

基于多教师引导的知识蒸馏图像去雾算法

崔智高, 兰云伟, 王念, 张炜

(火箭军工程大学, 陕西 西安 710025)

摘要: 针对现有图像去雾算法容易导致去雾图像颜色失真等问题, 采用多教师知识蒸馏方式, 融合基于先验信息的图像复原方法与基于深度学习的图像去雾方法的互补优势, 提出了一种基于多教师引导的知识蒸馏图像去雾算法。该算法选择两个预训练的去雾模型作为教师网络, 并利用教师模型蕴含的知识指导学生网络的训练; 此外, 算法还通过构建一个多尺度学生网络以及设计特征注意残差密集块来提高学生网络的特征提取能力。结果表明: 与其他去雾算法相比, 所提算法在合成图像和真实场景图像上均表现出优异的去雾性能, 在 SOTS 室外数据集上的峰值信噪比和结构相似度分别达到了 23.57 dB 和 0.934。

关键词: 图像处理; 图像去雾; 知识蒸馏; 多教师网络

中图分类号: TP391

文献标志码: A

文章编号: 2097-2741(2024)05-035-09

An Image Dehazing Algorithm Based on Multi-teacher Guided Knowledge Distillation

CUI Zhigao, LAN Yunwei, WANG Nian, ZHANG Wei

(Rocket Force University of Engineering, Xi'an 710025, Shaanxi)

ABSTRACT: To solve the problem of serious color distortion caused by existing image dehazing algorithms, a single image dehazing algorithm based on multi-teacher guided knowledge distillation dehazing network (MGKDN) was proposed, which combined the complementary advantages of prior-based image restoration methods and deep learning-based image dehazing methods. In the proposed MGKDN, two published models namely principled synthetic-to-real dehazing network (PSD) and enhanced pix2pix dehazing network (EPDN) were used as teacher networks. Moreover, to build an efficient student network, a feature attention residual dense block, which improved feature extraction and keep the student network compact was adopted. Compared to other dehazing algorithms, the proposed algorithm achieves excellent performance on both synthetic and real scene images. It achieves PSNR of 23.57 dB and SSIM of 0.934 on the SOTS outdoor dataset.

KEYWORDS: image processing; image dehazing; knowledge distillation; multi-teacher network

当前, 智能视频监控系统正大规模应用于安防系统、城市管理、自动驾驶等领域^[1-2], 能够解

决人员因长时间、高强度关注监控画面而产生的视觉疲劳, 有效降低错检、漏检情况发生的可能

收稿日期: 2024-05-31

基金项目: 陕西省自然科学基金 (2023-JC-YB-501)

第一作者: 崔智高 (1984—), 男, 副教授, 主要从事模式识别与智能监控技术研究。E-mail: cuizg10@126.com

引用格式: 崔智高, 兰云伟, 王念, 等. 基于多教师引导的知识蒸馏图像去雾算法[J]. 火箭军工程大学学报, 2024, 38 (5): 35-43.

性。然而由于户外视觉传感器常年受到雨、雾、风、暗光等环境影响,导致采集视频出现多种退化降质现象^[3]。在雾霾条件下,视觉传感器采集的图像偏灰白色,对比度下降,其物体特征也难以辨认^[4]。如何实现雾霾条件下图像质量的增强处理,从而提升摄像机的抗干扰能力和在高级视觉任务中的智能化应用效果,具有重要的研究意义和广阔的应用前景。

图像去雾旨在提升图像的对比度、恢复图像的原有细节。目前,图像去雾技术可分为基于先验信息的图像复原方法和基于深度学习的图像去雾方法两种^[5]。其中,基于先验信息的图像复原方法依据成像过程中光在大气中的吸收作用和散射作用建立大气散射模型,并通过对无雾图像颜色、饱和度等信息的深入观察和分析,人为制定先验信息对大气散射模型进行约束,进而求得大气散射模型中的未知参数并生成最终的去雾图像。例如:暗通道先验去雾算法(Dark Channel Prior, DCP)^[6]假设在一幅图像的非天空区域图像块中,一般至少有1个通道在某些像素处具有非常低的强度,并且该强度趋近于0;Fattal等^[7]观察到图像块的像素在RGB颜色空间中通常呈一维分布,并据此提出色线先验图像去雾算法来恢复无雾图像;Berman等^[8]假设无雾图像在RGB颜色空间中可以近似为几百种不同颜色的簇,并据此提出非局部先验图像去雾算法(Non-local Image Dehazing, NLD)。上述算法可以有效进行去雾,但由于人为设定的先验信息无法满足复杂多样的雾霾分布,上述算法往往会过度去雾,从而使图像质量进一步降低。

随着深度学习技术的不断发展,基于深度学习的图像去雾方法依靠强大的图像生成能力逐渐成为图像去雾领域研究的主要方向^[9]。例如:Qin等^[10]通过引入密集连接和残差网络结构,提出了一种特征融合注意力网络(Feature Fusion Attention Network, FFA-Net),该算法证明了通过增加网络深度可有效提高算法的去雾能力;Chen等^[11]提出了一种门控聚合网络(Gated Context Aggregation Network, GCANet),该算法使用平滑膨胀卷积以更好地获取图像的全局信息,并使用门控网络融合不同尺度的特征信息来改善图像去雾效果;Dong等^[12]基于U-Net^[13]架构,提出了一种多尺度增强图像去雾网络(Multi-scale Boosted Dehazing Network, MSBDN),该算法采

用编码器-解码器结构并使用增强策略来生成去雾图像;Qu等^[14]基于生成对抗网络相关理论,提出了一种增强型像素对像素的图像去雾网络(Enhanced Pix2pix Dehazing Network, EPDN),该算法通过嵌入的生成对抗网络和增强器进行共同训练,取得了较好的图像去雾效果。相比于基于先验信息的图像去雾方法,基于深度学习的图像去雾方法直接利用端到端网络生成去雾图像,通常可使去雾图像具有更少的伪影。但由于缺乏真实有雾数据集进行有效训练,导致此类算法往往仅在合成有雾图像上去雾效果较好。

为解决上述问题,研究者们尝试将基于先验信息的图像复原方法与基于深度学习的图像去雾方法进行结合,即在考虑雾天图像退化机理的同时,利用深度学习强大的学习能力提高算法的去雾效果。例如:Chen等^[15]提出了一种先验信息引导的合成到真实图像去雾网络(Principled Synthetic-to-real Dehazing, PSD),该算法利用多种先验信息对训练好的网络进行精细化调整,从而使调整后的网络在真实有雾图像上获得了较好的图像去雾效果;Shao等^[16]提出了一种域自适应图像去雾算法(Domain Adaption, DA),该算法使用一个双向翻译网络将图像从一个图像域转换到另一个图像域,以弥补真实有雾图像和合成有雾图像之间的域差异。

与此同时,知识蒸馏作为当前深度学习领域一个新兴的研究热点,已在计算机视觉领域取得了显著成就。知识蒸馏技术可将单个教师模型学到的知识传递给学生模型,从而使其具有与教师模型相类似的性能。但由于采用单个教师模型对学生网络进行单向知识传递,训练后的学生模型往往会受限于教师模型的性能。为此,一些研究者提出了多教师知识蒸馏,即通过对多个教师模型的知识进行加权以整合多个教师模型的预测结果来提高算法的性能。目前,多教师知识蒸馏已成功应用于人脸识别^[17]、图像分类^[18]等领域。

借鉴知识蒸馏相关理论,本文提出了一种基于多教师引导的知识蒸馏图像去雾算法(Multi-teacher Guided Knowledge Distillation Dehazing Network, MGKDN)。该算法首先选择EPDN、PSD两种图像去雾算法作为教师模型,然后利用教师模型蕴含的知识指导学生网络的训练;此外,为有效提高学生网络的特征提取能力,构建了一个多尺度的学生网络,该学生网络通过特征注意

残差密集块来提取图像的全局和局部特征。

1 算法描述

基于多教师引导的知识蒸馏图像去雾算法结构如图1所示, 分为教师网络和学生网络两部分。

1.1 教师网络

教师网络由预训练的图像去雾模型EPDN和PSD组成。其中: EPDN是一种端到端的深度学习图像去雾方法, 其网络结构如图2所示。在训练阶段, G1和G2分别作为全局子生成器和局部子生成器, 首先通过下采样和特征融合生成去雾图像, 然后将局部子生成器G2生成的去雾图像作为伪标签与多尺度鉴别器进行对抗训练, 从而提高生成器的性能, 最后使用增强块对提取的特征进行增强, 并生成最终的去雾图像。

PSD是一种先验信息引导的图像去雾方法, 其网络结构如图3所示。该算法以预训练的特征融

合注意力网络为主体, 首先通过增加一个物理兼容块以使网络能够同时生成去雾图像、大气光和透射图, 然后利用由多种先验信息组成的损失引导网络的精细化训练, 从而提升网络的图像去雾性能。需要指出的是, PSD图像去雾算法由于采用先验信息对网络进行二次优化, 可使训练后的模型显著改善去雾图像的颜色对比度和亮度。

1.2 学生网络

通常情况下, 图像局部特征主要反映纹理、结构等信息, 用于增强图像对比度并降低雾霾影响, 而图像全局特征主要反映图像色彩、轮廓等信息, 用于恢复原始图像的视觉效果和颜色保真度。基于此, 本文基于U-Net^[13]架构设计了一个多尺度网络, 并将其作为学生网络, 用于有效提取图像特征, 其网络结构如图1所示。本文所提多尺度网络首先使用两个卷积将图像特征的大小由 $3 \times H \times W$ 变为 $32 \times H \times W$, 其中每个卷积后都使用一个实例归一化层和一个ReLU激活函数,




图1 基于多教师引导的知识蒸馏图像去雾算法结构

Fig. 1 Structure of the image dehazing algorithm based on multi-teacher guided knowledge distillation




图2 EPDN图像去雾算法结构

Fig. 2 Structure of EPDN image dehazing algorithm




图 3 PSD 图像去雾算法结构

Fig. 3 Structure of PSD image dehazing algorithm

然后采用最近邻下采样对特征进行 2 倍和 4 倍下采样, 并分别在 3 个尺度上进行图像特征提取。此外, 为有效增强学生网络的特征提取能力, 本文还设计了特征注意残差密集块作为跳连接, 以使网络能够更加有效地关注图像中的有雾区域。需要指出的是, 由于原始大小的特征具有更多信息, 为此本文在 3 个尺度上分别使用 6、4 和 2 个特征注意残差密集块进行特征提取。

特征注意残差密集块网络结构如图 4 所示。




图 4 特征注意残差密集块网络结构

Fig. 4 Structure of feature attention residual dense block network

首先, 输入 f_1 经过卷积核大小为 3×3 的卷积和 ReLU 激活函数进行初始特征提取, 从而得到预处理特征 f_2 ; 然后将 f_2 分为两个分支, 其中, 分支一经过一个卷积核大小为 3×3 的卷积和 Sigmoid 激活函数, 以生成空间权重图 f_3 , 而分支二则经过一个卷积核大小为 1×1 的卷积和残差密集块继续进行特征提取; 最后, 经过残差密集块提取的特征和空间权重图 f_3 进行像素级相乘, 再与预处理特征 f_2 进行像素级相加, 从而生成中间特征 f_4 。该过程可表示为

$$f_4 = (f_3 \otimes \text{RDB}(f_2)) \oplus f_2 \quad (1)$$

式中: RDB 表示采用残差密集块进行特征提取; $\otimes$ 表示像素级乘法; $\oplus$ 表示像素级加法。

如图 5 所示, 残差密集块^[19]由 5 个卷积组成, 其中: 前 4 个卷积的卷积核大小均为 3×3 , 且在每个卷积后使用一个 ReLU 激活函数; 最后 1 个卷

积的卷积核大小为 1×1 , 但无激活函数。该残差密集块可有效结合残差结构和密集连接结构的优点, 在提取图像边缘和纹理信息的同时, 能够防止浅层信息在传播过程中的丢失。




图 5 残差密集块结构

Fig. 5 Structure of residual dense block

为进一步提高算法在不同场景下的去雾能力, 首先对生成的中间特征 f_4 进行加权处理, 然后使用特征注意机制^[20]生成特征 f_5 , 从而使算法能够对图像中雾霾浓度不同的区域赋予不同的权重, 最后 f_5 再经过一个 Sigmoid 激活函数进行归一化, 并与 f_2 进行像素相乘, 此时加权后的特征与 f_1 进行残差连接就可得到特征注意残差密集块的输出 f_6 。上述过程可表示为

$$f_6 = (\delta(f_5) \otimes f_2) \oplus f_1 \quad (2)$$

式中: δ 代表 Sigmoid 激活函数。

1.3 蒸馏方式

本文结合输出特征知识蒸馏和中间特征知识蒸馏^[21-22]的优势, 从而使学生网络生成的去雾图像无限接近并优于教师模型生成的去雾图像。如图 1 所示, 右侧虚线箭头代表教师模型到学生网络的单向知识蒸馏。具体实现过程中, 算法首先选择在 EPDN 教师模型的全局生成器和采样倍数为 2 的学生网络之间加入中间特征知识蒸馏, 然后在 PSD 教师模型的物理兼容块和采样倍数为 1 的学生网络之间加入中间特征知识蒸馏, 最后在 EPDN 教师模型的输出结果、PSD 教师模型的输出结果和学生网络的输出结果之间加入输出特征知识

蒸馏, 从而有效约束学生网络的训练。

1.4 损失函数

为实现教师模型到学生网络之间的知识蒸馏, 构建如下损失函数以约束整个训练过程, 损失函数可表示为

$$L = \lambda_1 L_1 + \lambda_2 L_2 + \lambda_3 L_3 + \lambda_4 L_4 \quad (3)$$

式中: L 为总损失; L_1 为蒸馏损失; L_2 为感知损失; L_3 为结构相似度损失; L_4 为频域损失; λ_1 、 λ_2 、 λ_3 和 λ_4 为损失权重, 根据各个损失的作用, 本文根据经验将其分别设置为 1、0.4、0.4 和 0.4。

1.4.1 蒸馏损失

图像去雾是一种像素级的图像恢复任务, 为此, 采用像素级损失可快速匹配有雾图像和无雾图像之间的特征分布; 此外, 与 L_2 损失 (均方误差) 不同, L_1 损失 (标准差误差) 能够更稳定地加速网络训练。基于此, 本文算法在教师模型和学生模型之间加入 L_1 损失, 并将其作为蒸馏损失来指导学生网络的训练, 可表示为

$$L_1 = \|s_1 - e_1\| + \|s_2 - p_2\| + \|o - o_1\| + \|o - o_2\| \quad (4)$$

式中: s_1 和 s_2 分别为学生网络采样倍数为 2 和 1 的中间特征; e_1 为 EPDN 教师模型全局生成器生成的中间特征; p_2 为 PSD 教师模型物理兼容块生成的中间特征; o 、 o_1 和 o_2 分别为学生网络、EPDN 教师模型和 PSD 教师模型的输出特征。

1.4.2 感知损失

感知损失能够理解图像的语义信息, 对于图像纹理信息恢复具有重要作用。其通常利用一个训练好的 VGG 网络^[23] 提取图像不同深度的特征, 并利用这些特征作为损失来监督目标生成图像。在本文所提图像去雾算法中, 使用在 ImageNet^[24] 数据集上训练好的 VGG19 网络作为感知损失, 可表示为

$$L_2 = \sum_{i=1}^5 \frac{1}{C^i H^i W^i} \|\Phi^i(o) - \Phi^i(g)\| \quad (5)$$

式中: Φ^i 代表 VGG19 网络所选取的第 i 层网络对图像的特征提取操作, 依据以往的研究工作, 本文分别取第 2、7、12、21 和 30 层; C^i 、 H^i 和 W^i 分别代表提取特征的通道数、高度和宽度; g 为无雾图像。

1.4.3 结构相似度损失

结构相似度 (Structural Similarity, SSIM)

损失是一种典型的特征级损失, 用于评价两幅图像的结构相似程度。为此, 本文算法进一步引入结构相似度损失, 以使生成的去雾图像纹理更加清晰、视觉效果更好, 可表示为

$$L_3 = -r_{\text{SSIM}}(o, g) \quad (6)$$

式中: r_{SSIM} 为结构相似度。

1.4.4 频域损失

通常, 雾霾条件下图像的边缘细节、精细纹理等高频特征会显著降低。为此, 本文算法还设计了一种基于二维离散小波变换的频域损失, 以使模型减少图像去雾过程中的高频分量丢失, 进一步提升图像去雾效果, 可表示为

$$L_4 = \|\text{DWT}(o) - \text{DWT}(g)\| \quad (7)$$

式中: DWT 代表二维离散小波变换。

2 实验结果与分析

2.1 实验设置

实验采用一台 PC 主机进行模型训练和测试, 其 CPU 为 Intel Core i9-7900X, 主频为 3.30 GHz, 内存为 64 GB, GPU 为一张 NVIDIA RTX 3080Ti 显卡。本文所有实验均在 Pytorch 深度学习框架下进行设计和实现。在训练过程中, 随机裁剪训练图像为 256 像素 $\times$ 256 像素, 批处理大小设置为 4, 训练 30 个回合。此外, 采用衰减系数为默认值的 Adam 优化器来加速训练进程, 初始学习率设置为 0.001, 并且每 5 个回合降低为原来的一半。

算法在图像去雾数据集 RESIDE^[25] 的室内训练集 ITS 上进行训练, 并在合成有雾和真实有雾数据集上进行测试。其中训练集包含 1 399 张干净图像以及 13 990 张配对有雾图像。为了验证本文所提算法的有效性和优越性, 选择 DCP^[6]、NLD^[8]、DA^[16]、EPDN^[14] 和 PSD^[15] 5 种图像去雾算法进行实验测试与对比。

2.2 实验结果

2.2.1 合成有雾图像实验结果

在 RESIDE 图像去雾数据集的测试集 SOTS 上进行定性比较, 实验结果如图 6 所示。

从图 6 可以看出: 基于先验信息的图像复原方法 DCP 可有效对图像进行去雾, 但生成的去雾图像会产生严重的颜色畸变, 如图 6 中 DCP 去雾图像的天空区域均呈现异常的蓝色, 此外相比于无雾图像, 该算法生成的去雾图像亮度较暗, 严重




图 6 本文算法与对比算法在 SOTS 测试集的定性对比结果

Fig. 6 Qualitative experimental results of the proposed method and contrast methods on SOTS dataset

影响人的视觉感知效果；与 DCP 图像去雾算法类似，由于单方面假设的先验信息并不适用于所有场景，NLD 图像去雾算法同样未能对图像中的天空区域雾霾进行有效去除，且该算法生成的去雾图像产生了不必要的伪影；DA 图像去雾算法生成的去雾图像具有令人满意的视觉效果，但其在某些图像上仍然会造成一定程度的颜色失真；EPDN 图像去雾算法能够对图像中的雾进行有效去除，但该算法会使生成的去雾图像亮度变暗，对比度下降；PSD 图像去雾算法生成的去雾图像具有较高的亮度和对比度，但颜色的过饱和也使该算法生成的去雾图像看起来不真实；与其他算法相比，本文所提算法 MGKDN 生成的去雾图像颜色更加自然、纹理更加清晰，且保真度高。

为进一步验证算法的性能，在 RESIDE 图像去雾数据集的测试集 SOTS 上进行定量比较，评价指标选择峰值信噪比（Peak Signal-to-Noise Ratio, PSNR）和 SSIM，实验结果如表 1 所示。

从表 1 可以看出：在室内数据集上，算法取得了最优的图像去雾结果，其 PSNR 和 SSIM 分别为 30.87 dB 和 0.982；在室外数据集上，算法同样取得了最好的图像去雾结果，且与次优算法 DA 相比，所提算法将 PSNR 从 22.59 dB 提高到了 23.57 dB，同时将 SSIM 从 0.927 提高到了 0.934。上述实验结果表明，MGKDN 在室内和室外数据集上均能有效去雾。

表 1 不同算法在 SOTS 测试集的定量对比结果

Tab. 1 Quantitative experimental results of different methods on SOTS dataset

算法	室内数据集		室外数据集	
	PSNR/dB	SSIM	PSNR/dB	SSIM
DCP	19.95	0.872	20.44	0.898
NLD	17.29	0.801	18.11	0.871
EPDN	25.09	0.932	20.32	0.902
PSD	16.32	0.729	15.15	0.771
DA	30.32	0.981	22.59	0.927
MGKDN	30.87	0.982	23.57	0.934

2.2.2 真实有雾图像实验结果

为进一步验证算法性能，将其与对比算法在真实有雾数据集 URHI 上进行比较，实验结果如图 7 所示。

从图 7 可以看出：基于先验信息的图像复原方法 DCP 倾向于使去雾后的图像亮度变暗，特别是在天空区域会产生伪影，进而影响去雾图像的视觉效果；NLD 图像去雾算法虽可以有效地对图像进行去雾，但生成的去雾图像存在严重的颜色失真，从而使其视觉效果较差；相比之下，基于深度学习的图像去雾方法往往导致去雾不够彻底，会生成欠去雾的图像。例如：DA 和 EPDN 图像去雾算法在图像的某些区域仍会造成一定程度的雾



图 7 本文算法与对比算法在 URHI 数据集的对比实验结果

Fig. 7 Contrast experiment results of the proposed method and contrast methods on URHI dataset

残留，且图像的纹理特征不够明显；PSD 图像去雾方法生成的去雾图像亮度更亮、对比度更高，然而由于该算法在部分区域增强过度，其生成的去雾图像仍产生了一定程度的过饱和。相比之下，MGKDN 算法使模型在有效去雾的同时，能够极大程度上避免去雾过程中产生的去雾图像颜色失真，从而在真实有雾图像上呈现了较好的图像去雾效果。

2.2.3 消融实验

本文通过消融实验验证了特征注意残差密集块、EPDN 教师模型知识蒸馏、PSD 教师模型知识蒸馏、频域损失函数等关键模块对本文算法的贡献。具体地，本文对以下变体进行评估：变体 A，算法未采用特征注意残差密集块、EPDN 和 PSD 教师模型知识蒸馏和频域损失函数；变体 B，算法未采用 EPDN 和 PSD 教师模型知识蒸馏和频域损失函数；变体 C，算法未采用 EPDN 教师模型知识蒸馏和频域损失函数；变体 D，算法未采用 PSD 教师模型知识蒸馏和频域损失函数；变体 E，算法未采用频域损失函数；变体 F，本文 MGKDN 算法。在 ITS 数据集上将这些变体训练 30 个回合，并在 SOTS 测试集对其进行测试，实验结果如表 2 所示。

实验结果表明：上述关键模块在本文所提算法中均有重要作用；此外，从变体 B 和变体 E 的比较结果来看，将多教师模型蕴含的知识对学生网络进行单向传递能够大幅改善图像去雾结果，并可有效缓解去雾过程中存在的图像颜色失真严

重等问题。

表 2 本文算法在 SOTS 测试集的消融实验结果

Tab. 2 Ablation experiment results of the proposed method on SOTS dataset

评价指标	PSNR/dB	SSIM
变体 A	19.73	0.894
变体 B	21.25	0.892
变体 C	21.36	0.889
变体 D	21.70	0.898
变体 E	23.28	0.907
变体 F	23.57	0.934

3 结论

本文基于知识蒸馏相关理论，研究提出了一种基于多教师引导的知识蒸馏图像去雾算法 MG-KDN，该算法选择图像去雾领域公开发布的去雾算法 EPDN 和 PSD 作为教师模型，能够有效结合基于先验信息的图像复原方法和基于深度学习的图像去雾方法的互补优势。同时以特征注意残差密集块为基本结构，设计了一个多尺度学生网络来提高网络的特征提取能力。在合成有雾数据集和真实有雾数据集上的实验结果均表明，本文所提算法在提升图像去雾性能的同时，可有效缓解图像去雾过程中产生的全局和局部颜色失真问题。

参考文献:

- [1] LIU L Q, WANG X H, BAO Q F, et al. Behavior detection and evaluation based on multi-frame MobileNet[J]. *Multimedia Tools and Applications*, 2024, 83(6): 15733-15750.
- [2] KUMAR JAIN D, ZHAO X D, GARCIA S, et al. Robust multi-modal pedestrian detection using deep convolutional neural network with ensemble learning model[J]. *Expert Systems with Applications*, 2024, 249(4): 123527.
- [3] TREIBITZ T, SCHECHNER Y Y. Polarization: Beneficial for visibility enhancement? [C]//2009 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2009: 525-532.
- [4] CUI Z G, WANG N, SU Y Z, et al. ECANet: Enhanced context aggregation network for single image dehazing[J]. *Signal, Image and Video Processing*, 2023, 17(2): 471-479.
- [5] WANG N, CUI Z G, SU Y Z, et al. RGNAM: Recurrent grid network with an attention mechanism for single-image dehazing[J]. *Journal of Electronic Imaging*, 2021, 30(3): 33026.
- [6] HE K M, SUN J, TANG X O. Single image haze removal using dark channel prior[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2011, 33(12): 2341-2353.
- [7] FATTAL R. Dehazing using color-lines[J]. *ACM Transactions on Graphics*, 2014, 34(1): 1-14.
- [8] BERMAN D, TREIBITZ T, AVIDAN S. Non-local image dehazing[C]//2016 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2016: 1674-1682.
- [9] SU Y Z, HE C, CUI Z G, et al. Physical model and image translation fused network for single-image dehazing[J]. *Pattern Recognition*, 2023, 142(1): 109700.
- [10] QIN X, WANG Z L, BAI Y C, et al. FFA-Net: Feature fusion attention network for single image dehazing [C]//2020 AAAI International Conference on Artificial Intelligence. Piscataway, NJ, USA: IEEE, 2020: 11908-11915.
- [11] CHEN D D, HE M M, FAN Q N, et al. Gated context aggregation network for image dehazing and deraining[C]//2019 IEEE Winter Conference on Applications of Computer Vision. Piscataway, NJ, USA: IEEE, 2019: 1375-1383.
- [12] DONG H, PAN J S, XIANG L, et al. Multi-scale boosted dehazing network with dense feature fusion[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2020: 2154-2164.
- [13] RONNEBERGER O, FISCHER P, BROX T. UNet: Convolutional networks for biomedical image segmentation[C]//2015 Medical Image Computing and Computer-Assisted Intervention. Piscataway, NJ, USA: IEEE, 2015: 234-241.
- [14] 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. Piscataway, NJ, USA: IEEE, 2019: 8152-8160.
- [15] CHEN Z Y, WANG Y C, YANG Y, et al. PSD: Principled synthetic-to-real dehazing guided by physical priors[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2021: 7176-7185.
- [16] SHAO Y J, LI L, REN W Q, et al. Domain adaptation for image dehazing[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2020: 2805-2814.
- [17] CHENG T C, ZHANG Y, YIN Y F, et al. A multi-teacher assisted knowledge distillation approach for enhanced face image authentication[C]//International Conference on Multimedia Retrieval. Piscataway, NJ, USA: IEEE, 2023: 107-119.
- [18] XIANG L Y, DING G G, HAN J G. Learning from multiple experts: Self-paced knowledge distillation for long-tailed classification[C]//2020 European Conference on Computer Vision. Glasgow, UK: Springer, 2020: 247-263.
- [19] ZHANG Y L, TIAN Y P, KONG Y, et al. Residual dense network for image super-resolution [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2018: 2472-2481.
- [20] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]//2018 European Conference on Computer Vision. Munich, Germany: Springer, 2018: 3-19.
- [21] WANG T, YUAN L, ZHANG X P, et al. Distilling object detectors with fine-grained feature imitation[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2019: 4928-4937.
- [22] LIU Y F, CHEN K, LIU C, et al. Structured knowledge distillation for semantic segmentation

- [C]//2019 IEEE / CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2019: 2599-2608.
- [23] SHAHA M, PAWAR M. Transfer learning for image classification[C]//2018 International Conference on Electronics, Communication and Aerospace Technology. Piscataway, NJ, USA: IEEE, 2018: 656-660.
- [24] DENG J, DONG W, SOCHER R, et al. ImageNet: A large-scale hierarchical image database [C]//2009 IEEE / CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2009: 248-255.
- [25] LI B Y, REN W Q, FU D P, et al. Benchmarking single image dehazing and beyond[J]. IEEE Transactions on Image Processing, 2019, 28 (1): 492-505.