

文章编号:1007-2780(2022)11-1467-09

显示系统图像引擎的自适应色彩优化算法

张博文, 夏振平*, 周 波, 宋 玉, 马凤云, 柏 溢
(苏州科技大学 电子与信息工程学院, 江苏 苏州 215009)

摘要: 图像引擎通过多种特定的算法对图像信号进行优化, 在显示系统中具有极其重要的作用和地位。图像引擎中的传统色彩优化算法由多种图像算法组合而成, 存在无法进行自适应优化、容易放大图像噪声等问题。为此, 提出了一种基于空洞卷积的全卷积神经网络用于构建优化算法, 侧重于从人眼主观感知的角度优化图像色彩。同时, 有针对性地构建大规模数据集以提高算法的泛化能力, 防止过拟合。测试结果表明, 所提出的算法可以有效地增强原始图像的色彩, 相较于传统方法, 平均峰值信噪比提升了 4.01 dB, 平均结构相似性提升了 0.04。主观对比实验结果表明, 提出的算法对图像主观感知质量有显著性影响, 平均提升了 61%。

关 键 词: 图像引擎; 色彩优化算法; 深度学习; 图像质量; 视觉感知

中图分类号: TP391.9 **文献标识码:** A **doi:** 10.37188/CJLCD.2022-0143

Adaptive color optimization algorithm of image engine in display system

ZHANG Bo-wen, XIA Zhen-ping*, ZHOU Bo, SONG Yu, MA Feng-yun, BAI Yi

(College of Electronic and Information Engineering, Suzhou University of Science and Technology,
Suzhou 215009, China)

Abstract: Image engine optimizes the image signal through a variety of specific algorithms, which plays an extremely important role in the display system. The traditional color optimization algorithm of image engine is composed of various image optimization algorithms, which can not optimize images adaptively and easy to amplifies the noise. Therefore, a full convolution neural network based on dilated convolution is proposed to construct the optimization algorithm, which focuses on optimizing images from the perspective of subjective perception. At the same time, a large-scale dataset is constructed to improve the generalization ability of the algorithm and prevent overfitting. The experiment results show that the proposed algorithm can effectively enhance the color of original images. Compared with the traditional method, the average peak signal-to-noise ratio is improved by 4.01 dB and the average structural similarity

收稿日期: 2022-04-23; 修订日期: 2022-05-07.

基金项目: 国家自然科学基金(No. 62002254, No. 61876121); 江苏省自然科学基金(No. BK20200988); 江苏省研究生科研与实践创新计划(No. SJCX21_1424, No. KYCX20_2755)

Supported by National Natural Science Foundation of China (No. 62002254, No. 61876121); Natural Science Foundation of Jiangsu Province (No. BK20200988); Postgraduate Research and Practice Innovation Project of Jiangsu Province (No. SJCX21_1424, No. KYCX20_2755)

*通信联系人, E-mail: xzp@usts.edu.cn

is improved by 0.04. The subjective comparison experiment shows that the proposed algorithm has a significant impact on the subjective perception quality of the image, with an average improvement of 61%.

Key words: image engine; color optimization algorithm; deep learning; image quality; visual perception

1 引言

视觉是人类获取外界信息的重要渠道,显示系统则是当今人们获取视觉信息的主要途径之一。随着科学技术的不断发展,人们对于显示系统成像质量的要求越来越高。以液晶显示器(Liquid Crystal Display, LCD)为例,其主要由面板、控制板、菜单控制板等组件构成,其中,控制板在整个液晶显示器中至关重要,其上装载的图像引擎(一种集成芯片)是对成像质量起到决定性作用的一环^[1]。图像引擎上集成的色彩优化算法能够对图像的色彩进行优化^[2],这对于显示设备的图像质量优化具有重要意义^[3]。

传统图像引擎色彩优化算法一般由多种算法组合而成,每种算法实现单一的图像优化。例如,直方图均衡化算法可以使图像亮度在显示系统的成像范围内更加均匀地分布,优化局部细节,在优化整体亮度过高或过低的图像时有显著效果^[4];锐化算法主要用于补偿图像轮廓,增强局部对比度,使图像边缘变得清晰^[5];均值滤波算法一般用于消除图像获取过程中因照明环境不佳或高温引起的传感器噪声^[6]。传统算法若要追求较好的效果,需要根据图像特征人工调整各个算法的参数,这对于一个有实时性要求的算法来说是不切实际的,故其难以自动完成图像的最佳优化。

随着深度学习在图像处理领域的快速发展,诸多深度学习架构在该领域取得了长足的进步。Moran 等人^[7]使用了深度局部参数滤波器(Deep Local Parametric Filters)以改善图像的色彩,借此提升图像整体质量。Guo 等人^[8]提出了一种零参考深度曲线估计(Zero-Reference Deep Curve Estimation)方法,该方法可以增强微光图像,使微光图像展示更多的局部细节。Deng 等人^[9]使用对抗学习(Adversarial Learning)方法实现了图像剪裁和色彩增强的功能。当前,实现上述研究中的图像优化功能均需要较高的硬件成本和时间成本,在实际应用中阻力较大。为此,本文提出了一种采用全卷积神经网络^[10](Fully-Convolutional

Network)构建图像优化算法的方法,借助空洞卷积^[11]在尽量保留原图信息的同时既扩大了感受野,又减少了计算量和参数量,时间和硬件成本较小。因此,该网络在图像引擎色彩优化领域具有较大的潜力。此外,色彩优化算法一般使用图像增强类的数据集进行训练^[12],但其中多数规模较小,不适用于需要优化任意图像的图像引擎算法,本文为此构建了一个全新的大规模数据集。

为解决传统图像引擎色彩优化算法无法针对图像特性做出自适应优化的问题,本文提出了一种基于空洞卷积的全卷积神经网络以构建自适应图像引擎色彩优化算法。该算法结合空洞卷积融合多种图像优化算法,可以替代多种独立算法组合而成的传统算法,侧重于从人眼主观感知的角度优化图像色彩。同时,为了更好地构建数据集,引入了基于神经网络的图像质量评估方法^[13]对扩充后的图像对分别进行图像质量评估,籍此优化在 AVA^[14](Aesthetic Visual Analysis)数据集的基础上构建的 High Quality AVA,最终取得了较好的效果。

2 基本原理

2.1 图像引擎和色彩优化算法

显示器目前主要由面板、控制板、逆变器、OSD 菜单控制板、连接线缆和外壳 6 个部分组成^[15]。其中,图像引擎是控制板上的一颗至关重要的集成芯片。图像引擎的主要功能是接收主机发送的所有图像信息并在其内部实现图像的转换、测量及优化,保证优化后的图像能够正确、稳定地显示。其需要解决的问题主要有图像缩放、时序控制、色彩优化等。色彩是决定图像质量的重要组成部分,故而优越的色彩优化算法是十分必要的。

图像在获取、压缩、传输和缩放的过程中难免会被平滑,导致图像边缘产生模糊。为使显示器给予用户较好的视觉体验,需要对图像进行锐化和对比度调整。传统图像引擎色彩优化算法采用了 8 邻域的拉普拉斯锐化算法以及基于双重

自动阈值分割的分段线性变换对比度增强算法(双阈值线性增强法)。双阈值线性增强法是基

于Otsu^[16]改进的三段线性变换法,表达式如式(1)所示。

$$g(x, y) = \begin{cases} (1-w) \times f(x, y) & 0 \leq f(x, y) < T_2 \\ T_2(1-w) + \frac{255 + (1-w)(T_3 - T_2 - 255)}{T_3 - T_2} (f(x, y) - T_2) & T_2 \leq f(x, y) < T_3 \\ 255w + (1-w) \times f(x, y) & T_3 \leq f(x, y) < 255 \end{cases}, \quad (1)$$

其中, $f(x, y)$ 为原始图像, $g(x, y)$ 为输出图像, $w=0.5$, T_2 和 T_3 为 Otsu 分割方法得出的阈值分割界限。通过 Otsu 方法可以得到最佳的分割阈值 T_1 , 设灰度级大于 T_1 的区域为目标区域, 灰度级小于 T_1 的区域为背景区域。分别对目标区域和背景区域之间再进行一次分割, 背景区域的阈值为 T_2 , 目标区域的阈值为 T_3 。双阈值线性增强法能够在一定程度上获取图像的特征信息, 但是仅局限于轮廓层次较为分明的图像, 且需要人工调整参数, 而图像引擎需要处理所有类型的图像且在处理过程中需要尽量避免人工干预, 算法的自适应性就显得尤其重要。

2.2 基于分类网络的图像质量预测器

Howard 等人提出了 MobileNet^[17] 和一组超参数, 可以搭建规模极小的低延迟模型来满足移动端或嵌入式应用的要求。MobileNet 基于深度可分离卷积的模型, 它将一个标准卷积分解为深度卷积和一个 1×1 的点卷积(图 1)。深度卷积对输入图像的每个通道应用单个滤波器, 然后点卷积应用 1×1 卷积来组合深度卷积的输出, 该方法大幅减少了计算量, 缩小了模型尺寸。因此, 该轻量级架构适用于一个资源有限平台上的计算任务, 例如图像引擎、机器人、自动驾驶等。

Google 在 2018 年提出了一种与人类感知高度相关的无参考单幅图像评价模型: NIMA (Neural Image Assessment)^[13]。该模型能对输入图像进

行评分, 给出一个范围在 1~10 之间的小数作为图像的评分。构建大规模图像对数据集时普遍存在无法保证图像优化效果的问题, 即对原始图像进行增强后无法保证没有过度优化图像, 从而导致图像质量下降。NIMA 模型可以帮助我们改善这一状况, 模型具体结构如图 2 所示。网络首先在 ImageNet 数据集^[18]上进行预训练, 初始化基于网络的权值参数, 然后分别在 AVA 数据集和 TID 2013^[19]数据集上进行端到端的训练, 得到最终的参数。




图 2 基于 MobileNet 的 NIMA 模型

Fig. 2 NIMA model based on MobileNet

本文将单幅图像的评分数据命名为 NINA Score (列出的 NIMA Score 均取 3 位有效数字)。考虑到实际应用中遇到的计算资源及存储空间的问题, 采用以 MobileNet 为基干的评价模型作为图像质量预测器。该预测器用于对已构建的图像对进行评分, 以确保构建理想化的数据集, 使其中的目标图像质量不低于原始图像。

3 自适应色彩优化算法

3.1 网络架构

本文为色彩优化算法确立了 3 个理想标准: (1) 精度。一张图像经本文算法处理后, 其峰值




图 1 标准卷积被替换成深度卷积和点卷积

Fig. 1 Standard convolution are replaced by depthwise convolution and pointwise convolution

信噪比(Peak Signal-to-Noise Ratio, PSNR)和结构相似性(Structural Similarity, SSIM)应不低于传统算法处理后。(2)自适应。算法应当具备较强的泛化能力,即能够对不同内容的图片做出合理的优化。(3)规模。模型应当能够被部署在图像引擎(边缘设备)上。

空洞卷积可以增加感受野,同时保持特征图尺寸不变,从而代替下采样和上采样。空洞卷积引入了“扩张率”这一超参数,该参数定义了卷积运算时卷积核中各个值的间距,具体原理如图3所示。

在图3中,菱形代表卷积核元素,加粗方框代表左上角卷积核元素的感受野大小,感受野的扩大使神经元可以接触到图像中更大的范围,使得




图3 空洞卷积原理示意图。(a)扩张率为1,感受野为 3×3 的普通卷积;(b)扩张率为2,感受野为 5×5 的空洞卷积;(c)扩张率为3,感受野为 7×7 的空洞卷积。

Fig. 3 Schematic diagram of the principle of dilated convolution. (a) 1-dilated convolution, each element has a receptive field of 3×3 ; (b) 2-dilated convolution, each element has a receptive field of 5×5 ; (c) 3-dilated convolution, each element has a receptive field of 7×7 .

这种卷积方法可以提取出更加全局、语义层次更高的图像特征,同时提高了卷积的效率。相比于传统算法仅能获取边缘信息的情况,卷积神经网络可以共享所有卷积提取的图像信息,能更好地根据图像特征做出自适应优化。图4为基于空洞卷积的图像色彩优化网络架构。网络由9个卷积层构成,从第一层至第八层采用空洞卷积,扩张率分别为1,2,4,8,16,32,64,1。最后一层卷积采用大小为 1×1 的卷积核,卷积核个数为3,且不使用激活函数。除最后一层外,每个卷积层中卷积核的个数均为32,卷积核为 3×3 大小,均使用LReLU非线性修正单元函数进行激活(式(2)),其中 $\alpha=0.2$,对卷积结果采用自适应归一化(Adaptive Normalization, AN)(式(3))。

$$\text{LReLU}(x) = \begin{cases} x & x > 0 \\ \alpha x & x \leq 0 \end{cases}, \quad (2)$$

$$\phi^s(x) = \lambda_s x + \mu_s \text{BN}(x), \quad (3)$$

其中, λ_s 和 μ_s 是通过反向传播与其他参数一起学习到的两个标量,BN是批标准化操作^[20]。网络通过最小化输出图像和参考图像的损失函数进行优化,损失函数 $L(w, b)$ 由L2损失和MSSIM损失构成,对应的权重系数分别为0.8和0.2(式(4))。

$$L(w, b) = 0.8 \times \sum_{i=1}^n \frac{1}{N_i} \left\| \hat{f}(I_i; w, b) - f(I_i) \right\|^2 + 0.2 \times (1 - \text{MSSIM}(f(I_i), \hat{f}(I_i; w, b))), \quad (4)$$

其中输入图像为 I_i , N_i 为图像 I_i 的像素个数, w 和 b 为网络待训练的权重, $f(I_i; w, b)$ 表示网络的输出图像,参考图像为 $f(I_i)$ 。




图4 图像色彩优化网络架构

Fig. 4 Architecture of image color optimization network

3.2 High Quality AVA 图像对数据集构建

数据集是算法性能的决定性因素之一,大规模数据集能显著提升算法的精度并增强其泛化能力。Zhang等人使用普通手机和数码单反相机拍摄相同内容的照片构建了DPED^[12]数据集,包

含了6 000多张图像。Bychkovsky等人邀请了5位摄影专业的学生对5 000张图片进行了人工修饰,最终得到了MIT-Adobe FiveK^[21]数据集。这两种方法构建的数据集质量较高,但所需成本非常高,因此难以构建更大规模的数据集,而色彩

优化算法需要对输入显示系统的所有图像进行优化,小规模数据集很难保证网络的泛化能力。受图像质量评价任务^[22]及相关数据集的启发,采用对AVA数据集集中的高质量图像添加不同程度失真的方法^[23]构建了更大规模的色彩优化数据集 High Quality AVA dataset。AVA数据集共包括超过25万张图片,包含了丰富的主题。数据集集中的每一张图片平均都会被约200位摄影师打分,最后得出图像的平均主观意见分(Mean Opinion Score, MOS),分数的取值范围在1~10之间,分数越高,说明人们对于该图像的评价越好。色彩优化数据集中每组图像对由原始图像和参考图像构成,原始图像的图像质量应当低于参考图像。选取AVA中MOS在前20%的图像作为参考图像,共49 178张图片。对参考图像使用退化算法,生成对应的原始图像,将该图像作为原始图像和参考图像组合成一组图像对以构成数据集。图像处理的表达式如式(5)所示:

$$g(x, y) = h(x, y) \triangle f(x, y) + \eta(x, y), \quad (5)$$

其中, $f(x, y)$ 代表高质量的参考图像; $h(x, y)$ 代表两种图像处理操作的组合,分别是幂律变换 $S(r)$ 和高斯模糊 $G(r)$, 符号“ $\triangle$ ”代表 $h(x, y)$ 对 $f(x, y)$ 的操作; $\eta(x, y)$ 代表由高斯噪声构成的加性噪声项。幂律变换的表达式如式(6)所示:

$$S(r) = cr^\gamma, \quad (6)$$

其中, c 和 γ 为常数, c 取1。将幂律变换后的图像与日常生活中的低质量图像进行对比,当 γ 分别取0.8和1.3时,变换图像的亮度特征与低质量图像较为相符,经此处理后的数据集能够帮助网络更好地学习到灰度变换的参数信息。高斯模

糊的表达式如式(7)所示:

$$G(x, y) = \frac{1}{2\pi\delta^2} e^{-\frac{(x-\frac{n}{2})^2 + (y-\frac{n}{2})^2}{2\delta^2}}, \quad (7)$$

其中, n 是模糊半径,取值为5, δ 是正态分布的标准偏差,取值为1。图像在传输过程中通常会受到压缩算法的处理,图像边缘易被平滑,经对比验证,采用该参数处理后的图像边缘与经压缩算法处理后的图像边缘较为相似。高斯噪声的表达式如式(8)所示。

$$P(z) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(z-\bar{z})^2}{2\sigma^2}}, \quad (8)$$

其中, z 表示灰度值; $\bar{z}$ 表示 z 的平均值; σ 表示 z 标准差,标准差的平方 σ^2 为 σ 的方差。此处 $\bar{z}$ 取0, σ^2 取0.001,以此来对图像添加轻微的噪声,避免将模型建模为图像去噪模型。High Quality AVA数据集的构建过程如图5所示。图5(a)为两张相同的参考图像,作为算法的输入。首先,对图5(a)使用两个 γ 值不同的幂律变换算法 $S(r)$ 得到对应的图像对图5(b);然后,对其添加高斯模糊 $G(r)$ 得到图5(c);最后,对图5(c)添加高斯噪声 $\eta(x, y)$ 得到图5(d),将其标记为原始图像。在构建数据集的过程中,默认对参考图像添加的失真会降低图像质量,但由于筛选出的图像数量规模较大,无法保证每一对图像均满足要求,故使用NIMA模型对每一对图像进行评分,如果参考图像的评分低于原始图像,则交换两张图像的标记;反之,则不做任何操作。评分和图像重排完成后,将原始图像与参考图像对应组合,以此生成新的数据集 High Quality AVA dataset (HQAVA),共包含98 356对图像。




图5 HQAVA数据集的构建过程

Fig. 5 Construction process of HQAVA dataset

4 算法性能分析

4.1 客观性能分析

网络训练时的硬件及软件环境如表 1 所示。所使用的训练集和测试集从 HQAVA 中按照 9:1 的比例随机抽取生成。训练基于 TensorFlow 框架,采用 Adam 优化器,初始学习率为 0.000 1,10 个 epoch 后学习率降低为 0.000 01,训练至损失函数平稳为止。为验证算法对图像的优化效果,采用了 3 个评价指标,分别是 PSNR、SSIM 以及 NIMAScore。PSNR 是基于均方误差 (Mean Squared Error, MSE) 的图像质量评价指标,其值越大说明图像的失真程度越低。SSIM 是一种基于图像局部亮度和对比度进行计算的图像质量评价标准,该指标由德州大学奥斯丁分校的图像和视频工程实验室提出,是一种符合人类视觉的标准,其值越接近 1,说明图像质量越好。

表 1 系统配置

Tab. 1 System configuration

系统环境	版本信息
操作系统	Ubuntu 16.04 LTS
CPU	Intel Core i7-8700k
GPU	NVIDIA GeForce GTX 1080Ti
内存	32 GB
Python 版本	3.5

除了与传统方法进行对比,本文还选取了领域内其他基于深度学习的方法进行了对比。Ignatov^[12]创建了 DPED 数据集并提出使用双阶段网络对图像进行优化,该方法中所提出的损失函数被广泛应用。De Stoutz^[24]在 Ignatov 网络架构的基础上进行了优化,在降低模型参数量的同时提升网络的性能和处理速度。Zamir^[25]提出了一种全新的多尺度残差块,以此搭建的网络能在图像去噪、超分、增强 3 个领域达到最佳性能。

表 2 展示了上述方法在测试集上的表现,包括传统方法 (2.1 节所述)、DPED、FPIE、MIRNet 和本文方法的平均 PSNR 值、平均 SSIM 值以及 NIMA 模型的平均得分,加粗值为同一评价指标下所有方法的最优结果。结果表明,原始图像经过本文算法处理后,图像的 3 个评价指标均有不同程度的提升,相较于传统方法,PSNR 提高了

4.01 dB,SSIM 提升了 0.04,NIMA Score 增加了 0.6,表明本文方法对图像起到了更好的优化作用,且从 NIMA Score 来看,其对图像的优化也更加符合人的主观感受。相较于其他深度学习的相关方法,本文方法在 PSNR 和 NIMA Score 上具有较大优势,同时 SSIM 与最优的 MIRNet 极为接近。图 6 为本文和上述算法的优化结果对比。图 6 表明,每种方法均能从色彩角度对原始图像进行优化,但也都存在不足之处。传统方法能够在一定程度上改善原始图像边缘模糊、色彩不够鲜艳的问题,但多种优化算法的叠加放大了原始图像中的噪声,导致图像细节不够清晰,同时,由于无法感知图像信息并自动调整参数,传统方法有时会反向优化图像的色彩。例如,参考图像表明天空是乌云密布的,而传统方法却将天空中的乌云变成了白云,这与图像原本的含义产生了冲突,这是没有人工调整参数所导致的结果。DPED 和 FPIE 虽能够根据图像特征做出优化,但是降噪效果较差,从局部放大的图像中可以看出,优化过后图像细节不够清晰,甚至可能在优化过程中引入了新的噪声。MIRNet 的优化效果较好,但是整体亮度明显地高于参考图像,使得人群衣着颜色不够鲜明。本文方法在优化图

表 2 本文方法与其他方法在测试集上的客观评价指标对比

Tab. 2 Comparison of objective evaluation indexes in test set between our method and others

Index	Traditional method	DPED	FPIE	MIRNet	Proposed
PSNR	22.81	22.74	22.44	24.02	26.82
SSIM	0.78	0.76	0.79	0.83	0.82
NIMA Score	4.23	4.25	4.32	4.76	4.83




图 6 算法优化效果对比图

Fig. 6 Comparison chart of the optimization effect of algorithms

像的同时尽可能地避免了噪声的产生,由此得到的图像亮度更加适宜,色彩更加鲜艳,具有较好的观感。测试表明,提出的网络架构是一种有效可行的架构,希望该架构及相关测试能为未来图像引擎色彩优化算法的发展提供理论参考以及新的思路。

4.2 主观性能分析

图像色彩优化算法的优化效果最终还是取决于人的感知,无论在图像质量评价领域或是视频质量评价领域,都存在具有统计学意义的主观感知实验标准。为从主观感知的角度分析本文方法对图像质量的优化效果,设计了相应的主观实验。被试者通过视觉感知实验对原始图像和经本文方法优化后的图像进行评价。实验从AVA数据集中挑选了不同类型的60幅图像,包含室内图像、室外图像、自然图像和计算机生成图像,利用算法对原始图像进行优化,得到了对应的60幅优化图像。在实验过程中,图像成对随机出现,每对图像前后随机显示,被试者观察每幅图像后对图像质量进行评分。实验设置如图7所示,被试者端坐在显示屏3倍图像高处,正对显示屏中央位置观看图像。




图7 视觉感知实验设置

Fig. 7 Visual perception experiment setting

评分标准采用5分制^[26],5分为极佳,1分为最差,具体分值对应主观图像质量表述如表3所示。为保证实验数据真实可靠,于正式实验前安排练习实验对被试者进行实验方法的练习。共22名被试者^[27](包含6名女性)参与实验,年龄在22~37岁之间,平均年龄24.5岁。所有被试者双眼视力均正常或矫正至正常水平。

实验结果采用SPSS软件(IBM SPSS Statis-

tics 20.0)进行分析。方差分析(ANOVA)(表4)结果表明,优化过程和图像内容对图像质量有高度显著影响($p < 0.01$),且优化过程与图像内容的交叉作用对图像质量具有高度显著影响($p < 0.01$)。

表3 视觉感知实验评分标准

Tab. 3 Grading standard of visual perception experiment

Grade	Image quality
5	Excellent
4	Good
3	Fair
2	Poor
1	Bad

表4 各变量因素对图像质量评分的ANOVA分析结果

Tab. 4 Results of ANOVA analysis for different factors on image quality score

Factor	Image quality score		
	df	F	Sig.
Process	1	809.280	<0.001
Image	59	7.509	<0.001
Image×Process	59	2.309	<0.001

原始图像经本文方法优化后,图像质量显著提升,如图8所示。原始图像的平均主观评分为2.53,优化图像的平均主观评分为3.47,归一化后的平均主观得分上升了61%。实验结果表明,本文方法能较好地优化图像,显著提升了原始图像的图像质量。




图8 原始图像与优化图像的质量评分平均值

Fig. 8 Mean scores of original and optimized images for image quality

5 结 论

本文提出了一种具有高度自适应性的图像

引擎色彩优化算法。算法采用了基于空洞卷积的全卷积神经网络以构建优化算法,侧重于从人眼主观感知的角度优化图像色彩,可以替代多种独立算法组成的传统算法。同时,针对该领域缺少大规模数据集的现状,借助 AVA 数据集构建了大规模图像增强数据集 High Quality AVA,并使用 NIMA 模型保证其合理性。所提出的色彩优化算法能够在图像的亮度、对比度、清晰度方

面针对图像做出合理优化且具有一定的泛化能力。原始图像在经过本文算法处理后,PSNR、SSIM 以及 NIMA Score 相较于传统算法均有显著提升,从主观上看能较好地优化显示设备画面的色彩。在未来的研究中将会更进一步优化 High Quality AVA 数据集,从数据集的角度加强算法自适应的优化能力,同时改进网络结构,让其能够对原始图像进行更加符合人眼的优化。

参 考 文 献:

- [1] ZHA C J, ZHANG Q, DUAN H M. Modeling and image quality enhancement for dynamic compressive imaging system [J]. *Journal of Algorithms & Computational Technology*, 2021, 15: 1-9.
- [2] 黄友文,唐欣,周斌. 结合双注意力和结构相似度量的图像超分辨率重建网络[J]. 液晶与显示, 2022, 37(3): 367-375.
HUANG Y W, TANG X, ZHOU B. Image super-resolution reconstruction network with dual attention and structural similarity measure [J]. *Chinese Journal of Liquid Crystals and Displays*, 2022, 37(3): 367-375 (in Chinese).
- [3] 陈清江,顾媛,李金阳. 双分支金字塔网络的微光图像增强算法[J]. 液晶与显示, 2022, 37(3): 395-404.
CHEN Q J, GU Y, LI J Y. Low-light level image enhancement algorithm based on double-branch pyramid model [J]. *Chinese Journal of Liquid Crystals and Displays*, 2022, 37(3): 395-404 (in Chinese).
- [4] DAR KA, MITTAL S. An enhanced adaptive histogram equalization based local contrast preserving technique for HDR images [J]. *IOP Conference Series: Materials Science and Engineering*, 2021, 1022: 012119.
- [5] ZHANG W W, LI J J, HUA Z. Attention-based Tri-UNet for remote sensing image pan-sharpening [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 3719-3732.
- [6] SHAO C L, KAUR P, KUMAR R. An improved adaptive weighted mean filtering approach for metallographic image processing [J]. *Journal of Intelligent Systems*, 2021, 30(1): 470-478.
- [7] MORAN S, MARZA P, MCDONAGH S, et al. DeepLPF: deep local parametric filters for image enhancement [C]//*IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle: IEEE, 2020: 12823-12832.
- [8] GUO C L, LI C Y, GUO J C, et al. Zero-reference deep curve estimation for low-light image enhancement [C]//*IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle: IEEE, 2020: 1777-1786.
- [9] DENG Y B, LOY C C, TANG X O. Aesthetic-driven image enhancement by adversarial learning [C]//*Proceedings of the 26th ACM International Conference on Multimedia*. Seoul: ACM, 2018: 870-878.
- [10] CHEN Q F, XU J, KOLTUN V. Fast image processing with fully-convolutional networks [C]//*IEEE International Conference on Computer Vision*. Venice: IEEE, 2017: 2516-2525.
- [11] SZEGEDY C, VANHOUCHE V, IOFFE S, et al. Rethinking the inception architecture for computer vision [C]//*IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas: IEEE, 2016: 2818-2826.
- [12] IGNATOV A, KOBYSHEV N, TIMOFTE R, et al. DSLR-quality photos on mobile devices with deep convolutional networks [C]//*Proceedings of the IEEE International Conference on Computer Vision*. Venice: IEEE, 2017: 3297-3305.
- [13] YOO J, AHN N, SOHN K A. Rethinking data augmentation for image super-resolution: A comprehensive analysis and a new strategy [C]//*IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle: IEEE, 2020: 8372-8381.
- [14] LIU S, PAN J, YANG M H. Learning recursive filters for low-level vision via a hybrid neural network [C]//*14th European Conference on Computer Vision*. Amsterdam: Springer, 2016: 560-576.
- [15] 黄晓丽,孙玉宝,马红梅. 液晶显示器多种显示模式色彩表现的研究进展[J]. 液晶与显示, 2021, 36(3): 355-370.
HUANG X L, SUN Y B, MA H M. Research progress in color performance of LCD with various display modes

- [J]. *Chinese Journal of Liquid Crystals and Displays*, 2021, 36(3): 355-370 (in Chinese).
- [16] 郭波,管菊花,黄志开. 基于改进Otsu算法的TFT-LCD点缺陷自动光学检测系统[J]. *液晶与显示*, 2018, 33(3): 221-227.
- GUO B, GUAN J H, HUANG Z K. Automatic optical detection system for TFT-LCD spot-type defect based on improved Otsu algorithm [J]. *Chinese Journal of Liquid Crystals and Displays*, 2018, 33(3): 221-227 (in Chinese).
- [17] HOWARD A G, ZHU M L, CHEN B, *et al.* MobileNets: efficient convolutional neural networks for mobile vision applications [J]. *arXiv*:1704.04861, 2017.
- [18] DENG J, DONG W, SOCHER R, *et al.* ImageNet: a large-scale hierarchical image database [C]//*IEEE Conference on Computer Vision and Pattern Recognition*. Miami: IEEE, 2009: 248-255.
- [19] PONOMARENKO N, IEREMEIEV O, LUKIN V, *et al.* Color image database TID2013: peculiarities and preliminary results [C]//*European Workshop on Visual Information Processing*. Paris: IEEE, 2013: 106-111.
- [20] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift [C]//*Proceedings of the 32nd International Conference on Machine Learning*. Lille: ACM, 2015: 448-456.
- [21] BYCHKOVSKY V, PARIS S, CHAN E, *et al.* Learning photographic global tonal adjustment with a database of input/output image pairs [C]//*IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. Colorado Springs: IEEE, 2011: 97-104.
- [22] KIM J, NGUYEN A D, LEE S. Deep CNN-based blind image quality predictor [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2019, 30(1): 11-24.
- [23] KIM S J, CHAE C B, LEE J S. Subjective and objective quality assessment of videos in error-prone network environments [J]. *Multimedia Tools and Applications*, 2016, 75(12): 6849-6870.
- [24] DE STOUTZ E, IGNATOV A, KOBYSHEV N, *et al.* Fast perceptual image enhancement [C]//*Proceedings of the European Conference on Computer Vision Workshops*. Munich: Springer, 2018: 260-275.
- [25] ZAMIR S W, ARORA A, KHAN S, *et al.* Learning enriched features for real image restoration and enhancement [C]//*Proceedings of the 16th European Conference on Computer Vision*. Glasgow: Springer, 2020: 492-511.
- [26] 夏振平,程成. 基于视觉显著性的立体显示图像深度调整[J]. *光学学报*, 2017, 37(1): 0133001.
- XIA Z P, CHENG C. Stereoscopic display image depth adjustment based on visual saliency [J]. *Acta Optica Sinica*, 2017, 37(1): 0133001. (in Chinese)
- [27] ITU-R recommendation BT. 500-11-2002 methodology for the subjective assessment of the quality of television pictures [S] ITU, 2002.

作者简介:



张博文(1998—),江苏南通人,硕士研究生,2020年于南京财经大学获得学士学位,主要从事图像增强和图像质量评价方面的研究。E-mail:zhangbowen_66@163.com



夏振平(1985—),江苏兴化人,博士,副教授,2014年于东南大学获得博士学位,主要从事视觉相关的立体显示图像质量测量、评价和优化等方面的研究。E-mail:xzp@usts.edu.cn