

式中:C为各通道像素值构成的集合,$C=\{\boldsymbol{R},\boldsymbol{G},\boldsymbol{B}\}$,$\boldsymbol{R}$、$\boldsymbol{G}$、$\boldsymbol{B}$分别指代RGB色彩模型里3个颜色通道的所有像素值所构成的向量.

在HSV颜色空间中,色相分量取值范围为[0,360],色相值构成闭合圆环,并通过模运算实现数值循环.红色对应的基准色相为0°,红色像素集中分布在该边界位置.当红色区域像素的色相发生微小扰动时,色相数值会跨越0°边界,负值经模运算后跳转为接近360°的数值,最终造成红色色域内色相数值的不连续突变.

因此,HVI通过极化操作将色相轴映射为正交的水平分量$\boldsymbol{h}_{\text{or}}$和垂直分量$\boldsymbol{v}_{\text{or}}$,分别为

$$\boldsymbol{h}_{\text{or}}=\cos\left(\frac{\pi\boldsymbol{h}}{3}\right) \tag{2}$$

$$\boldsymbol{v}_{\text{or}}=\sin\left(\frac{\pi\boldsymbol{h}}{3}\right) \tag{3}$$

式中:$\boldsymbol{h}$为逐像素的色相图.在该表征下,色相可在正交的$\boldsymbol{h}_{\text{or}}$-$\boldsymbol{v}_{\text{or}}$平面中表示为角度;饱和度$\boldsymbol{S}$为角度矢量到原点的距离.该极化操作将周期循环的色相映射为平面内连续的二维分量,从而有效避免了红色区域的非连续性问题.

此外,HVI构建了一个可学习的强度坍缩函数$\boldsymbol{C}_k$,用于在压缩低光区域的同时保留高光细节,其表达式为

$$\boldsymbol{C}_k=\sqrt[k]{\sin\left(\frac{\pi\boldsymbol{I}}{2}\right)+\epsilon} \tag{4}$$

式中:k为可学习参数,用于调控暗区的密度分布;ϵ为极小正常数,本文取1×10^{-8},以避免梯度不稳定问题[10].该设计最初被应用于低光照图像增强,能够缓解色彩与亮度耦合的弊端,并通过几何化的颜色表达方式减少伪影产生.

然而,沙尘图像往往具有更强烈的色彩偏移(整体色相向黄-红区间偏移)和局部细节退化特征.因此,在HVI的基础上进行针对性扩展.

首先,引入一个可学习的全局偏移参数$\mu\in[-0.5,0.5]$,并通过周期化操作实现色相的平移.平移后的色相$\tilde{\boldsymbol{h}}$为

$$\tilde{\boldsymbol{h}}=(\boldsymbol{h}-\mu)\bmod1 \tag{5}$$

式中:mod1为对1取模运算,用于将色相数值约束在区间[0,1).

该操作等效于在由$\boldsymbol{h}_{\text{or}}$与$\boldsymbol{v}_{\text{or}}$构成的单位圆上施加刚体旋转,既保证了色相表征的可学习性,又保持了其周期性与可逆性.

然后,为进一步建模沙尘特有的光谱偏置,提出沙尘颜色调节因子$\boldsymbol{D}$为

$$\boldsymbol{D}=1+\alpha\tanh\left(\frac{\boldsymbol{l}-l_{\text{mean}}}{c}\right) \tag{6}$$

$$\boldsymbol{l}=\log\frac{\boldsymbol{R}}{\boldsymbol{G}+\boldsymbol{B}+\epsilon} \tag{7}$$

式中:$\boldsymbol{l}$为$\boldsymbol{R}$、$\boldsymbol{G}$、$\boldsymbol{B}$向量经红-蓝通道比率对数变换得到的单通道特征向量;l_{mean}为$\boldsymbol{l}$在整幅图像上的均值;α为可学习权重参数;c为缩放常数,本文中取值为1.

沙尘粒子对短波长光(蓝绿光)的散射强于长波长光(红光),导致沙尘图像呈现偏黄红色调.$\boldsymbol{D}$通过计算红/绿蓝通道比率的对数来量化这一色偏程度.为避免极端值干扰,采用去均值操作并通过tanh函数将$\boldsymbol{D}$约束在合理范围内,同时引入可学习权重α实现自适应校正强度.

结合饱和度$\boldsymbol{S}$,构建复合水平$\hat{\boldsymbol{H}}$分量与复合垂直$\hat{\boldsymbol{V}}$分量分别为

$$\hat{\boldsymbol{H}}=\boldsymbol{C}_k\odot\boldsymbol{D}\odot\boldsymbol{S}\odot\boldsymbol{H}_{\text{or}} \tag{8}$$

$$\hat{\boldsymbol{V}}=\boldsymbol{C}_k\odot\boldsymbol{D}\odot\boldsymbol{S}\odot\boldsymbol{V}_{\text{or}} \tag{9}$$

式中:$\odot$表示逐元素相乘;$\boldsymbol{H}_{\text{or}}$和$\boldsymbol{V}_{\text{or}}$分别为在式(2)和式(3)中引入式(5)后的结果.

最后,将$\hat{\boldsymbol{H}}$、$\hat{\boldsymbol{V}}$和$\boldsymbol{I}$进行级联,得到针对沙尘退化特性的HVI特征表示.该扩展后的HVI空间能够更准确地刻画沙尘图像的色彩分布与亮度结构特征,从而为后续的清晰化增强网络提供更具判别力的输入表示.

输入图像经由增强网络得到增强后的特征.为获得最终的可视化结果,需要将这些特征从HVI空

间映射回 RGB 空间.因此,采用逆变换 PHVIT. PHVIT 的核心思想是:首先将 HVI 特征转换为对应的 HSV 表达,再通过标准的 HSV - RGB 变换得到最终的彩色图像.

变换后,式(8)、式(9)可分别表示为

$$\hat{H}=A\cos(\theta) \tag{10}$$

$$\hat{V}=A\sin(\theta) \tag{11}$$

式中:A 为合成幅值项,为强度压缩项、沙尘颜色调节因子与饱和度分量的联合作用,$A=C_k\odot D\odot S$;θ 为像素级相位角,$\theta=\frac{\pi\tilde{h}}{3}$.可据此推导出色相 H、饱和度 S 与亮度 V 的估计形式为

$$H=\left(\mu+\frac{3\arctan\left(\frac{\hat{V}}{\hat{H}}\right)}{\pi}\right)\bmod 1 \tag{12}$$

$$S=\frac{A}{C_k+\epsilon} \tag{13}$$

$$V=I \tag{14}$$

由勾股定理推导出幅值项 A 的等价算术形式为 $A=\sqrt{\hat{H}^2+\hat{V}^2}$.在该过程中,引入的调节因子 α 与 D 被限制在适度的区间范围内,并保持均值的中性化特性,故 $D\odot S$ 对原始饱和度 S 的偏移具有上界约束,从而可近似 $S\approx D\odot S$.这一近似在数值稳定性与视觉感知质量之间取得了合理平衡.最终,将估计得到的 HSV 图像通过逆变换映射至 RGB 空间,得到增强后的清晰图像.

1.3　BCIMNet 网络结构

为更好地增强沙尘图像特征,本文在 CIDNet[10] 的基础上提出一种改进的网络结构,称为 BCIMNet,其结构如图 1 所示.该网络以 HVID 模块的输出特征作为输入,并在编码器与解码器的特征传播过程中采用深度可分离卷积[14](Depth-wise Convolution,DwConv)替代常规卷积,从而在保证恢复性能的同时有效降低计算开销.同时,BCIMNet 融合了 SNSC 与 BCIM,既提升了跨尺度特征融合能力,又加强了空间与通道维度的交互建模.

1.3.1　稀疏嵌套跳跃连接

原始 CIDNet 采用传统 UNet 结构,该结构使用一一对应的残差跳跃连接,将编码器与解码器相连,以缓解梯度消失并保留细节特征.然而,这种方式在复杂退化的沙尘场景下可能不足以充分利用跨层语义信息.相比之下,UNet++[15] 通过引入密集的嵌套跳跃连接,显著增强了特征重用与语义传递能力,但同时也带来了较高的计算开销与潜在的特征冗余.为在二者之间取得平衡,提出稀疏嵌套跳跃连接 SNSC.每一级编码器不仅与对应的解码器建立直接连接,还与该对应解码器相邻的一层解码器建立跨层连接.该设计在保持较低复杂度的同时,可有效增强跨尺度特征融合能力,使网络能够更好地恢复沙尘退化图像中的细节与结构.

1.3.2　BCIM 模块

在特征增强阶段,引入注意力机制对于捕获跨通道与跨空间的依赖关系至关重要.原始 CIDNet 中的轻量化交叉注意力模块(Lightweight Cross-Attention,LCA)[10] 能够有效建模通道间的交互关系,但在显式刻画空间依赖方面仍存在一定不足.为解决这一问题,引入扩张空间注意力模块(Dilated Spatial Attention Module,Di-SpAM)[16],增强对局部空间结构和多尺度分布的建模能力.进一步地,将 LCA 与 Di-SpAM 有机结合,提出双向耦合交互模块 BCIM,其整体结构如图 2 所示.图 2 中,BCIM 为整体框架,Di-SpAM 和 LCA 为 BCIM 内部的两个并行子模块.

LCA 模块接收来自 I 分支与 HV 分支的特征作为输入.为实现跨分支的信息交互,LCA 将其中一个分支的特征作为查询,另一个分支作为键和值,并通过特征嵌入卷积(Feature Embedding Convolution, FEConv)将输入映射至适配多头注意力机制的矩阵形式.在此过程中,多头注意力机制会将查询矩阵 $\boldsymbol{Q}$、键矩阵 $\boldsymbol{K}$ 和值矩阵 V_a 划分为多个子空间,并在每个子空间中分别执行缩放点积注意力(Scaled Dot-Product Attention)计算,其单头注意力输出矩阵 $\boldsymbol{Y}$ 为

$$\boldsymbol{Y}=\mathrm{Softmax}\left(\frac{\boldsymbol{Q}\boldsymbol{K}^{\mathrm{T}}}{\sqrt{d_k}}+b\right)V_a \tag{15}$$

式中:Softmax 为激活函数;d_k 为键向量的维度;b 为可学习的偏置项.

各子空间的输出结果被拼接后,经过线性变换以融合来自不同子空间的信息,得到最终的多头注意力输出矩阵 F_{att}.然后,LCA 模块通过门控前馈机制(Gated Feed-Forward, GFF)进一步增强特征表达:输出矩阵 F_{att} 被分为两路,均通过 tanh 激活函数处理,其中一路作为选择器,另一路作为待调制特征.二者经逐点乘法实现动态调制,并与残差连接融合,最终获得增强后的输出特征 F_{LCA} 为

$$F_{LCA}=\left(F_{att}+\tanh(\boldsymbol{W}_1F_{att})\right)\odot\left(F_{att}+\tanh(\boldsymbol{W}_2F_{att})\right) \tag{16}$$

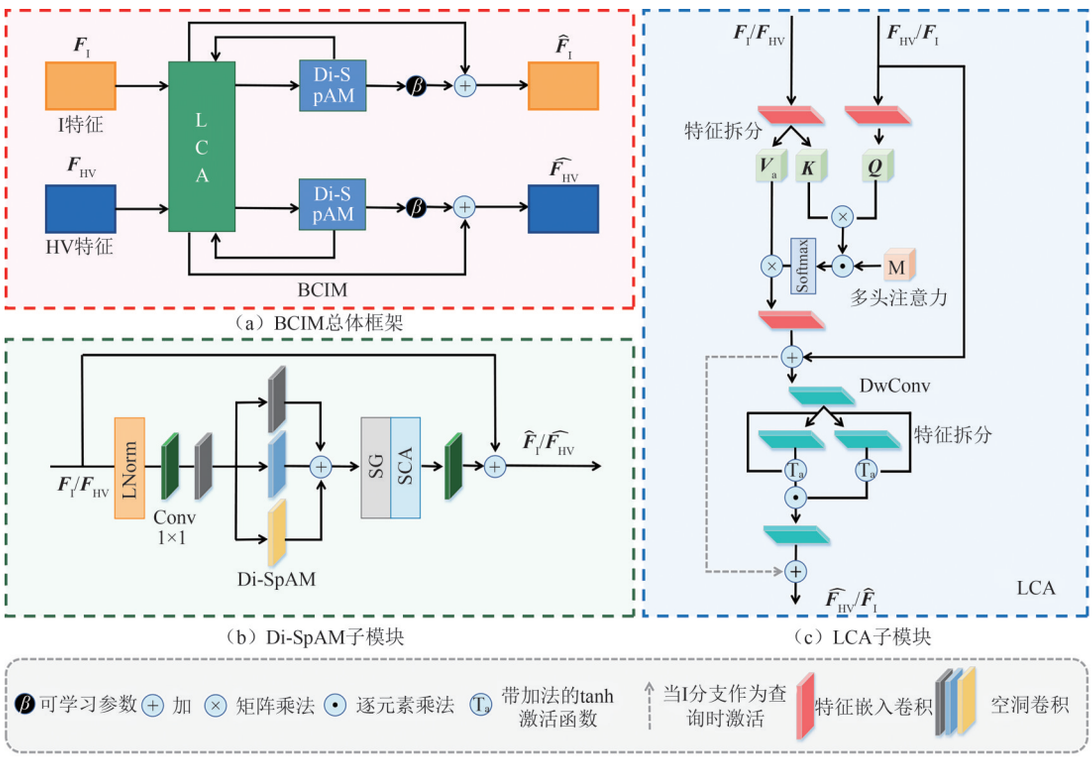


图 2 BCIM 结构图

Fig.2 Architecture of BCIM

式中：$\boldsymbol{W}_1$和$\boldsymbol{W}_2$为可学习映射矩阵.

Di-SpAM 旨在高效捕获多尺度信息并增强特征表达能力.模块通过设置不同膨胀率的深度可分离卷积构建多分支特征提取路径，之后将各分支特征在通道维度上进行融合，得到综合特征$\boldsymbol{F}$.在此基础上，Di-SpAM 引入简化门控机制（Simple Gate，SG），将$\boldsymbol{F}$沿通道维度均等拆分，得到两路中间过渡特征$\boldsymbol{F}_1$与$\boldsymbol{F}_2$，通过逐元素相乘实现特征调制，特征调制结果$\boldsymbol{F}_{\mathrm{g}}$为

$$\boldsymbol{F}_{\mathrm{g}}=\boldsymbol{F}_1\odot\boldsymbol{F}_2 \tag{17}$$

为突出关键语义特征并抑制冗余信息，Di-SpAM 在门控特征上引入简化通道注意力（Simplified Channel Attention，SCA），SCA 利用全局平均池化生成长度等于特征通道总数的一维通道描述符$\boldsymbol{z}$，并通过线性变换得到通道权重向量$\boldsymbol{W}$，再施加于特征，得到最终通道加权特征$\boldsymbol{F}_{\mathrm{Di}}$为

$$\boldsymbol{F}_{\mathrm{Di}}=\boldsymbol{F}_{\mathrm{g}}\otimes\sigma(\boldsymbol{W}\boldsymbol{z}) \tag{18}$$

式中：$\sigma(\cdot)$为 Sigmoid 激活函数；$\otimes$为矩阵乘法，进行通道加权操作.

BCIM 将 LCA 和 Di-SpAM 进行结合.首先采用LCA 对两个输入分支I特征$\boldsymbol{F}_{\mathrm{I}}$与HV 特征$\boldsymbol{F}_{\mathrm{HV}}$进行交叉注意力建模，得到交互增强后的特征表示$\boldsymbol{F}_{\mathrm{ILCA}}$与$\boldsymbol{F}_{\mathrm{HVLCA}}$（后续说明以$\boldsymbol{F}_{\mathrm{I}}$为例，$\boldsymbol{F}_{\mathrm{HV}}$亦可采用相同方式进行处理）.

其次，增强后的特征$\boldsymbol{F}_{\mathrm{ILCA}}$被送入 Di-SpAM，在多个不同膨胀率的卷积、简化门控机制与简化通道注意力 SCA 的协同作用下，生成多尺度融合特征$\boldsymbol{F}_{\mathrm{IDi}}$.该特征一方面与输入的$\boldsymbol{F}_{\mathrm{ILCA}}$进行残差融合，以保留 LCA 输出的交互信息；另一方面，$\boldsymbol{F}_{\mathrm{IDi}}$会重新输入LCA，与其另一分支特征$\boldsymbol{F}_{\mathrm{HV}}$共同参与键值$\boldsymbol{K}$、$\boldsymbol{V}_{\mathrm{a}}$的生成过程，从而建立跨分支的双向反馈机制.$\widehat{\boldsymbol{F}_{\mathrm{I}}}$为该模块的最终输出，其计算过程为

$$\boldsymbol{F}_{\mathrm{ILCA}}=O(\boldsymbol{F}_{\mathrm{I}},(\boldsymbol{F}_{\mathrm{HV}},\boldsymbol{F}_{\mathrm{IDi}})) \tag{19}$$

$$\boldsymbol{F}_{\mathrm{IDi}}=P(\boldsymbol{F}_{\mathrm{ILCA}}) \tag{20}$$

$$\widehat{\boldsymbol{F}_{\mathrm{I}}}=\boldsymbol{F}_{\mathrm{ILCA}}+\beta\boldsymbol{F}_{\mathrm{IDi}} \tag{21}$$

式中：$O(\cdot)$和$P(\cdot)$分别为 LCA 和 Di-SpAM 的运行算法；β为可学习的平衡参数，用于控制 LCA 与 Di-SpAM 的相对贡献.

该模块通过双向交互机制实现 LCA 与 Di-SpAM 在训练过程中的相互指导：一方面，LCA 提供的通道注意力信息可引导 DiSpAM 更好地关注空间特征的重要区域；另一方面，Di-SpAM 的空间依赖建模结果也能反馈给 LCA，从而优化通道特征的权重分配.通过这种交互式耦合设计，BCIM 可有效提升跨通道与空间维度的协同表达能力.

BCIMNet 通过稀疏嵌套跳跃连接提升了跨尺度特征融合能力，并通过 BCIM 模块加强了空间与通道注意力的双向交互，从而显著增强了对沙尘图

像退化特征的建模能力.

1.4　损失函数

为在多维度上对网络的训练过程进行约束,设计的损失函数同时结合了 sRGB 空间与 HVI 空间的监督信息.在整体框架中,综合引入 4 类损失:平均绝对误差(Mean Absolute Error, MAE)、结构相似性损失(Structural Similarity Index Measure, SSIM)、边缘保持损失(Edge Loss,EL)以及感知损失(Perceptual Loss,PL).其中,MAE 用于约束像素层面的恢复精度,SSIM 关注结构一致性,EL 强调图像细节的锐利度,PL 则通过高层语义特征提升恢复结果的感知质量.

上述 4 类损失通过加权组合构成的单空间损失函数 L 为

$$L=\lambda_1 L_{\mathrm{MAE}}+\lambda_2 L_{\mathrm{SSIM}}+\lambda_3 L_{\mathrm{edge}}+\lambda_4 L_{\mathrm{perc}} \tag{22}$$

式中:L_{MAE}、L_{SSIM}、L_{edge}、L_{perc} 分别为 MAE、SSIM、EL、PL 4 类损失;λ_1、λ_2、λ_3、λ_4 分别为平衡 4 类损失的权重超参数,在实验中设置为 1、0.5、50 和 0.01.

在 HVI 空间和 sRGB 空间中分别计算损失并进行加权,得到最终的总体损失函数 L_{loss} 为

$$L_{\mathrm{loss}}=\varphi L(\widehat{J_{\mathrm{HVI}}},J_{\mathrm{HVI}})+L(\hat{J},J) \tag{23}$$

式中:J_{HVI} 和 J 分别为原始清晰图像在 HVI 空间和 sRGB 空间的表示;$\widehat{J_{\mathrm{HVI}}}$ 和 $\hat{J}$ 为网络输出的增强后图像在对应空间的表示;φ 为平衡 HVI 空间与 sRGB 空间损失的权重系数,设置为 1.这种设计使得模型不仅能够在 HVI 空间中保持与目标分布的一致性,同时也能在 sRGB 空间中有效继承像素级的结构与细节,从而在整体上提升网络的重建质量与感知表现.

1.5　先验引导的伪标签分阶段训练策略

由于目前缺乏公开的沙尘图像数据集,直接对深度网络进行端到端的有监督训练存在较大困难.为解决这一问题,设计一种先验引导的伪标签分阶段训练策略,以实现对真实沙尘图像的有效建模.

在第一阶段,基于现有的清晰图像数据集构建合成沙尘图像数据集,得到合成沙尘图像-清晰图像对 $(x_{\mathrm{s}},y_{\mathrm{s}})$,在该数据集上训练所提出的 HVID-BCIMNet,记录最终训练权重 θ_0.该阶段网络先在合成域上学习基础的去色偏与细节恢复能力,为后续真实域训练提供稳定的初始化,缓解直接在真实域优化时的不适性与不稳定问题.

在第二阶段,由于真实沙尘图像缺乏配对清晰标签,设计双源伪标签策略以提供监督信号:对真实沙尘图像 x_{r},分别使用传统方法和预训练网络生成两路增强结果 y_{rU} 和 y_{rN}.其表达式分别为

$$y_{\mathrm{rU}}=U(x_{\mathrm{r}}) \tag{24}$$

$$y_{\mathrm{rN}}=f(x_{\mathrm{r}},\theta_0) \tag{25}$$

式中:$U(\cdot)$ 为基于物理先验的传统沙尘图像增强方法[17],该方法依托色差一致性与伽玛校正等原理,能够较为有效地恢复图像的整体色彩与亮度分布,但在细节恢复上存在不足;$f(\cdot,\theta_0)$ 为第一阶段预训练后的 HVID-BCIMNet,其在结构细节和局部纹理方面表现优异,但因域偏差会导致颜色失真.考虑到两者的互补性,采用加权融合生成伪标签 y_{r} 为

$$y_{\mathrm{r}}=\tau y_{\mathrm{rU}}+(1-\tau)y_{\mathrm{rN}} \tag{26}$$

式中:τ 为平衡传统方法与深度学习网络贡献的辅助参数,$\tau\in[0,1]$,本文设置为 0.7,以强化传统先验对色彩与对比度的约束.将结果再结合少量人工筛选,剔除严重失真的图像后,得到最终的训练伪标签 $\widehat{y_{\mathrm{r}}}$.然后,以 $(x_{\mathrm{r}},\widehat{y_{\mathrm{r}}})$ 作为训练对在真实域上继续训练 HVID-BCIMNet,并以 θ_0 作为初始化权重,记录训练后的权重 θ_1.

在得到 θ_1 后,根据 $y=f(x_{\mathrm{r}},\theta_1)$ 实现真实图像恢复.考虑到第二阶段中伪标签可能带来的潜在影响(微弱色彩偏置或局部伪影),推理端再施加轻量 HVI 先验后处理.该过程通过对色相、亮度与饱和度进行简洁而稳健的调整,用于抑制局部异常并提升整体感知一致性.该步骤不参与训练,仅在模型部署时启用,得到最终的清晰图像 $\hat{y}$.

整个训练策略实现了从合成数据到真实数据的逐步迁移,确保了模型在实际应用中对真实沙尘图像的有效恢复与增强.

2　实验结果与分析

2.1　数据集的构建及特征描述

由于缺乏公开的沙尘图像数据集,基于 KITTI 清晰图像数据集[18]合成具备真实场景特性的沙尘图像.合成过程主要参考沙尘退化图像的常见特征,如色彩偏移、对比度降低与局部模糊:通过随机噪声与高斯平滑生成空间非均匀掩码,在 HSV 空间中施加适度的色相与亮度扰动,并结合基于掩码强度的模糊处理,以再现不同浓度下的沙尘效应.最终,随机选取 KITTI 数据集中 6 000 张清晰图像,为每张图像生成对应的合成沙尘图像,构建包含 6 000 组清晰-沙尘图像对的合成沙尘数据集.将其中 5 000 对用于模型训练,剩余 1 000 对用于测试,供 HVID-BCIMNet 及对比模型开展训练与评估.

此外,通过实地拍摄与互联网检索的方式收集

1 036张真实沙尘图像，经人工筛选后，保留其中1 000张质量较高的图像用于生成伪标签，并在此基础上进一步选择800张作为可用样本，其中650张用于训练，150张用于测试，以验证所提算法的有效性.

为便于表征测试集的退化程度分布，采用简化的沙尘浓度指数(Dust Density Index, DDI)作为辅助标记.DDI定义为

$$\mathrm{DDI}=1-P_{95}(\boldsymbol{V})/255 \tag{27}$$

式中：$\boldsymbol{V}$为图像在HSV颜色空间下的亮度向量；算子P_{95}表示95%分位数运算，将亮度向量映射为单一标量，代表剔除最亮5%像素后的代表性亮度值.

DDI指标的设计依据如下：沙尘会造成画面整体亮度衰减，天空、建筑外墙等高亮区域退化特征尤为显著.为避免图像固有暗区域干扰退化程度统计，本指标选取亮度95%分位数替代均值作为计算基底，能够更准确地反映沙尘对画面高亮主体区域的衰减影响；再通过线性变换将统计量映射至[0,1]区间，得到DDI.DDI取值越大，表示图像沙尘退化越严重.

根据DDI的分布特征，将测试集划分为轻度沙尘(DDI<0.3)、中度沙尘(0.3≤DDI<0.6)、重度沙尘(DDI≥0.6)3个等级.统计显示，150张真实测试图像中，轻度53张，中度60张，重度37张，涵盖了从轻微扬尘到严重沙尘的多种退化程度.DDI仅作为相对参考指标，用于描述数据集的多样性和便于后续讨论，并非精确的物理量化.

2.2 实验环境和参数

所有实验均在Win11系统下进行，设计的HVID-BCIMNet基于Pytorch深度学习框架实现，torch版本为2.5.1.训练网络时，图像分辨率均设置为250×250像素；使用Nvidia RTX 4070 laptop显卡进行GPU加速；训练轮数设置为100，批量大小设置为12；模型参数由初始学习率为0.000 1的Adam优化器更新，学习率通过余弦退火(Cosine Annealing)结合重启(Restart)机制实现动态调整.

2.3 评价指标

为客观评估不同算法在沙尘图像清晰化任务中的表现，综合采用全参考与无参考图像质量评价指标.

在合成数据集上，选用峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)、SSIM以及学习感知图像块相似性(Learned Perceptual Image Patch Similarity, LPIPS)作为主要指标.其中，PSNR和SSIM的取值越大，表明图像质量越高；LPIPS的取值越小，表明图像与参考清晰图越接近.为了在数值趋势上保持一致性，将LPIPS转换为

$$\mathrm{LPIPS}^{*}=1-\mathrm{LPIPS} \tag{28}$$

由于LPIPS的原始取值范围为[0,1]，因此LPIPS^{*}同样落在[0,1]区间内.这样PSNR、SSIM与LPIPS^{*}的数值均满足“越大表示图像质量越优”的一致性标准.

在真实沙尘数据集上，因无对应清晰图像作为参考，采用无参考评价指标对算法的有效性进行评估.选取3个较为常用的无参考图像质量评价指标：自然图像质量评估(Natural Image Quality Evaluator, NIQE)、基于感知的图像质量评估(Perception-based Image Quality Evaluator, PIQE)、无参考图像空间质量评估(Blind/Referenceless Image Spatial Quality Evaluator, BRISQUE).NIQE、PIQE和BRISQUE均为取值越小表示图像质量越好.

2.4 消融实验

通过消融实验系统分析所提方法在沙尘图像清晰化任务中各模块的边际贡献.实验均基于合成数据集展开，采用相同的训练与测试配置，以保证对比的公平性.实验设计并训练了8个不同的模型：模型A为原始HVI-CIDNet；模型B为HVID-CIDNet；模型C为基于HVI并引入SNSC的CIDNet；模型D为基于HVI并结合UNet结构的BCIMNet；模型E为基于HVID并引入SNSC的CIDNet；模型F为基于HVID并结合UNet结构的BCIMNet；模型G为HVI-BCIMNet；模型H为HVID-BCIMNet，即本文所提模型.为验证不同改进策略对沙尘图像复原性能的影响，各模型在相同条件下的评价指标如表1所示.

表1 不同模型的消融实验客观评价结果

Tab.1 Objective evaluation results of ablation experiments for different models

模型	HVID	SNSC	BCIM	PSNR (↑)	SSIM (↑)	LPIPS^{*} (↑)
模型A	×	×	×	23.993	0.794	0.793
模型B	√	×	×	24.324	0.795	0.809
模型C	×	√	×	24.019	0.795	0.799
模型D	×	×	√	24.967	0.797	0.827
模型E	√	√	×	25.351	0.799	0.846
模型F	√	×	√	27.834	0.900	0.937
模型G	×	√	√	27.055	0.889	0.921
模型H	√	√	√	**28.369**	**0.903**	**0.946**

注：“√”代表启用对应模块，“×”代表不启用；“↑”表示指标取值越大，图像复原质量越优.

不同模块的引入在性能提升上具有显著差异.由表1可知：① 只有当HVID、SNSC与BCIM三者协同集成时(即提出的HVID-BCIMNet)，各评价指

标均达到最优,充分证明了所提网络对沙尘图像质量恢复的有效性.② 从单模块价值分析,BCIM 的贡献尤为突出,单独引入 BCIM 的模型 D 明显优于未启用任何模块的基准模型 A,且性能超过仅引入 HVID 或 SNSC 的模型 B 和模型 C,表明 BCIM 是提升基础性能的核心组件.③ 在双模块组合中,HVID 与 BCIM 的协同效果最为显著,其性能接近完整模型 H,体现出二者具有较强的互补性和高效的增益作用;而 SNSC 与 BCIM 的组合虽不及 HVID+BCIM,但仍优于单独使用 BCIM,验证了各模块融合的价值.

选取 8 个场景开展消融实验,模块消融实验的主观可视化结果如图 3 所示.图 3 中,首列“输入图像”为存在明显偏色和细节模糊的合成沙尘图像,末列“基准图像”为对应的清晰参考图像.由图 3 可知:① 单模块实验中,未引入任何模块的模型 A 的输出仍存在明显色偏与细节缺失;引入 HVID 的模型 B 在色彩校正上更为自然,但细节恢复不足;集成 SNSC 的模型 C 在局部对比度方面有所提升,却难以兼顾整体色彩一致性;而加入 BCIM 的模型 D 在细节重建方面表现最佳,是单模块方案中效果最优的配置.② 在多模块协同实验中,模型 E 能够实现色彩与对比度的联合优化,但细节还原能力不及包含 BCIM 的模型 F 与模型 G;3 个模块全集成的模型 H 在色彩精准性、对比度控制以及细节完整性方面均达到最优,其主观视觉质量高度接近基准图像.③ 整体来看,主观可视化与客观评价指标结果高度一致,BCIM 在单模块中对细节恢复贡献最显著,双模块增益主要依赖 BCIM 的参与,而 3 个模块协同则能够覆盖“色彩校正-对比度增强-细节重建”的完整流程,充分验证多模块融合在沙尘图像增强任务中的必要性与有效性.

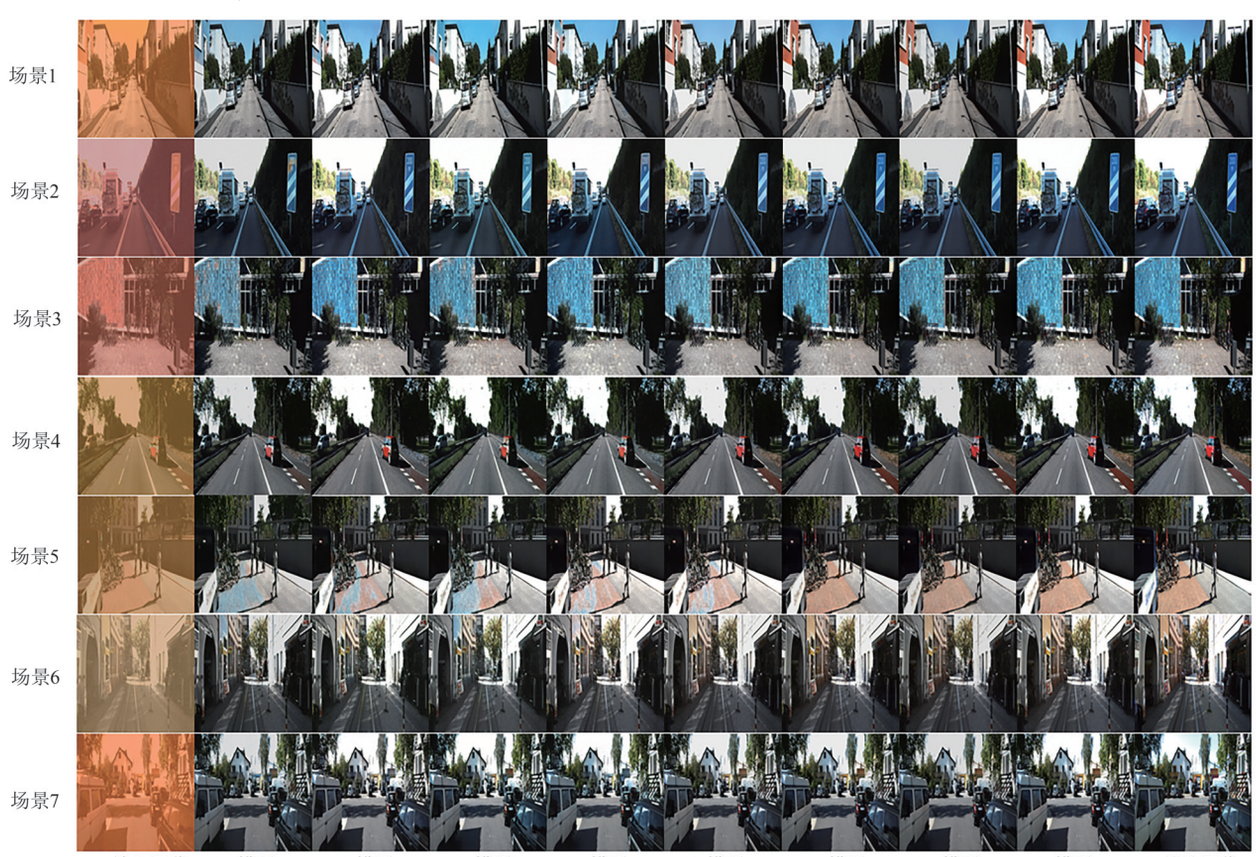


图 3　不同模型的消融实验主观对比结果

Fig.3　Subjective comparison results of ablation experiments for different models

为验证所提出的训练策略在真实沙尘图像清晰化任务中的有效性,在真实场景下设计两组对比实验:实验 1 直接利用 HVID-BCIMNet 进行恢复;实验 2 则在同一模型基础上引入先验引导的伪标签分阶段训练策略.两组实验输入均为真实沙尘图像,实验结果通过无参考图像质量评价指标进行客观对比分析,以评估不同训练方式对恢复效果的影响.

引入训练策略的消融实验客观评价结果如表 2 所示.由表 2 可知:仅依赖 HVID-BCIMNet 时,各项无参考指标已有显著改善,说明该网络能够有效优

表 2 引入训练策略的消融实验客观评价结果

Tab.2 Objective evaluation results of ablation experiments on the introduced training strategy

实验	HVID-BCIMNet	训练策略	NIQE(↓)	PIQE(↓)	BRISQUE(↓)
原始沙尘图像	×	×	12.895	52.176	45.573
实验 1	√	×	6.993	32.177	30.088
实验 2	√	√	**2.936**	**22.364**	**18.210**

注:“√”代表启用对应模块,“×”代表不启用;指标旁标注“↓”表示该指标取值越小,图像复原质量越优.

化真实沙尘图像的基础质量;在此基础上引入先验引导的伪标签分阶段训练策略后,指标表现进一步提升,验证了该策略在充分挖掘网络潜力和提升图像恢复质量方面的有效性.

针对 6 个场景开展引入训练策略的消融实验,实验主观对比结果如图 4 所示.由图 4 可知:从视觉效果来看,HVID-BCIMNet(实验 1)能够初步减轻沙尘导致的色彩偏差与模糊感,恢复图像的基本细节;在叠加训练策略后(实验 2),图像的边缘轮廓更为清晰,色彩还原更为自然,整体视觉效果更接近理想无沙尘状态.由此可见,HVID-BCIMNet 提供了可靠的基础修复框架,而训练策略的引入进一步增强了细节还原与色彩校正能力,实现客观与主观质量的双重提升.



图 4 引入训练策略的主观对比结果

Fig.4 Subjective comparison results with and without the staged training strategy

2.5 对比实验

为全面验证所提方法的有效性,选取 9 种主流算法进行对比,其中包括 Pix2Pix[19]、RIDCP[20]、HVI-CIDNet[10]与 AECR-Net[21]等深度学习方法,以及 RBC[22]、CVCG[17]、CCSE[23]、FSID[24]和 3c[25]等传统方法.对比实验采用 NIQE、PIQE 和 BRISQUE 共 3 个无参考图像质量评价指标,从自然度、感知质量和失真度控制等方面对各方法在真实沙尘图像增强任务中的表现进行系统评估.

2.5.1 客观评价分析

各方法在 150 张真实沙尘测试图像上的客观评价结果如表 3 所示.表 3 中,数据为所有测试图像的均值和标准差,其中标准差反映了算法在不同图像上的性能波动.由表 3 可知:① 所提方法在 3 项无参考指标上均取得最优表现;同时,所提方法的标准差显著小于其他对比方法,表明算法在不同退化程度的沙尘图像上表现更加稳定,具有良好的泛化能力.② 与深度学习方法相比,所提方法突破了基线 HVI-CIDNet 的性能瓶颈,3 项指标分别提升了 55.8%、47.9% 和 46.1%,验证了 HVID 颜色空间、BCIMNet 网络结构和伪标签训练策略的有效性.③相比传统方法,所提方法在所有指标上均实现全面超越,说明深度学习在捕获沙尘退化的复杂模式方面具有明显优势.

表 3 各方法在 150 张真实沙尘图像上的客观评价结果(均值±标准差)

Tab.3 Objective evaluation results of various methods on 150 real sand-dust images (mean ± standard deviation)

方法	NIQE(↓)	PIQE(↓)	BRISQUE(↓)
Pix2Pix	5.36±1.29	33.50±10.61	30.13±10.31
RIDCP	9.51±1.10	53.10±9.65	40.94±11.52
AECR-Net	4.81±0.52	28.39±9.43	26.69±8.33
HVI-CIDNet	6.65±0.86	42.90±8.06	33.79±8.51
RBC	6.09±1.38	43.06±11.31	34.83±8.22
CVCG	3.88±0.79	31.74±9.02	22.51±8.96
CCSE	4.90±0.74	34.43±10.67	26.53±10.02
FSID	7.96±0.56	50.76±10.26	37.11±9.78
3c	5.40±0.81	42.80±10.43	29.48±10.39
所提方法	**2.94±0.51**	**22.36±7.23**	**18.21±7.52**

2.5.2　跨浓度鲁棒性分析

为进一步验证算法在不同退化程度下的稳定性,按照沙尘浓度指数DDI将测试集分为轻度、中度、重度3个等级,各等级与全部样本下所提方法的性能表现如表4所示.由表4可知:随着沙尘浓度增加,各项无参考指标呈现合理的上升趋势(性能下降);但即使在极端浓度场景下,所提方法的各项无参考指标仍优于所有对比方法,验证了所提方法的跨浓度鲁棒性.其中,重度场景下标准差增大主要源于样本量减少导致的统计波动,以及沙尘颜色调节因子D在极端浓度下接近饱和的物理限制,这是当前方法的固有局限.

表 4　所提方法在不同沙尘浓度下的性能对比

Tab.4　Performance comparison of the proposed method under different sand-dust concentrations

浓度等级	NIQE(↓)	PIQE(↓)	BRISQUE(↓)
轻度 (DDI<0.3)	2.51±0.26	20.34±6.29	16.82±6.90
中度 (0.3≤DDI<0.6)	2.93±0.38	22.15±6.96	18.47±7.38
重度 (DDI≥0.6)	3.68±0.85	25.21±8.78	20.91±8.69
全部样本	**2.94±0.51**	**22.36±7.23**	**18.21±7.52**

2.5.3　主观视觉对比

各种方法在9个代表性场景下的主观对比结果如图5所示,9个场景是从150张测试集图像中选取的具有代表性的样本,用于直观展示不同方法在实际场景中的视觉效果.选取图像涵盖不同的浓度等级,其中轻度3张(场景1~3)、中度3张(场景4~6)、重度3张(场景7~9),以验证算法在不同退化程度下的适用性,每个等级内选择DDI值接近中位数的图像,以确保代表性.



(a) 场景1　(b) 场景2　(c) 场景3　(d) 场景4　(e) 场景5　(f) 场景6　(g) 场景7　(h) 场景7　(i) 场景7

图 5　各方法在9个代表性场景下的主观对比结果

Fig.5　Subjective comparison results of various methods across nine representative scenarios

由图5可知:① 在深度学习方法中,Pix2Pix在天空区域易产生明显的黑色噪点,严重影响视觉观感;RIDCP对沙尘特有的色偏抑制不足,恢复结果整体偏黄;AECR-Net在细节纹理还原方面存在不足,生成图像略显模糊;HVI-CIDNet在高浓度沙尘场景下则易出现明显的颜色失真.② 对于传统方法,RBC常导致图像局部区域过曝;CVCG在部分场景中表现较好,但仍难以彻底清除沙尘残留;CCSE在天空区域恢复时易引入黑色噪点,破坏图像自然感;FSID无法有效消除色偏,且部分结果出现结构性扭曲;3c方法生成图像整体偏暗,细节清晰度不足.从视觉质量来看,对比方法普遍存在一定局限性.③ 相比之下,所提方法在所有场景下均展现出更加优越的清晰化能力.综上,所提方法能够有效消

除沙尘遮蔽，准确还原场景真实色彩，保持建筑、植被等细节纹理的清晰性，同时避免色彩失真与伪影产生，使整体视觉效果更加自然，主观体验显著提升.

综合客观指标与主观感知，所提方法在真实沙尘图像清晰化任务中显著优于现有主流算法，在色彩校正、细节保持和感知一致性方面取得了全面提升，具有良好的实际应用价值.

3 结论

1）基于HVID颜色空间与BCIM模块构建的增强网络，能够在沙尘退化条件下有效解耦色彩偏移与亮度衰减分量，在显著减弱色彩失真与朦胧感的同时保留细节结构与场景纹理，输出结果更接近自然图像的视觉效果.

2）伪标签驱动的分阶段训练策略可有效缓解真实沙尘场景下配对数据稀缺的问题，使模型在完成合成数据基础特征学习的基础上，实现了由合成域向真实域的稳定迁移，提升了方法在真实复杂场景下的泛化能力.

3）多种典型真实沙尘场景下的实验结果显示，所提方法在NIQE、PIQE、BRISQUE三项无参考图像质量指标上的全样本均值分别为2.94、22.36与18.21，相较于基准模型分别下降55.8%、47.9%与46.1%，有效降低图像失真程度并提升视觉自然度，整体性能优于现有主流深度学习与传统沙尘增强算法，且在不同沙尘浓度等级下均保持稳定复原效果.该结果充分验证了所提方法在色彩校正、细节保留与退化鲁棒性方面的综合优势，具备良好的实际应用价值.

沙尘颜色调节因子D在极端浓度条件下接近饱和，制约了模型在高浓度场景中的清晰化表现.同时，所采用的DDI指标基于单一亮度维度建模沙尘浓度，尚难以全面刻画真实退化中亮度、对比度、色偏、模糊等多因素耦合特性，且在暗调场景下存在一定的场景依赖性.未来工作可从以下方向进一步展开：一方面，引入自适应调节机制，根据输入图像的退化程度动态调整D的上界，以突破极端浓度场景下的性能瓶颈；另一方面，结合深度学习的退化程度估计方法，构建多维度耦合的沙尘浓度量化模型，使退化评估指标摆脱对单一亮度统计的依赖，从而推动沙尘图像清晰化方法在更广泛实际场景中的应用与发展.

参考文献(References)：

[1] 丁元，邬开俊.基于RGB色彩平衡方法的沙尘降质图像增强[J].光学精密工程，2023，31(7)：1053－1064.
Ding Yuan，Wu Kaijun. Sand-dust image enhancement using RGB color balance method[J]. Optics and Precision Engineering，2023，31(7)：1053－1064.(in Chinese)

[2] Hassan M F，Siaw L W，Paramesran R. An integrated enhancement method to improve image visibility and remove color cast for sand-dust image [J]. Multimedia Tools and Applications，2025，84(10)：7361－7376.

[3] Shi F，Jia Z H，Lai H C，et al. Sand-dust image enhancement based on light attenuation and transmission compensation [J]. Multimedia Tools and Applications，2023，82(5)：7055－7077.

[4] Yang Y，Zhang J L，Liu C，et al. Visibility restoration of haze and dust image using color correction and composite channel prior[J]. The Visual Computer，2023，39(7)：2795－2809.

[5] 刘运博，陈平.基于多尺度信息交互的深度学习图像去沙算法[J].国外电子测量技术，2023，42(8)：147－153.
Liu Yunbo，Chen Ping. Deep learning image desanding algorithm based on multi-scale information interaction[J]. Foreign Electronic Measurement Technology，2023，42(8)：147－153.(in Chinese)

[6] 侯丁博，陈平.基于多尺度信息与HSV空间的图像去沙尘算法[J].测试技术学报，2025，39(3)：305－312.
Hou Dingbo，Chen Ping. Image desanding algorithm based on multi-scale information and HSV space[J]. Journal of Test and Measurement Technology，2025，39(3)：305－312.(in Chinese)

[7] 王荣，邹淑平，郝鹏飞，等.多级联注意力交互的沙尘图像增强方法[J].计算机科学，2025，52(增1)：517－523.
Wang Rong，Zou Shuping，Hao Pengfei，et al. Sand dust image enhancement method based on multi-cascaded attention interaction[J]. Computer Science，2025，52(S1)：517－523.(in Chinese)

[8] Si Y Z，Li C，Yang F. LGASR：latent-content guided adversarial sand-dust image reconstruction strategy [J]. The Journal of Supercomputing，2024，81(1)：168.

[9] Shi F，Jia Z，Zhou Y. Zero-Shot Sand-Dust Image Restoration[J].Sensors，2025，25(6)：1889.

[10] Yan Q S，Feng Y X，Zhang C，et al. HVI：a new color space for low-light image enhancement [C]//2025 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville，2025：5678－5687.

[11] Chen H，Tao R，Fan Y，et al. SoftMatch：addressing the quantity-quality trade-off in semi-supervised learning [EB/OL]. (2023-01-25)[2025-10-16]. https://arxiv.org/abs/2301.10921.

[12] Yan Q S，Feng Y X，Zhang C，et al. You only need

one color space: an efficient network for low-light image enhancement [EB/OL]. (2024-02-08) [2025-10-16]. https://arxiv.org/abs/2402.05809.

[13] Land E H. The retinex theory of color vision[J]. Scientific American, 1977, 237(6): 108－128.

[14] Coates A, Ng A, Lee H. An analysis of single-layer networks in unsupervised feature learning[C]//Proceeding of the 10th International Conference on Artificial Intelligence and Statistics. Fort Lauderdale 2011, 15: 215－223.

[15] Zhou Z W, Siddiquee M M R, Tajbakhsh N, et al. UNet＋＋: a nested U-Net architecture for medical image segmentation[C]//Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support. Cham: Springer, 2018: 3－11.

[16] Feijoo D, Benito J C, Garcia A, et al. DarkIR: robust low-light image restoration[C]//2025 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville,2025: 10879－10889.

[17] Jeon J J, Park T H, Eom I K. Sand-dust image enhancement using chromatic variance consistency and gamma correction-based dehazing[J]. Sensors, 2022, 22(23): 9048.

[18] Geiger A, Lenz P, Stiller C, et al. Vision meets robotics: The kitti dataset[J]. The international journal of robotics research, 2013, 32(11): 1231－1237.

[19] Qu Y Y, Chen Y Z, Huang J Y, et al. Enhanced Pix2pix dehazing network[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Long Beach, 2020: 8152－8160.

[20] Wu R Q, Duan Z P, Guo C L, et al. RIDCP: revitalizing real image dehazing *via* high-quality codebook priors[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Vancouver, 2023: 22282－22291.

[21] Wu H Y, Qu Y Y, Lin S H, et al. Contrastive learning for compact single image dehazing[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville, 2021: 10546－10555.

[22] Shi F, Jia Z H, Lai H C, et al. Sand dust images enhancement based on red and blue channels[J]. Sensors, 2022, 22(5): 1918.

[23] Hua Z W, Qi L Z, Guan M, et al. Colour balance and contrast stretching for sand-dust image enhancement[J]. IET Image Processing, 2022, 16(14): 3768－3780.

[24] Kim S E, Park T H, Eom I K. Fast single image dehazing using saturation based transmission map estimation[J]. IEEE Transactions on Image Processing, 2020, 29: 1985－1998.

[25] Ancuti C O, Ancuti C, De Vleeschouwer C, et al. Color channel compensation (3C): A fundamental preprocessing step for image enhancement[J]. IEEE Transactions on Image Processing, 2020, 29: 2653－2665.