计算机科学
COMPUTER SCIENCE

亮度自调节的无监督图像去雾与低光图像增强算法研究

王斌, 梁宇栋, 刘哲, 张超, 李德玉

引用本文

王斌, 梁宇栋, 刘哲, 张超, 李德玉.亮度自调节的无监督图像去雾与低光图像增强算法研究[J]. 计算机科学, 2023, 50(1): 123-130.

WANG Bin, LIANG Yudong, LIU Zhe, ZHANG Chao, LI Deyu. Study on Unsupervised Image Dehazing and Low-light Image Enhancement Algorithms Based on Luminance Adjustment [J]. Computer Science, 2023, 50(1): 123-130.

相似文章推荐（请使用火狐或 IE 浏览器查看文章）

Similar articles recommended (Please use Firefox or IE to view the article)

一种基于强化学习的口令猜解模型

Password Guessing Model Based on Reinforcement Learning

计算机科学, 2023, 50(1): 334-341. https://doi.org/10.11896/jsjkx.211100001

基于双向注意力机制和门控图卷积网络的文本分类方法

Text Classification Method Based on Bidirectional Attention and Gated Graph Convolutional Networks

计算机科学, 2023, 50(1): 221-228. https://doi.org/10.11896/jsjkx.211100095

预训练语言模型的应用综述

Survey of Applications of Pretrained Language Models

计算机科学, 2023, 50(1): 176-184. https://doi.org/10.11896/jsjkx.220800223

融合注意力特征的无锚框视觉目标跟踪方法

AFTM:Anchor-free Object Tracking Method with Attention Features

计算机科学, 2023, 50(1): 138-146. https://doi.org/10.11896/jsjkx.211000083

基于移位窗口金字塔Transformer的遥感图像目标检测

SPT:Swin Pyramid Transformer for Object Detection of Remote Sensing

计算机科学, 2023, 50(1): 105-113. https://doi.org/10.11896/jsjkx.211100208

计算机科学 COMPUTER SCIENCE
http://www.jsjkx.com
DOI:10.11896/jsjkx.211100058

亮度自调节的无监督图像去雾与低光图像增强算法研究

王 斌 梁宇栋 刘 哲 张 超 李德玉
山西大学计算机与信息技术学院 太原 030006
(202022407046@email.sxu.edu.cn)

摘 要 在低质图像降质问题中,亮度偏离(如图像偏亮及偏暗)是较为常见的图像降质现象。基于全监督学习的图像增强方法面临训练数据难以获取或获取成本过高、训练数据和应用场景不一致的困境。针对以上问题,提出了一种能够克服数据依赖和亮度自适应的无监督图像增强方法。方法的具体细节为:针对图像去雾与低光增强任务,设计了一个基于通道与像素注意力的深度卷积网络,对增强图像与输入图像进行比较,采用亮度饱和度、空间一致性、照明平滑度、伪标签监督损失等多种无监督损失函数,在保证增强图像与输入图像一致性的同时,调节图像的亮度偏离程度,有效提高图像质量。实验结果表明,所提方法在客观指标及视觉效果上不仅优于传统方法和基于无监督学习的方法,甚至优于近年来的全监督图像增强方法。将所提方法与5种图像去雾方法及4种低光增强方法分别进行对比,相比性能次优的方法,其在图像去雾任务的Reside数据集上,PSNR和SSIM值分别提高了2.8dB和0.01;在低光增强任务的SICE数据集上,PSNR和SSIM分别提高了0.56dB和0.01。结果表明,所提无监督图像去雾与低光增强算法能够有效调节图像的亮度偏离程度,重建了亮度正常、细节清晰、对比度较好的增强复原图像,较为有效地克服了当前底层视觉任务数据难以获取、训练数据与应用数据不一致、存在域迁移的难题,提升了算法在应用中的适用性。

关键词:无监督学习;亮度调节;图像去雾;低光增强;深度学习
中图法分类号 TP391

Study on Unsupervised Image Dehazing and Low-light Image Enhancement Algorithms Based on Luminance Adjustment

WANG Bin,LIANG Yudong,LIU Zhe,ZHANG Chao and LI Deyu
School of Computer and Information Technology,Shanxi University,Taiyuan 030006,China

Abstract Among the degradations of low-quality images,luminance deviations such as brighter or darker images are very common image degradation phenomena. The image enhancement method based on fully supervised learning faces the dilemma that the training data is difficult to obtain or the acquisition cost is too high,and the training data is inconsistent with the application scene. To handle these problems,an unsupervised image dehazing and low-light enhancement algorithm based on luminance adjustment is proposed in this paper. A deep architecture with channel attention and pixel attention mechanism are designed to measure the differences between enhanced images and input low-quality images. A variable quadratic function has been applied to adjust the pixel luminance of the image. Multiple unsupervised losses i.e.,brightness saturation loss,spatial consistency loss,illumination smoothness loss and pseudo-label supervision loss are utilized to alleviate the illumination deviations but to ensure the identity between the enhanced images and the input low-quality images,which efficiently improve the quality of the images. Empirically,an intensity compression strategy is applied for the hazy images to darken the hazy images to have a similar intensity range with low-light images. Thus,the hazy images can be treated equally with low-light images with our deep network to adjust the luminance of the image. For the dehazing task,compared with the second-best method,our method improves the PSNR value

到稿日期:2021-11-05 返修日期:2022-07-28
基金项目:国家自然科学基金(61802237,62272284,61906114);山西省自然科学基金(201901D211176,201901D211170,202103021223464);山西省高等学校科技创新项目(2019L0066);山西省科技重大专项计划(202101020101019);山西省重点研发计划(国际科技合作,201903D421041;能源与节能环保领域202102070301019);山西省科技创新人才团队专项资助
This work was supported by the National Natural Science Foundation of China(61802237,62272284,61906114),Natural Science Foundation of Shanxi Province(201901D211176,201901D211170,202103021223464),Scientific and Technological Innovation Programs of Higher Education Institutions in Shanxi(2019L0066),Science and Technology Major Project of Shanxi Province(202101020101019),Key R&D Program of Shanxi Province(International Cooperation,201903D421041,Energy Conservation and Environmental Protection,202102070301019) and Special Fund for Science and Technology Innovation Teams of Shanxi Province.
通信作者:梁宇栋(liangyudong@sxu.edu.cn)

for 2.8 dB and SSIM value for 0.01 in RESIDE dehazing dataset. For the low-light enhancement task, our method outperforms the second-best method for 0.56 dB and 0.01 separately measured by PSNR and SSIM in the SICE dataset. The proposed image dehazing and low-light enhancement algorithms can restore high-quality images from hazy images and low-light images. It effectively overcomes the difficulty of acquiring the targeted enhanced data or alleviates the problem of domain gap between training data and application data in the low-level vision tasks, which improves its adaptivity in real applications.

Keywords Unsupervised learning, Luminance adjustment, Image dehazing, Low-light enhancement, Deep Learning

1 引言

成像设备常因为不良成像条件或设备成像技术的限制而采集到大量的低质图像，如存在雨、雾、霾、沙尘或亮度过暗的图像。这些低质图像不仅严重影响人们的观感，也严重降低了目标检测、图像分类等上游任务的算法精度。

在低质图像的降质问题中，亮度偏离是较为常见的图像降质现象。低光图像亮度偏暗，有雾图像则由于光线的大气散射效应，图像发白，亮度偏亮。低质图像亮度偏移往往伴随着细节信息模糊与清晰度差等图像退化情况。为了解决低质图像亮度偏离的问题，研究者们提出了大量的解决策略，这些方法大体可以分为两类：传统方法与基于深度学习的方法。传统方法往往基于图像的像素统计分布或先验信息，进行图像增强，如基于直方图的低光图像增强方法[1]、暗通道先验去雾方法[2]以及基于 Retinex 的图像增强方法[3]；基于深度学习的图像增强方法[4-6]往往从海量数据集中学习低质图像到目标增强图像间的映射关系，其借助深度模型强大的特征提取能力，能够生成更高质量的复原增强图像。基于深度学习的低质图像增强方法已成为图像增强领域的主流研究方向。

然而，现有的基于深度学习的低质图像增强方法主要采用监督学习方法，其性能极大地依赖于使用的训练数据集与实际应用场景的一致性。低质图像增强数据集的构建需要收集低质图像和对应的目标增强复原图像，而真实场景中往往难以获取低质图像对应的目标增强复原图像，或获取目标图像的成本较高，需要大量的人力物力。在图像去雾任务中往往采用大气光散射模型，将清晰图像退化模拟生成不同浓度的有雾图像，从而构建数据集。真实场景有雾图像的成像与数据集合成图像的成像过程往往存在不一致性，造成了去雾算法在真实场景中的性能退化。在低光增强任务中，构建真实场景的低照度图像和清晰图像数据需要严格的成像条件控制，现有低光增强数据集图像无法全面涵盖真实的应用场景，训练集与应用场景的域迁移问题阻碍了基于深度学习的低光增强算法性能的进一步提升。

无监督学习算法为克服目标增强监督图像缺失及模型训练与应用时的领域差异难题提供了解决思路。基于无监督学习的图像增强算法仅仅依赖输入的低质图像本身，其根据低质图像本身的特性，学习数据的内在分布，提取较有判别力的特征进行图像增强，有效地避免了目标增强图像的数据缺失或应用场景与训练数据存在域迁移的难题。另一方面，深度网络的注意力机制借鉴人类视觉，将深度模型的计算资源聚焦于计算输入或特征图的难点部分，能够有效提升模型面对低质图像进行增强过程的建模与特征提取能力。

有雾图像与低光图像分别存在亮度偏亮、偏暗的亮度偏差。对于低光增强问题，本文采用基于深度学习的无监督学习方法，采用注意力机制与精心设计的损失函数，来提取更有判别力的特征，自适应地调整较暗的图像亮度，从而重建亮度正常、细节清晰、对比度较好的增强复原图像。对于有雾图像，本文引入亮度收缩过程，将图像亮度映射到较暗的亮度空间，进而采用同样的无监督学习过程，通过亮度自适应调整，最终达到图像去雾增强的目的。实验表明，本文建立了一种亮度自适应的无监督图像增强方法，能够有效进行低光增强与图像去雾，在相关数据集上，本文算法的性能超越了现有的性能最优的无监督低光增强与图像去雾方法，并能够和有监督学习的图像增强方法相媲美。其重建了亮度正常、细节清晰、对比度较好的增强复原图像，有效避免了监督学习模型在存在域迁移的应用场景下性能退化的问题。

2 相关工作

研究者对低光增强、图像去雾等低质图像增强任务进行了大量探索，而无监督学习为解决低质图像增强领域训练数据获取困难等难题提供了解决思路，日益成为研究热点。本节将分别从低光增强、图像去雾与无监督方法 3 个方面对相关研究进行回顾。

2.1 低光图像增强

传统的低光增强方法主要通过图像处理方法来调节图像亮度，例如通过直方图均衡化[3,7]来调节图像动态范围，以及利用基于 Retinex 的方法及其衍生方法[8-9]来提高图像亮度。但直方图均衡化与基于 Retinex 的方法无法根据输入图像的内容进行调节，且增强图像有时会产生不理想的照明效果或有噪声。近年来，基于深度学习的方法相比传统低光增强方法在性能上有了巨大的提升。基于深度学习的方法设计网络架构，使用海量数据进行长时间的训练，能够在指定数据集上生成质量极高的复原增强图像。研究者设计了不同网络架构的众多低光增强模型[10-12]，其中文献[12]提出的 LLNet 利用深度自编码器在合成数据上进行图像低光增强，能够在提升图像较暗部分的亮度的同时，避免图像较亮部分出现过饱和现象。基于深度学习的方法是基于数据的方法，与传统的方法相比，其图像修复的质量更高，噪声更少；但基于全监督的深度学习低光增强方法的训练集或采用合成数据，或无法涵盖应用场景，存在域迁移的难题。

为了克服对监督数据的依赖，文献[13]提出了基于半监督学习的低光修复网络。该网络结合了全监督与无监督学习的优势，取得了高质量的修复效果，但其并未真正摆脱对真实标签的依赖。文献[14]提出了基于对抗学习的无监督网络

EnlightenGAN，其不需要使用配对的训练图像数据即可完成低光增强任务。但由于对抗网络的不稳定性，该方法仍需要挑选恰当且有效的非配对数据对网络进行监督，且其生成的图像中有时存在较为明显的伪影。本文方法采用无监督学习思想，但不依赖对抗网络，算法较为稳定，可以取得较好的恢复效果；且模型能够进行亮度的自适应调整，通过使用精心设计的损失函数对生成结果进行约束，最终达到了观感良好的恢复效果。

2.2　图像去雾

传统的图像去雾方法往往采用某种先验假设进行图像处理，能够在某些数据上实现较好的去雾效果，代表性的算法有暗通道先验[2]与非局部图像去雾方法[15]。对于先验假设不满足的图像，传统方法通常存在严重色偏，图像恢复效果较差。随着深度学习技术的发展，大量基于深度学习的算法使用大规模合成数据集，取得了远超传统算法的去雾表现，并成为图像去雾算法研究领域的主流研究方向。文献[5]提出了FFA-Net，该算法使用通道注意力与像素注意力以及全监督的学习策略，在 SOT 测试集上取得了当时最优的图像去雾结果。该方法证明了注意力机制对特征提取的有效性。本文提出的方法同样采用了注意力机制来提取特征并对图像的亮度进行调节，取得了高质量的去雾结果。文献[16]根据大气光散射模型，设计了同时估计光传播率与大气光值的深度网络 DCPDN 算法。该算法充分体现了深度学习模型强大的特征提取能力，但它极大地依赖于合成数据中光的传播率，无雾图像的数据监督约束，制约了该方法在真实数据的表现。

图像去雾的研究者同样在探索使用半监督或无监督的学习算法克服目标增强图像的数据缺失以及应用场景与训练数据存在域迁移的难题。文献[17]提出了一个半监督的去雾网络，该网络采用两阶段的训练策略，期望将有标签数据的先验信息迁移到无标签数据的修复上，但该策略使得模型学到的先验偏向于建模有标签数据的数据分布，限制了其在不同真实场景的去雾表现。文献[18]提出的无监督图像增强网络 DDIP 将 3 个随机噪声作为输入，并将其输入 3 个生成网络中，通过早期停止的策略来生成去雾图。然而，早期停止的策略造成了修复结果的不稳定性，需要研究人员具有丰富的经验。本文方法通过亮度自适应调整，能够更好地调整真实场景中有雾图像的亮度信息，提升图像的对比度，恢复较为清晰的图像细节。本文方法不需要光传播率图或清晰无雾图像进行监督，同时无监督的学习策略使得当前方法不会受到应用时数据域迁移的难题的影响，能够在不同的合成数据集与真实数据集上取得高质量的去雾效果。

2.3　基于深度学习的无监督图像处理

基于深度学习的无监督图像增强是一项极具挑战性的任务，研究者们也进行了大量探索。文献[19-20]利用对抗学习零和博弈的训练策略结合高质量的非配对数据进行图像增强。文献[21]通过重新设定对抗博弈的训练范式来优化低质图像的修复效果，但对抗学习的训练难度较大，过程有时不太稳定，应用中生成图像的质量参差不齐，且生成的部分图像中存在伪影。文献[22]从构造无监督学习的监督信息出发，采用双目图像视差估计任务辅助单目深度估计任务的学习，利用图像视差与深度内在几何关系监督网络的输出。该策略需要引入额外数据，实际应用时对单幅图深度估计任务构造视差估计的过程会引入额外误差，进而影响算法性能。文献[23]提出采用相同噪声分布的含噪图像来训练神经网络，避免了含噪图像对应的清晰图像无法获取的难题，但该方法相比采用清晰图像的全监督学习过程，仍存在一定的性能损失，对于存在某种统一模式的噪声，性能不佳。文献[24]提出的零参考低光图像增强方法 Zero-DCE 通过对亮度曲线进行迭代式的高阶调整，克服了需要使用清晰参考图像训练低光图像增强模型的局限性，取得了较好的低光增强效果。

本文同样采用了亮度调整的思想，但与 Zero-DCE[24]不同的是，本文舍弃了迭代式的亮度高阶逼近方法，而是设计了无监督深度网络，直接进行亮度调整，减少了迭代的计算量及迭代阶数的选取。本文方法未使用对抗学习的方式，不需要配对或者非配对数据来训练网络，只需要低质量输入图像本身，极大地降低了训练难度。本文提出的方法通过采用注意力机制与图像特性度量损失函数（亮度饱和度损失、空间一致性损失、照明平滑度损失）对输出进行约束，能够保留增强图像与输入图像的同一性并实现亮度调节，从而完成较高质量的图像增强。

3　本文方法

本文提出的基于亮度自调节、采用注意力机制的无监督图像增强模型是一个端到端的深度卷积网络模型，输入低光或有雾图像，能够得到低光增强图像或去雾图像。如图 1 所示，整个无监督图像增强模型由两个部分组成，分别是基于注意力机制的特征提取层（FA 组件）与重建高质量图像的图像重建层。

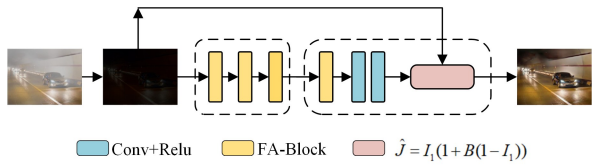


图 1　基于亮度自调节的无监督图像去雾与低光增强网络

Fig. 1　Unsupervised image dehazing and low-light enhancement network based on luminance adjustment

该模型首先通过基于像素与通道双重注意力机制的特征提取层对低质输入图像进行特征抽取，特征提取层包含 3 个基于注意力机制的 FA 组件，每个 FA 组件由通道注意力模块与像素注意力模块级联而成，网络层与卷积之间均使用 Relu 层作为激活函数，特征抽取层的特征维度即通道数保持在 32。模型的图像重建层根据亮度自适应可变二次函数来完成图像的增强映射，其能够有效学习该函数的亮度调节参数 B，达到亮度自适应调节的效果。图像重建层通过 1 个 FA 组件对特征提取层提取的特征进行降维，并根据注意力机制进行特征加权，特征维度会由 32 降低到 24，随后，特征经过 2 个卷积映射到亮度自适应可变二次函数的亮度调节参数 B。模型通过应用恰当的损失函数对输出与低质输入图像进行

比较，在调节图像亮度的同时保证增强图像与低质输入图像的同一性，最终得到高质量的增强图像。下面将分别介绍算法细节与各个网络模型组件。

3.1 数据预处理

低光图像和有雾图像均存在亮度偏离，且伴随着图像对比度低、细节信息模糊、清晰度差等图像退化情况。其中低光图像亮度偏暗，有雾图像由于光线的大气散射效应，图像发白，亮度偏亮。而在图像去雨、图像去反射光与图像去噪任务中，整幅图像的亮度偏离问题并不严重，主要是去除图像中的干扰信息。各类低质图像在视觉感知上明显不同。为了探讨该问题，本文对雾图、低光图、自然图像、雨图与添加噪声的图像的像素亮度数值(即 0.30R+0.59G+0.11B)的分布进行了统计，如图 2 所示，不同图像的像素值分布不同，相比高质量的自然图像，低光图像多数像素值偏低，而雾图多数像素值偏高；高质量的自然图像、雨图与包含噪声的图像像素值分布大体一致。

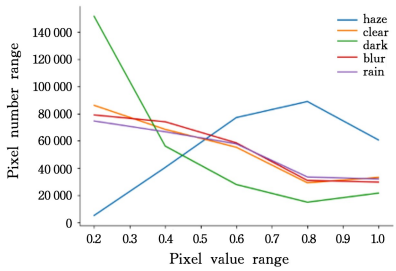


图 2 雾图、雨图、噪声图、低光图与清晰图的像素值分布

Fig. 2 Pixel value distribution of haze, rain, noise, low light and clear images

为了有效地处理存在亮度偏离的低光图像与有雾图像这两类数据，利用亮度变换的策略将雾图变暗，或将低光图像变亮，将两类图像变换为较为一致的亮度分布空间。如图 2 所示，低光图像较亮的像素数目比有雾图像亮度较暗的像素数目更少。同时在实验中发现，通过映射变换，部分低光图像中的较暗区域无法通过亮度增强达到较好的视觉效果，而将雾图变暗则不存在局部区域无法变暗的问题，故本文提出通过亮度压缩过程，将雾图变暗，从而将雾图的亮度分布变换到与低光图像一致的区间，进而采用无监督方法，实现同一网络对两类数据进行亮度调节的目的。

3.2 特征抽取层

特征抽取层主要由基于注意力机制的网络组件 FA 模组构成，图 3 给出了 FA 模组的具体结构。

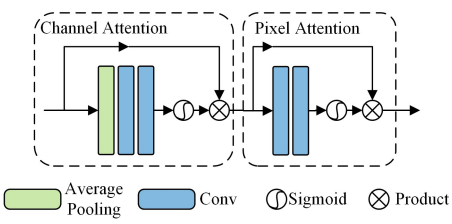


图 3 由通道注意力与像素注意力模块组成的 FA 组件

Fig. 3 FA component composed of channel attention and pixel attention unit

我们在实验中发现，雾与低光等不利成像条件对真实场景低质图像的不同像素或不同颜色通道的干扰强度并不一致，这就要求图像增强模型对不同像素与不同颜色通道应采用不同的特征提取方式，而注意力机制有助于建模该问题。类似文献[5]提出的工作，FA 组件包含了通道注意力与像素注意力双机制，针对不同数据分布，特征注意力机制模块可对不同通道特征和不同位置像素进行不同程度的关注，这可以为模型处理不同信息提供额外的灵活性，并可有效扩展卷积神经网络的表达能力。

3.2.1 通道注意力

本文方法引入的通道注意力模块具体操作为：首先对待处理特征 F_c 的每一个通道采用全局平均池化操作，求出每个通道的平均值，特征维度由 $C\times H\times W$ 转变为 $C\times 1\times 1$。此时特征的每个通道利用特征度量来表示响应强度。随即将该 $C\times 1\times 1$ 维度的特征度量输入两层卷积与 Sigmoid 激活函数，表达式如下：

$$C_A=Conv(\delta(Conv(Avgpool(F_c)))) \tag{1}$$

其中，F_c 代表网络中间某层的多通道特征，$Conv$ 代表卷积层，δ 代表 Sigmoid 激活函数，C_A 代表不同通道的加权系数。最后将加权系数与多通道特征进行点乘，得到通道注意力的输出：

$$F_c^*=C_A\otimes F_c \tag{2}$$

3.2.2 像素注意力

低质图像不同位置的雾浓度或低光退化程度并不均匀，因此本文引入了一个像素注意力模块，使得特征提取网络更加关注降质严重的区域以及图像高频区域的信息特征。具体操作是，与通道注意力计算相似，首先将通道注意力生成的特征输入卷积与 Sigmoid 激活函数。

$$P_A=Conv(\delta(Conv(F_c^*))) \tag{3}$$

其中，F_c^* 代表通道注意力输出的结果，$Conv$ 代表卷积层，δ 代表 Sigmoid 激活函数，P_A 代表不同像素的加权系数。然后将不同像素的加权系数与通道注意力的输出进行点乘，得到计算结果：

$$F_p^*=P_A\otimes F_c^* \tag{4}$$

3.3 图像重建层与损失函数

有雾图像与低光图像均存在亮度偏移降质现象。有雾图像发白，亮度偏亮；低光图像亮度不足。本文引入的图像重建层与损失函数主要针对存在亮度偏移的低质图像增强问题，尤其适合图像去雾与低光图像增强问题。而对于亮度偏移不明显的低质图像，如失焦图像、有雨图像与含噪图像，本文方法无法进行有效处理。本文运用的亮度饱和度损失(见式(6))，能够有效抑制色偏，使得去雾图像和低光增强图像的亮度饱和度分布更加符合自然图像的分布规律；运用的空间一致性损失(见式(7))能够保证去雾图像和输入的有雾图像、低光增强后的图像和低光图像具有邻域间的一致性；采用的照明平滑度损失(见式(8))，能够建模自然图像具有的平滑性，从而增加了去雾及低光增强后图像的局部平滑性。通过运用多重损失，有效减少了去雾图像及低光增强图像的亮度

偏移，使得去雾及低光增强图像更加符合自然图像的数据分布。以下是对图像重建层与损失函数的详细介绍。

图像重建层由 1 个注意力组件、2 个卷积组件与 1 个图像亮度调节函数构成。本文采用的亮度调节函数主要参考文献[24]提出的工作，增强后的图像亮度可由输入图像的亮度经过自适应可变二次函数变化得到。函数的数学定义如下：

$$\hat{J}=I_1(1+B(1-I_1)) \tag{5}$$

其中，$\hat{J}$ 代表增强后的图像，I_1 代表输入的低质量图像，B 代表增强曲线的亮度调节参数，自适应增强曲线的参数 B 完全依赖于输入图像。该二次函数可微，具有良好的单调性，能够保持输入图像像素之间的相对亮度关系。

根据文献[15]提出的假设，成像良好的自然图像的亮度饱和度之差应尽可能趋向于 0。依据该假设，对于亮度偏离的低质图像，本文使用了亮度饱和度损失，其定义如下：

$$L_{vs}=\| V(\hat{J}_p)-S(\hat{J}_p) \|_F \tag{6}$$

其中，$\hat{J}_p$ 代表网络修复的图像，V 计算图像亮度，S 计算图像的饱和度。

该损失函数可有效抑制修复函数对生成图像造成的色偏，使增强图像 3 个色道的分布趋向于自然图像。

为了使生成图像的纹理结构与输入图像一致，本文使用了空间一致性损失，该损失函数可以有效保证输出与输入之间的邻域一致性。其定义如下：

$$L_{spa}=\frac{1}{K}\sum_{i=1}^{K}\sum_{j\in\Omega(i)}(|\hat{J}_i-\hat{J}_j|-|I_i-I_j|)^2 \tag{7}$$

其中，K 是局部区域的数量，$\Omega(i)$是以区域 i 为中心的 4 个相邻区域（上、下、左、右），$\hat{J}$ 和 I 分别表示为增强图像和输入图像中局部区域的强度平均值。根据经验设置局部区域大小为 4×4。

为了保持相邻像素之间的单调性关系，本文认为亮度调节参数 B 应当平滑变化，故增加了照明平滑度损失，其定义如下：

$$L_{tv}=\sum_{c\in\xi}(|\nabla_x B_n^c|+\nabla_y B_n^c)^2,\xi=\{R,G,B\} \tag{8}$$

其中，∇_x 与 ∇_y 分别为水平方向与垂直方向的梯度运算。

本文模型采用的损失函数由以上函数共同构成：

$$L_{total}=L_{vs}+L_{spa}+w_{tv}L_{tv} \tag{9}$$

其中，w_{tv} 为损失的权重。该组合损失可以有效提高低光增强的复原效果，但对于图像去雾任务，增强图像中仍有局部区域存在雾块。为了解决该问题，本研究引入了多重伪标签监督损失，其中伪标签由雾图通过简单的伽马变换的亮度调节生成。其定义如下：

$$L_{fake}=\sum_i w_i \| \hat{J}_p-J_i^{fake} \| \tag{10}$$

其中，J_i^{fake} 代表子伪标签；w_i 为每个子伪标签监督损失的超参数，且超参数之和等于 1。实验表明，伪标签的引入能够有效提高算法复原效果。

最终用于图像去雾的总损失函数如下：

$$L_{total}=L_{vs}+L_{spa}+w_{tv}L_{tv}+L_{fake} \tag{11}$$

4　实验介绍

4.1　数据集介绍与实验细节

对于低光增强任务，本文采用文献[10]提出的 SICE 多重曝光数据集的第一部分即 360 组低光图像作为训练集，将第二部分数据作为测试集。该数据集被广泛应用于低光增强的研究中，如文献[13-14]提出的低光增强工作。

对于图像去雾任务，本文采用了业内广泛应用的 RESIDE 数据集[25]，其中的 ITS 子数据集包含 14 900 组图像对。本文采用通用的做法，即采用 ITS 作为训练集，SOTS 作为测试集。对于大面积有雾场景，本文使用了 KITTI 道路场景数据集[26]。本文方法在两类数据集及网络搜索得到的真实数据上与主流去雾工作进行了比较。

本实验在 Ubuntu18.04 平台上采用 PyTorch 工具池实现，显卡型号为 Nvidia-2080Ti，CUDA 型号为 10.1。在网络初始训练阶段，使用 Adam 作为模型优化器，初始学习率为 0.000 1，使用 plateau 作为学习率衰减策略。

为了更好地分析不同方法的客观评价结果，本文采用峰值信噪比（PSNR）与结构相似性（SSIM）两种度量方法作为标准。PSNR 用于分析增强图像与真实数据之间的失真程度，SSIM 用于评价二者之间的几何、色彩、对比度等的一致性。

4.2　低光增强

对于低光增强任务，本文与业界性能最好的 4 类算法进行了比较，分别是：文献[27]提出的通过加权可变模型同时预测照明图与反射图进而实现低光增强的方法 SRIE、文献[28]提出的通过准确预测照明图来实现低光增强的方法 LIME、文献[4]提出的基于 Retinex 分解实现图像复亮的深度神经学习网络 RetinexNet，以及文献[14]提出的使用非配对数据实现低光增强的无监督学习对抗网络 EnlightenGAN。

4.2.1　定量分析

对于低光增强任务的定量分析的比较如表 1 所列。本文方法相比传统方法 SRIE 和 LIME 在性能指标 PSNR 与 SSIM 上极具优势，甚至优于采用监督数据的全监督学习方法 RetinexNet。与采用无监督学习方法基于对抗学习策略的 EnlightenGAN 算法相比，本文方法在性能指标 SSIM 上高出了 0.01，在 PSNR 高出 0.56 dB。该结果有效证明了本文提出的亮度自调节的图像增强方法不仅超过了现有性能最好的基于无监督学习的低光增强方法，并且超过了部分全监督学习的低光增强方法，显示出在低光增强任务中的有效性。

表 1　不同方法在 SICE 测试集上的结果

Table 1　Results of different methods on SICE test set

Method	*PSNR*/dB	*SSIM*
SRIE	14.41	0.54
LIME	16.17	0.57
RetinexNet	15.99	0.53
EnlightenGAN	16.21	0.59
Proposed	**16.77**	**0.60**

4.2.2　定性分析

为了进一步体现本文方法相比对比的低光增强算法的

优势，本文对采用不同方法得到的低光增强结果进行了可视化对比。如图 4 所示，对于低光增强，SRIE 算法增强效果不明显；LIME 与 RetinexNet 的修正图噪声较多；EnlightenGAN 则会导致轻微色差，而本文算法恢复的图像更加自然且噪声更小。



(a)低光图 (b)SRIE (c)LIME (d)RetinexNet (e)EnlightenGAN (f)Ours

图 4 在经典的低光图像下各类方法的可视化对比

Fig. 4 Visualization comparison of various methods on typical low-light images

4.3 图像去雾

对图像去雾任务，本文同样与具有代表性的业界性能最好的 5 类算法进行了比较，分别是：文献[2]提出的暗通道先验去雾算法 DCP、文献[15]提出的通过点聚类方法对图像整体像素进行聚类进而生成光传播率实现去雾的非局部图像去雾方法 NLD、文献[11]提出的基于多尺度与全监督的训练策略实现去雾的 MSCNN、文献[29]提出的基于深度图像先验的无监督图像增强网络 DIP，以及文献[18]提出的基于耦合深度图像先验完成图像去雾的方法 DDIP。

4.3.1 定量分析

对于图像去雾任务的定量分析比较如表 2 所列。可以看出，本文提出的方法性能不仅优于传统方法 DCP 和 NLD，并且超过了有监督的深度学习方法 MSCNN，PSNR 值比 MSCNN 高出了 2.8dB。相比无监督深度学习算法 DIP 与 DDIP，本文提出的方法占据明显优势，体现了其在去雾问题上的有效性。

表 2 不同方法在去雾标准集 SOTS 上的定量结果

Table 2 Quantitative results of different methods on standard set of dehazing SOTS

Method	*PSNR*/dB	*SSIM*
DCP	16.62	0.81
NLD	17.29	0.75
MSCNN	17.57	0.81
DIP	12.28	0.58
DDIP	16.97	0.71
Proposed	**20.37**	**0.82**

4.3.2 定性分析

图 5、图 6 给出了图像去雾任务中不同方法的可视化对比结果。其中 DIP 的去雾效果不明显；DDIP 在局部区域有很好的去雾效果，但会导致全局的色值失衡；DCP 与 NLD 对较远区域的去雾效果不彻底；MSCNN 的去雾效果不够充分。



(a)雾图 (b)DCP (c)NLD (d)MSCNN (e)DIP (f)DDIP (g)Ours (h)GT

图 5 SOT 标准去雾数据集上不同方法的可视化对比

Fig. 5 Visualization comparison of different methods on SOT standard haze removal data set

本文提出的方法基于无监督的学习策略，运用了亮度饱和度损失，能够有效抑制色偏，使得去雾图像的亮度饱和度分布更加符合理想自然图像的分布规律；运用空间一致性损失，保证了去雾图像和有雾图像具有邻域间的一致性；自然图像具有平滑性，因此本文采用照明平滑度损失，增加了去雾图像的局部平滑性，通过多重伪监督损失，提升了算法精度。本文采用的无监督策略不需要成对的退化图像与目标增强图像，减小了对训练数据的依赖，避免了对比方法由于训练数据和测试数据存在领域差异(Domain Gap)时方法性能的退化。本文通过运用多种损失，基于深度模型无监督地使用海量数据学习图像的亮度调节映射，使得去雾图像更加符合理想自然图像亮度、饱和度、平滑性等数据分布规律，从而取得了更加自然的去雾效果。如图 7 所示，本文提出的的算法与工业环境常用的去雾算法 DCP 相比，具有明显优势。



图 6 在室外浓雾场景下各类方法的可视化对比

Fig. 6 Visualization comparison of various methods in outdoor dense haze scenes



(a)真实雾图　(b)DCP　(c)Ours

图 7　本文方法与工业环境常用的图像去雾算法 DCP 在真实场景的表现比较

Fig. 7　Performance of the proposed method and DCP in real scenes

4.3.3　运算效率分析

本文提出的算法设计了端到端的深度卷积网络进行图像增强，应用时的运算时间为深度模型推理的前向计算时间，较为高效。深度模型推理的前向计算时间复杂度主要与模型的运算次数有关，常采用每秒浮点运算次数 FLOPS 来衡量。本文实验对比方法主要包括传统图像增强方法和采用迭代的图像增强方法以及端到端的基于深度学习的图像增强方法。一些性能较好的传统图像增强方法如 DCP 和 NLD 采用手工设计的计算步骤，操作较为繁琐，计算时间复杂度较高。采用迭代优化的图像增强方法由于循环迭代过程的存在，时间复杂度较高，如 LIME，SRIE，DIP，DDIP 方法。下面将重点对比基于深度学习的端到端图像增强模型的运算效率，如表 3 所列。

表 3　不同方法的时间复杂度与模型参数量的结果

Table 3　Results of time complexity and model parameters of different methods

Method	FLOPs	Parameters
RetinexNet	13.67×10^9	0.44×10^6
EnlightenGAN	12.56×10^9	8.63×10^6
DIP	0.35×10^9	0.58×10^6
DDIP	0.71×10^9	1.14×10^6
MSCNN	0.46×10^9	0.01×10^6
Proposed	9.48×10^9	0.19×10^6

表 3 列出了不同模型的每秒浮点运算次数 FLOPS 及其对应的参数量 Param，即分别提供了相应的时间、空间复杂度依据。可以看出，本文提出的方法在使用较少参数的情况下，得到了较大的每秒浮点运算次数 FLOPS，从而拥有较大的模型容量。本文提出的方法的 FLOPS 小于近年来性能较好的方法，如 RetinexNet 和 EnlightenGAN。参数量和 FLOPS 都较小的方法 MSCNN 为全监督学习图像去雾方法，而本文方法的去雾性能远远好于该方法。可见本文方法在取得更好性能的情况下，在时间和空间复杂度方面进行了较好的折中。

结束语　本文提出了一种可用于低光增强与图像去雾任务亮度自调节的无监督图像增强模型。本方法首先利用基于注意力机制的深度卷积网络抽取输入图像的特征，然后对重建图像与输入低质图像进行度量损失函数比较，在保证增强图像与输入图像同一性的同时增强修复图像，从而实现图像的无监督增强。本文方法较为有效地克服了当前底层视觉任务目标增强数据难以获取、训练数据与应用数据不一致且存在域迁移的难题，提升了算法的适用性。虽然相比其他图像增强算法，本文方法得到了更好的图像去雾与低光增强效果，但在处理图像景深较远的低质量图像时，增强的结果图会出现远处光照修复效果差，去雾不彻底等问题。在接下来的工作中，我们计划在图像增强算法的网络模型设计中考虑图像的视觉深度信息，进一步加强图像的增强效果。

参 考 文 献

[1] ABDULLAH-AL-WADUD M，KABIR M H，DEWAN M A A，et al. A dynamic histogram equalization for image contrast enhancement[J]. IEEE Transactions on Consumer Electronics，2007，53(2)：593-600.

[2] HE K，SUN J，TANG X. Single image haze removal using dark channel prior[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence，2010，33(12)：2341-2353.

[3] LAND E H. The retinex theory of color vision[J]. Scientific American，1977，237(6)：108-129.

[4] CAI B，XU X，JIA K，et al. Dehazenet：An end-to-end system for single image haze removal[J]. IEEE Transactions on Image Processing，2016，25(11)：5187-5198.

[5] WEI C，WANG W，YANG W，et al. Deep retinex decomposition for low-light enhancement[J]. arXiv：1808.04560，2018.

[6] YAN L，ZHENG W，GOU C，et al. Feature Aggregation Attention Network for Single Image Dehazing[C]// 2020 IEEE International Conference on Image Processing(ICIP). IEEE，2020：923-927.

[7] PIZER S M，JOHSON R E，ERICKSEN J P，et al. Contrast-limited adaptive histogram equalization：Speed and effectiveness[C]// Proceedings of the First Conference on Visualization in Biomedical Computing，Atlanta，Georgia. 1990，337：1.

[8] JOBSON D J，RAHMAN Z，WOODELL G A. Properties and performance of a center/surround retinex[J]. IEEE Transactions on Image Processing，1997，6(3)：451-462.

[9] WANG S，ZHENG J，HU H M，et al. Naturalness preserved enhancement algorithm for non-uniform illumination images[J]. IEEE Transactions on Image Processing，2013，22(9)：3538-3548.

[10] CAI J，GU S，ZHANG L. Learning a deep single image contrast enhancer from multi-exposure images[J]. IEEE Transactions on Image Processing，2018，27(4)：2049-2062.

[11] REN W，LIU S，MA L，et al. Low-light image enhancement via a deep hybrid network[J]. IEEE Transactions on Image Processing，2019，28(9)：4364-4375.

[12] LORE K G，AKINTAYO A，SARKAR S. LLNet：A deep autoencoder approach to natural low-light image enhancement[J]. Pattern Recognition，2017，61：650-662.

[13] YANG W，WANG S，FANG Y，et al. From fidelity to perceptual quality：A semi-supervised approach for low-light image enhancement[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020：3063-3072.

[14] JIANG Y，GONG X，LIU D，et al. Enlightengan：Deep light enhancement without paired supervision[J]. IEEE Transactions on Image Processing，2021，30：2340-2349.

[15] BERMAN D，AVIDAN S. Non-local image dehazing[C]// Pro-

ceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016:1674-1682.
[16] ZHANG H, PATEL V M. Densely connected pyramid dehazing network[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018:3194-3203.
[17] LI L, DONG Y, REN W, et al. Semi-supervised image dehazing [J]. IEEE Transactions on Image Processing, 2019, 29: 2766-2779.
[18] GANDELSMAN Y, SHOCHER A, IRANI M. "Double-DIP": Unsupervised Image Decomposition via Coupled Deep-Image-Priors[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019:11026-11035.
[19] CHEN Y S, WANG Y C, KAO M H, et al. Deep photo enhancer: Unpaired learning for image enhancement from photographs with gans[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018:6306-6314.
[20] DING Y J, HUANG S. An Improved Generative Adversarial Network for Image Dehazing[J]. Computer Engineering, 2022, 48(6):207-212.
[21] HE T, YU S M, XU H. Single Image Dehazing Method Based on Conditional Generative Adversarial Network and Knowledge Distillation[J]. Computer Engineering, 2022, 48(4):165-172.
[22] GODARD C, MAC AODHA O, BROSTOW G J. Unsupervised monocular depth estimation with left-right consistency[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017:270-279.
[23] KRULL A, BUCHHOLZ T O, JUG F. Noise2void-learning denoising from single noisy images[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019:2129-2137.
[24] GUO C, LI C, GUO J, et al. Zero-reference deep curve estimation for low-light image enhancement[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020:1780-1789.
[25] LI B, REN W, FU D, et al. Reside: A benchmark for single image dehazing[J]. arXiv:1712.04143, 2017.
[26] 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.
[27] FU X, ZENG D, HUANG Y, et al. A weighted variational model for simultaneous reflectance and illumination estimation[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016:2782-2790.
[28] GUO X, LI Y, LING H. LIME: Low-light image enhancement via illumination map estimation[J]. IEEE Transactions on image processing, 2016, 26(2):982-993.
[29] ULYANOV D, VEDALDI A, LEMPITSKY V. Deep image prior[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018:9446-9454.



WANG Bin, born in 1998, master. His main research interests include computer vision and image processing.



LIANG Yudong, born in 1988, associate professor. His main research interests include computer vision, image processing and deep learning based applications.

(责任编辑:何杨)