

基于密集连接生成对抗网络的图像颜色迁移

王晓宇, 朱一峰, 郝金洋, 王尧, 段锦

引用本文:

王晓宇, 朱一峰, 郝金洋, 等. 基于密集连接生成对抗网络的图像颜色迁移[J]. 液晶与显示, 2020, 35(3): 272–280.

WANG Xiao-yu, ZHU Yi-feng, XI Jin-yang, et al. Image color transfer with dense connections generative adversarial networks[J]. *Chinese Journal of Liquid Crystals and Displays*, 2020, 35(3): 272–280.

在线阅读 View online: <https://doi.org/10.3788/YJYXS20203503.0272>

您可能感兴趣的其他文章

Articles you may be interested in

基于局部路径特征信息神经网络的图像去噪

Image denoising based on local path feature information neural network

液晶与显示. 2020, 35(1): 70–79 <https://doi.org/10.3788/YJYXS20203501.0070>

基于多尺度残差网络的CT图像超分辨率重建

CT image super-resolution reconstruction based on multi-scale residual network

液晶与显示. 2019, 34(10): 1006–1012 <https://doi.org/10.3788/YJYXS20193410.1006>

基于深度学习的乳液泵缺陷检测算法

Defect detection algorithm of lotion pump based on deep learning

液晶与显示. 2019, 34(1): 81–89 <https://doi.org/10.3788/YJYXS20193401.0081>

基于图像分割和区域匹配的灰度图像彩色化算法

Gray image colorization algorithm based on image segmentation and region matching

液晶与显示. 2019, 34(6): 619–626 <https://doi.org/10.3788/YJYXS20193406.0619>

跟踪图像生成技术应用于光电设备模拟训练

Technology of tracking image generating applied in simulation training of photoelectric device

液晶与显示. 2015(2): 347–352 <https://doi.org/10.3788/YJYXS20153002.0347>

文章编号:1007-2780(2020)03-0272-09

基于密集连接生成对抗网络的图像颜色迁移

王晓宇,朱一峰*,郝金洋,王 尧,段 锦

(长春理工大学 电子信息工程学院,吉林 长春 130022)

摘要:针对传统颜色迁移算法在处理图像时存在颜色误传递,色彩不够自然等问题,提出一种基于密集连接生成对抗网络的图像颜色迁移方法。在训练过程中,训练生成网络生成颜色迁移图像。生成网络中的编码层利用密集连接网络跨层连接的优点促进颜色特征重用,加快网络的收敛速度,同时在转换层采用 3 层残差模块代替原始的两层残差模块更好地组合图像的不同特征。训练判别网络使其辨别原图像与生成的迁移图像间的差别。本文判别网络中用 $-\log$ 函数计算模型损失,加快训练初期更新速度。实验结果表明,与同类模型相比,本文方法结果图像保留更多细节,且能够抑制部分噪声,整体更接近自然图像。

关 键 词:生成对抗网络;颜色迁移;密集连接

中图分类号:TP391 **文献标识码:**A **doi:**10.3788/YJYXS20203503.0272

Image color transfer with dense connections generative adversarial networks

WANG Xiao-yu, ZHU Yi-feng*, XI Jin-yang, WANG Yao, DUAN Jin

(School of Electronic and Information Engineering,
Changchun University of Science and Technology, Changchun 130022, China)

Abstract: Aiming at the problem that the traditional color transfer algorithm has color mis-transmission and unnaturalness as processing images, an image color transfer method based on dense connection generative adversarial network is proposed. During the training process, the training generation network generates the color transfer image. The coding layer in the generated network promotes the reuse of color features and speeds up the convergence rate of the network by using the cross-layer connection of the dense connection network. The conversion layer uses a three-layer residual module instead of the original two-layer residual module to combine different features of the image. The discriminating network is trained to distinguish the difference between the original image and the generated transfer image. The $-\log$ function is used to calculate the model loss in the network and speed up the initial update of the training. The experimental results show that the result image of this method retains more details compared with the similar model, can suppress some noise and the whole image is closer to the natural image.

Key words: generative adversarial networks; color transfer; dense connection

收稿日期:2019-07-04;修订日期:2019-10-11.

基金项目:国家自然科学基金(No.61705017)

Supported by National Natural Science Foundation of China under Grant (No. 61705017)

* 通信联系人, E-mail: zhuyifeng@cust.edu.cn

1 引言

迁移学习在机器学习中是一个重要的研究课题。迁移学习的目标是将其他领域上学习到的知识迁移转化到不同但相关的其他领域或问题中。图像颜色迁移是指在保持图像风格和纹理不变的情况下,通过算法获取其他图像的颜色信息,从而使图像呈现全新的视觉效果。

2001年,颜色迁移的概念被首次提出。Reinhard^[1]等人利用颜色空间的抗相关性,有效地完成了彩色图像间的颜色转移工作。在这之后,颜色迁移引起中外学者的广泛关注。很多学者在原算法的基础上进行了改进,或提出新的颜色迁移算法,扩展了颜色迁移的应用领域。Tai等^[2]利用基于概率分割的局部颜色迁移算法实现了区域间对应像素点的颜色迁移。Pouli等^[3]利用直方图匹配使目标图像和参考图像拥有相似的颜色风格。Guo^[4]和 Gupta^[5]利用机器学习的方法实现图像的颜色迁移。在图像间有相同物体或场景的情况下,可利用特征检测的方法建立图像间的颜色映射关系。Yamamoto等^[6]使用 SIFT 计算空间对应关系,并应用高斯卷积核寻找颜色间的映射关系来进行颜色迁移。Hacohen等^[7]通过计算密集最近邻对应关系的经典算法寻找图像间对应的色调差异,然后进行整体的颜色调整。Wu等^[8]利用图像分析的方法分离出前景与背景,实现了语义相同或相似区域间的颜色迁移。Li等^[9]将颜色组合抽象出颜色情感,利用颜色情感去进行颜色迁移。

尽管颜色迁移算法迅速发展,但是目前使用的一些颜色迁移技术仍需人工干预,且部分场景与真实图像的差异仍旧明显,迁移过程会存在颜色误传递、色彩不够自然及图片细节丢失等问题。

2 生成对抗网络

2014年,Goodfellow^[10]等首次提出生成对抗网络(GAN)模型。该模型提出后受到了人们的广泛关注。生成对抗网络的主要思想是通过生成器 G (Generator) 和判别器 D (Discriminator) 不断博弈,进而使生成器学习到数据的分布。如果用到图片生成上,则训练完成后,生成器可以从一段随机数中生成逼真的图,判别器判别输入图片是不是“真实的”。生成对抗网络结构图

如图1所示。




图1 生成对抗网络总体结构图

Fig.1 Structure diagram of generative adversarial network

GAN成功的关键是对抗性损失的思想,这种对抗性损失迫使生成的图像原则上与真实图像无法区分。GAN自动学习一个适合目标的损失函数,同时训练一个生成模型来最小化损失。由于GAN学习的是适应于数据的损失函数,因此可以将GAN应用到大量的任务中去,这对于图像生成任务特别有用,因为这正是许多计算机图形学优化的目标。我们采用对抗性损失来学习映射,使得迁移图像与目标域中的图像难以区分。GAN的目标函数可以表示为公式(1):

$$\min_G \max_D V_{\text{GAN}}(D, G) = E_{x \sim P_{\text{data}}(x)} [\ln D(x)] + E_{z \sim p_z(z)} [\ln(1 - D(G(z)))], \quad (1)$$

近几年相关的研究成果相当丰富。已有的工作为GAN添加了标签^[11]、文本^[12]等。加入图像约束的工作也有很多, Ledig等^[13]提出利用GAN生成高分辨率图像; Yeh等^[14]将GAN应用在图像修复上并取得了很好的结果。Zhu等^[15]提出的CycleGAN可以实现图像翻译任务,该网络能根据目标域数据与源域数据的共有特征形成映射关系,且不要求源域与目标域数据一一对应,但其模型在训练阶段常会遇到网络训练不稳定、训练更新速度较慢且部分生成图像质量较差等问题。针对以上问题,本文在原CycleGAN模型基础上进行了如下改进:(1)提出了一种密集连接网络结构代替原网络中的单层连接,利用密集连接网络跨层连接的优点能够促进颜色特征重用同时提升网络效率。转换层部分将原本的2层残差模块改为3层残差模块,更好地拟合图像的深层特征和浅层特征。(2)判别网络损失函数处理伪造数据的表达式由 $\ln(1 - D(z))$ 改为 $-\ln(D(z))$, 同样能满足判别器的目标函数要求,并且在训练初期还能更新得更快。

3 颜色迁移的密集连接生成对抗网络

本文的颜色迁移方法的网络框架如图 2 所示, 我们的目标是学习两个图像集域 X 和域 Y 之间的映射函数。本文模型包括两个生成器和两个判别器, 映射 $G: X \rightarrow Y$, 映射 $F: Y \rightarrow X$, 判别器 D_X 和判别器 D_Y 。 G 的目标是使域 X 的样本经过映射后符合域 Y 的分布, 即 $G(X) \sim P_{\text{data}}(y)$ 。 D_X 的目标是将 $\{y\}$ 和 $\{G(X)\}$ 区分开。 F 和 D_Y 也是同理, 只是方向相反。对于颜色迁移, 域 X 通常需要转换颜色的内容图像集, 域 Y 通常是目标图像集。




图 2 本文网络架构

Fig.2 Network architecture of this paper

3.1 基于密集连接的生成器网络结构

为了正确训练样本分布, 提高生成图片的质量, 生成器网络采用编码层-转换层-解码层网络。第一部分编码层用于图像特征提取, 第二部分转化层使用残差网络组合图像的不同特征, 第三部分解码器对特征进行筛选并重构图像。

编码层网络的层与层之间不同于原始生成对抗网络编码层只有单层连接, 而采用密集连接^[16]。密集连接网络基本思路是建立前面所有层与后面层的跨层连接。在密集连接网络中, 第 m 层的输入会连接前面所有层作为输入, 如公式(2)所示。

$$x_m = H_m([x_0, x_2, \dots, x_{m-1}]), \quad (2)$$

其中: $[x_0, x_2, \dots, x_{m-1}]$ 表示由第 $0, 1, 2, \dots, m-1$ 层输出的特征图组成的张量; H_m 代表非线性转化函数, 它是一个组合操作, 包括批量归一化 (Batch Normalization, BN)、激活函数 (ReLU)、池化 (Pooling) 及卷积运算 (Conv)。在密集连接块中, 输出的通道数为 k , 第 m 层的输入通道为 $k_0 + k(m-1)$, 超参数 k 在密集连接网络中称为增长率, 随着层数的增加, 密集连接块的输入会非常多, 这是由于特征复用造成的, 所以一般情况下使用较小的 k , 本文 k 取 12。

原始的编码层网络要经过池化层及步长大于 1 的卷积运算来降低特征图的大小, 而密集连接网络需要特征图大小保持一致。为了解决这个问题, 我们采用密集连接块加过渡层的结构。在密集连接块中, 各个层的特征图大小一致, 可以在通道维度上连接。本文密集连接块中的非线性组合函数采用的是 BN+Leaky ReLU+ 3×3 Conv 的结构。对于转换层, 它主要是连接两个相邻的密集连接块, 并且在保证特征形状不变的情况下, 降低特征维度。过渡层包括一个 1×1 的卷积和 2×2 的平均池化, 结构为 BN+Leaky ReLU+ 1×1 Conv+ 2×2 AvgPooling。另外, 过渡层还起到了压缩模型的作用, 本文使用的压缩系数为 0.5。在密集连接网络中, 我们采用斜率为 0.2 的 Leaky ReLU 激活函数而非 ReLU 激活函数。Leaky ReLU 是给所有负值赋予一个非零斜率, 解决了 ReLU 在输入是负数时完全不激活的情况。图 3 所示为编码层密集连接图。




图 3 编码层密集连接示意图

Fig.3 Schematic diagram of code layer dense connection

生成网络编码层部分采用有 2 个密集连接块的密集连接网络, 密集连接块中所采用的卷积核大小均为 3×3 , 并采用填充卷积为 1 (padding=1) 的方式补偿像素尺寸精度的损失, 每个密集连接块里面的层数相同。输入图像首先进行一次卷积核大小为 7×7 , 卷积核的数量为 64, 步长为 1 的卷积运算, 再通过一个卷积核大小为 3×3 , 步长为 2 的最大池化层。然后进入密集连接块。编码层采用的网络配置如表 1 所示。

表1 编码层密集连接架构

Tab.1 Coding layer dense connection architecture

层	输出	尺寸和步长
卷积层	256×256	7×7 conv, stride=1
池化层	128×128	3×3 max pool, stride=2
密集连接块 1	128×128	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6, \text{stride}=1$
过渡层	128×128	1×1 conv
	64×64	2×2 average pooling, stride=2
密集连接块 2	64×64	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12, \text{stride}=1$

第二部分转换层网络的作用是组合图像的不同特征,然后基于这些特征,将深层的图像语义特征与浅层的图像细节更好地进行拟合。本文采用3层的残差模块有先降维再升维的操作。前一个1×1的卷积主要负责减少维度,剩下的3×3的卷积来减少输入和输出的维度,提取高维特征,后一个1×1卷积对颜色特征进行融合。

转换层结构由6个残差模块串联组成,每个残差块又包含了3个卷积层(Conv)、3个批量归一化层(BN)和3个激活函数(ReLU)。其中批量归一化层(BN)的作用是在通道上进行归一化。第一个卷积运算卷积核大小为1×1,步长为1,无填充卷积(padding=0)。应用ReLU激活函数,这里没有超参数;第二个卷积运算为卷积核大小为3×3,步长为1,卷积填充为相同卷积(padding='same'),应用ReLU激活函数。第三个卷积运算为卷积核大小为1×1,步长为1,无填充卷积(padding=0),这一部分中没有应用ReLU激活函数。将短路连接和输入一起添加到模块中,然后再应用ReLU激活函数。图4为本文残差模块示意图。

解码过程从特征向量中还原出图像特征,这是利用2个反卷积层(Deconv)、2个批量归一化层(Batchnorm)、2个激活函数(Leaky ReLU)、1个卷积层(Conv)和1个双曲正切激活层(Tanh)构成。

最终生成器的损失函数为:

$$\min_G V(D, G) = E_{z \sim p_z(z)} [\ln(1 - D(G(z)))]. \quad (3)$$

3.2 改进的判别器网络结构

判别器用于对抗训练。输入一副图像,判别




图4 残差模块示意图

Fig.4 Residual module diagram

器尝试预测其为原始图像还是生成器的输出图像。本文判别器由5个卷积层(Conv)、4个激活函数(Leaky ReLU)和3个批量归一化层(Batch Norm, BN)组成。其中5个卷积运算均为卷积核大小5×5,步长为2的卷积,如图5所示。




图5 判别器结构图

Fig.5 Discriminator structure diagram

在原始GAN中,判别器的损失函数表达式为:

$$\max_D V(D, G) = E_{x \sim P_{\text{data}}(x)} [\ln D(x)] + E_{z \sim p_z(z)} [\ln(1 - D(G(z)))], \quad (4)$$

其中对于伪造数据的处理式是:

$$E_{z \sim p_z(z)} [\ln(1 - D(G(z)))]. \quad (5)$$

一开始判别器是很容易鉴别伪造数据的,因此对于刚开始训练的模型,我们希望在初期 $D(z)$ 能够快速地更新,但不幸的是,目标函数 $\ln(1-D(z))$ 左端刚好是平缓的区域,这会阻碍 $D(z)$ 的快速更新。我们把 $\ln(1-D(z))$ 这个表达式换成 $-\ln(D(z))$, 同样能满足判别器的目标函数要求,并且在训练初期还能更新得更快。

改进的判别器损失函数为:

$$\max_D V(D, G) = E_{x \sim P_{\text{data}}(x)} [\ln D(x)] + E_{z \sim p_z(z)} [-\ln(D(G(z)))] . \quad (6)$$

要使得输出的图片既符合目标域的分布,又保留原来输入图片的语义信息,我们希望输出图片和输入图片具有一定的相似度。因此循环一致性要求对于某一个域上的数据通过两次转换,最后能生成接近初始数据的分布,对于来自于源域 X 的图片 x , 都有 $x \rightarrow G(x) \rightarrow F(G(x)) \approx x$, 成为前向循环一致性,同样的,有反向循环一致性 $y \rightarrow F(y) \rightarrow G(F(y)) \approx y$, 因此,定义循环一致损失函数为:

$$L_{\text{cyc}}(G, F) = E_{x \sim P_{\text{data}}(x)} [\|F(G(x)) - x\|_1] + E_{y \sim P_{\text{data}}(y)} [\|G(F(y)) - y\|_1] . \quad (7)$$


4 实验结果

实验在 Ubuntu16.04LTS 的操作系统下进

行,基于开源深度学习框架 Pytorch,使用的编程语言为 Python,核心实验设备包括 GPU (GEFORCE RTX2060), CPU (E5-2620 v4@2.10 GHz)(2 处理器), 16 G 内存。图像颜色迁移实验数据集为 Places 中的春天图片 1 273 张,夏天图片 1 096 张,秋天图片 1 174 张,冬天图片 854 张,分别进行了 4 次训练,并选取清晨和傍晚的各 1 000 张图像进行了 1 次训练。在训练前,将获取的图像进行旋转和翻转操作以扩充数据集,并且随机打乱图像的顺序,使训练样本更具多样性,并将其中 80% 样本设置为训练集,20% 样本为测试集,实验中每组数据集包含 TrainA、TrainB、TestA 和 TestB 4 个文件。在训练过程中,模型采用 Adam 优化算法对参数进行优化,网络的初始学习率为 0.000 2,权重衰减设置为 0.000 01,批处理大小为 32,训练的 epoch 数量为 200,训练中前 100 epoch 保持学习率不变。每训练一个 epoch,就打乱一下图像顺序,目的是保证训练的可靠性。同时为了减弱初始化对输出结果的影响,我们通过多次训练来获得最佳效果。

4.1 实验分析与比较

本文分别与文献[1]、文献[15]、文献[17]提出的算法进行比较,如图 6、图 7 所示。从图 6 可以看出,文献[1]、[15]、[17]的算法结果图中天空、山、草地、树的颜色并没有明显的区分,出现了






图6 不同方法进行四季颜色景观颜色迁移结果

Fig.6 Different methods for color transfer results of four seasons color landscape



图7 不同方法清晨傍晚景观进行颜色迁移结果

Fig.7 Different methods of color transfer results in the early morning and evening landscape

严重的颜色误传现象,而本文的算法克服了颜色误传递、色彩不够自然的现象。且本文的颜色迁移算法可以生成特征相近、但风格不同的结果图,图像的各类景物边界区分明显,更贴近真实场景颜色。图 7 中我们进行了清晨和傍晚景象颜色迁移,结果图像中文献[1]、[15]、[17]算法也出现了严重颜色误传、景物颜色边界不明显等现象,本文的算法则避免了这种缺点,颜色传递的效果明显优于前几种算法。

4.2 定量分析

4.2.1 密集连接有效性验证

为了证明密集连接对算法性能的影响,对本文生成器网络和文献[15]生成器网络分别进行 20 000 次实验。如表 2 所示,在生成器损失函数对比中,本文生成对抗网络在收敛速度和稳定性上明显优于文献[15]网络模型。

表 2 生成器损失函数对比

Tab.2 Comparison of Generator loss function

模型训练(step)	本文算法	CycleGAN
5 000	13.34±0.53	15.85±0.65
10 000	9.95±0.44	11.53±0.45
15 000	6.51±0.35	8.15±0.42
20 000	5.88±0.31	6.01±0.36

4.2.2 本文判别器损失函数有效性验证

图 8 为改进前、后判别器损失函数值随训练步长变化趋势。其中蓝线代表本文判别器损失函




图 8 改进前后判别器损失函数变化情况

Fig.8 Discriminator loss function before and after improvement

数随训练步长变化情况,红线代表文献[15]判别器损失函数随训练步长变化。在比较判别器损失函数性能时,我们固定生成器为本文提出的生成器模型,避免生成器不同对实验结果产生的影响,从图中可以看出用本文的判别网络训练初期更新更快,稳定性也较好。

4.2.3 图像经典特征比较

为了验证本文算法的有效性,我们选择了包括 Shape Context^[18]、PSNR 和边缘强度 3 种经典特征对图 7 中的 4 幅迁移图像进行比较。由表 3 可以看出本文算法较其他 3 种对比算法具有更小的 Shape Context、更高的 PSNR 和边缘强度。说明其颜色迁移后的结果具有更小的失真程度,可更有效地保持场景原有结构,且有效地减小了随机干扰对结果的影响,算法的鲁棒性较高。

表 3 不同颜色迁移算法的 shape context、PSNR 和边缘强度

Tab.3 Shape context, PSNR and edge strength of different color transfer algorithms

方法	Shape Context	PSNR	边缘强度
文献[1]算法	0.104 139	32.986	93.71
文献[15]算法	0.092 985	34.064	110.33
文献[17]算法	0.091 481	33.191	105.29
本文算法	0.092 053	35.308	118.40

表 4 本文算法四季景观颜色迁移图像中各图像的 SSIM 和对比度

Tab.4 SSIM and contrast of each image in the four seasons color transfer image in this paper

季节	SSIM	对比度
春季	0.953	4.26
夏季	0.977	4.41
秋季	0.925	3.30
冬季	0.933	3.04

表 4 为图 6(e)中本文算法四季景观颜色迁移各图像的 SSIM^[20-22] 和对比度。我们选择 SSIM 对本文算法结果图像中 4 幅季节景观颜色迁移图像同原图像的结构相似性进行评估,选择对比度评估 4 幅迁移图像的视觉效果。对比度对视觉的影响起着关键作用,通常对比度越大,图像

越清晰醒目,色彩也越鲜明艳丽;而对比度小,则会让整个画面都灰蒙蒙的。由表4可以看出,四季迁移图像中夏季的迁移图像与原图像的结构相似度最接近,有更小的失真程度且对比度较高,说明夏季的迁移图像在保持图像原有属性基础上具有较好的颜色迁移效果,可以准确地保持场景中的饱和度。分析造成4幅迁移结果图像细微不同的原因是4个训练集的图像数量不同,以及训练集内部图像间细节差异导致。

4.2.4 彩色度比较

在定性的评估中,我们选择 Hasler 等人提出的一种计算图像彩色度的方法^[19],实验证明该方法计算的彩色度和主观评价有较高的相关性。

该方法的彩色度定义为:

$$C = \sqrt{\delta_{rg}^2 + \delta_{yb}^2} + 0.3 \sqrt{\mu_{rg}^2 + \mu_{yb}^2}, \quad (7)$$

该定义基于图像的三原色理论,其中, μ 和 δ 表示图像的均值和标准 $rg = R - G$, $yb = 0.5(R + G) - B$, R 、 G 和 B 为彩色图像的3个颜色分量。本文计算不同模型测试结果图像的彩色度并求平均值,如表5所示,相比于同类模型本文算法具有更高的彩色度,说明本文迁移算法更接近

表5 不同模型结果图像的彩色度平均值

Tab.5 Color average of the results of differenc models

方法	彩色度
本文方法	92.519
CGAN	83.209
CycleGAN	80.362
Reinhard	61.833

人的主观感受。

5 结 论

本文提出了一种基于密集连接生成对抗网络的图像颜色迁移方法。在生成网络中利用密集连接网络模型加强了图像颜色特征的传播,提升了颜色迁移效率并且克服了现有算法中存在的颜色误传递、色彩不够自然等问题。实验结果证明,本文模型保留了更多图像细节,纹理清晰,整体图像更接近自然图像。

参 考 文 献:

- [1] REINHARD E, ADHIKMIN M, GOOCH B, *et al.* Color transfer between images [J]. *IEEE Computer Graphics and Applications*, 2001, 21(5): 34-41.
- [2] TAI Y W, JIA J Y, TANG C K. Local color transfer via probabilistic segmentation by expectation-maximization [C]//*Proceedings of 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. San Diego, CA, USA: IEEE, 2005: 747-754.
- [3] POULI T, REINHARD E. Progressive histogram reshaping for creative color transfer and tone reproduction [C]//*Proceedings of the 8th International Symposium on Non-Photorealistic Animation and Rendering*. Annecy, France: ACM, 2010: 81-90.
- [4] GUO Y J, LI H, ZHANG W, *et al.* Multi-source color transfer based on multi-labeled decision tree [C]//*Proceedings of the 2008 the 9th International Conference for Young Computer Scientists*. Hunan, China: IEEE, 2008: 820-825.
- [5] GUPTA R K, CHIA A Y S, RAJAN D, *et al.* A learning-based approach for automatic image and video colorization [J]. arXiv: 1704.04610, 2012.
- [6] YAMAMOTO K, YENDO T, FUJII T, *et al.* Color correction for multi-camera system by using correspondences [C]//*Proceedings of ACM SIGGRAPH 2006 Research Posters*. Boston, Massachusetts: ACM, 2006: 213-222.
- [7] HACOEN Y, SHECHTMAN E, GOLDMAN D B, *et al.* Non-rigid dense correspondence with applications for image enhancement [J]. *ACM Transactions on Graphics*, 2011, 30(4): 70.
- [8] WU F Z, DONG W M, KONG Y, *et al.* Content-based colour transfer [J]. *Computer Graphics Forum*, 2013, 32(1): 190-203.
- [9] HE L, QI H R, ZARETZKI R. Image color transfer to evoke different emotions based on color combinations [J].

- Signal, Image and Video Processing*, 2015, 9(8): 1965-1973.
- [10] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, *et al.* Generative adversarial nets [C]//*Proceedings of the 27th International Conference on Neural Information Processing Systems*. Montreal, Canada: MIT Press, 2014: 2672-2680.
 - [11] ODENA A. Semi-supervised learning with generative adversarial networks [EB/OL]. [2016-06-05]. <https://arxiv.org/pdf/1606.01583.pdf>.
 - [12] NGUYEN R M H, KIM S J, BROWN M S. Illuminant aware gamut-based color transfer [J]. *Computer Graphics Forum*, 2014, 33(7): 319-328.
 - [13] LEDIG C, THEIS L, HUSZÁR F, *et al.* Photo-realistic single image super-resolution using a generative adversarial network [C]//*Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu, HI, USA: IEEE, 2017: 105-114.
 - [14] YEH R A, CHEN C, LIM T Y, *et al.* Semantic image inpainting with deep generative models [C]//*Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu, HI, USA: IEEE, 2017: 6882-6890.
 - [15] ZHU J Y, PARK T, ISOLA P, *et al.* Unpaired image-to-image translation using cycle-consistent adversarial networks [C]//*Proceedings of 2017 IEEE International Conference on Computer Vision*. Venice, Italy: IEEE, 2017: 2242-2251.
 - [16] HUANG G, LIU Z, VAN DER MAATEN L, *et al.* Densely connected convolutional networks [C]//*Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu, HI, USA: IEEE, 2017: 2261-2269.
 - [17] SU Y Y, SUN H M. Emotion-based color transfer of images using adjustable color combinations [J]. *Soft Computing*, 2019, 23(3): 1007-1020.
 - [18] MORI G, BELONGIE S, MALIK J. Efficient shape matching using shape contexts [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2005, 27(11): 1832-1837.
 - [19] HASLER D, SUESSTRUNK S E. Measuring colorfulness in natural images [J]. *SPIE*, 2003: 87-95.
 - [20] 何阳, 黄玮, 王新华, 等. 稀疏阈值的超分辨率图像重建 [J]. *中国光学*, 2016, 9(5): 532-539.
HE Y, HUANG W, WANG X H, *et al.* Super-resolution image reconstruction based on sparse threshold [J]. *Chinese Optics*, 2016, 9(5): 532-539. (in Chinese)
 - [21] 朱福珍, 刘越, 黄鑫, 等. 改进的稀疏表示遥感图像超分辨重建 [J]. *光学精密工程*, 2019, 27(3): 718-725.
ZHU F Z, LIU Y, HUANG X, *et al.* Remote sensing image super-resolution based on improved sparse representation [J]. *Optics and Precision Engineering*, 2019, 27(3): 718-725. (in Chinese)
 - [22] 刘超, 张晓晖. 超低照度下微光图像的深度卷积自编码网络复原 [J]. *光学精密工程*, 2018, 26(4): 951-961.
LIU C, ZHANG X H. Deep convolutional autoencoder networks approach to low-light level image restoration under extreme low-light illumination [J]. *Optics and Precision Engineering*, 2018, 26(4): 951-961. (in Chinese)

作者简介:



王晓晓(1993—),女,天津人,硕士研究生,2017年于长春理工大学取得学士学位,主要从事通信与信息系统,图像处理方面的研究。E-mail: 1518015796@qq.com



朱一峰(1979—),男,浙江兰溪人,博士,副教授,2012年于长春理工大学获得博士学位,主要从事通信与信息系统方面的研究。E-mail: zhuyifeng@cust.edu.cn