

# 基于深度残差生成对抗网络的本征图像分解算法

王照<sup>1</sup> 陈恩庆<sup>2</sup>

<sup>1</sup>(河南护理职业学院公共学科部 河南 安阳 455000)

<sup>2</sup>(郑州大学信息工程学院 河南 郑州 450000)

**摘要** 针对现有方法分解质量不佳、特征信息不够清晰的问题,提出一种基于深度残差生成对抗网络的本征图像分解算法,用于将单个图像本征分解为反照率和阴影分量。该算法是基于一个全卷积神经网络。通过引入残差块的单个端到端深序列以及两个经过对抗训练的判别器形成了对图像敏感的感知动机度量网络,在不需要任何物理先验和几何信息前提下,实现了单幅图像本征分解。实验结果表明,相对于其他算法,该方法具有更优的性能,而且获得对尺度敏感的反照率。

**关键词** 本征图像分解 深度学习 生成对抗网络 残差模块

中图分类号 TP391.4

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2022.03.032

## AN INTRINSIC IMAGE DECOMPOSITION ALGORITHM BASED ON DEPTH RESIDUAL GENERATIVE ADVERSARIAL NETWORK

Wang Zhao<sup>1</sup> Chen Enqing<sup>2</sup>

<sup>1</sup>(Department of Public Studies, Henan Vocational College of Nursing, Anyang 455000, Henan, China)

<sup>2</sup>(School of Information Engineering, Zhengzhou University, Zhengzhou 450000, Henan, China)

**Abstract** Aiming at the problem that the existing methods have poor decomposition quality and the feature information is not clear enough, an intrinsic image decomposition algorithm based on depth residual generative adversarial network is proposed to decompose intrinsically the single image into albedo and shadow component. The algorithm was based on a full-convolution neural network. By introducing a single end-to-end deep sequence of residual blocks and two confrontation-trained discriminators, an image-sensitive perceptual motivation measurement network was formed. Without any physical priori and geometric information, the intrinsic decomposition of a single image was realized. The experimental results show that the proposed method has better performance than other algorithms and can obtain scale-sensitive albedo.

**Keywords** Intrinsic image decomposition Deep learning Generative adversarial network Residual module

## 0 引言

图像信息的提取是图像领域研究中最基础的方面,通过将图像分解为固有成分在许多计算机视觉和图形任务的有效预处理手段<sup>[1]</sup>。本征图像分解技术就是通过提取反照率和亮度两个本征图来更直观地获得图像的颜色和光照信息,从而提高图像分割、对比度增强等算法的性能<sup>[2-3]</sup>。

由于本征图像分解技术的重要性,研究人员对该技术进行了广泛的研究。目前,大多数方法是基于特定图像理论的算法,如图像序列法<sup>[4]</sup>、Retinex模型算法<sup>[5]</sup>等。这些传统算法在提取图像细节特征方面存在弱点,遇到光照不均或材质条件复杂的自然场景时性能明显下降。近年来,随着人工智能被广泛关注,基于机器深度学习的技术被广泛应用到计算机科学的很多领域中,本征图像分解方向也不例外。Janner等<sup>[6]</sup>提出了一种基于解释输入图像来学习本征图像分解的方

法,该方法利用 RIN 网络将图像分解管道连接在一起,通过给定单个图像来预测反射率、形状和照明条件。Baslamisli 等<sup>[7]</sup>提出了一种基于 CNN 学习与 Retinex 模型相结合的本征图像分解方法,该方法采用数据集训练 CNN 网络,通过基于物理的反射模型来指导学习过程,以及利用反射率和阴影渐变信息来获取固有图像,从而提高算法模型的计算速度。Yuan 等<sup>[8]</sup>提出了使用联合并行学习进行本征图像分解的方法,该方法利用并行卷积神经网络分别学习具有不同空间特征和数据分布的反照率和明暗度,同时将基于传统图像的梯度先验引入损失函数中,通过结合基于物理方法和基于数据驱动的方法的优点来改善学习模型的性能。Liu 等<sup>[9]</sup>开发了用于本征分解的增强型残差密集本征网络,该网络通过构建增强型残差密集块来达到充分利用分层功能的目标,并且将图像物理成像原理设计为重建损失函数,确保观测和估计分量的乘法之间的一致性,提高模型的本征分解性能。

本文针对现有方法分解质量不高、纹理细节不够清晰的现象,提出一种基于深度残差生成对抗网络的本征图像分解算法。该算法是在全卷积神经网络的基础上,加入了端到端的残差网络模块和生成对抗网络,并提出一个由数据损失、数据梯度损失和对抗损失三项组成的加权损失函数用于监督网络的训练过程。本文算法可以在不需要任何物理先验和几何信息前提下,实现单幅图像本征分解。

## 1 相关知识

### 1.1 生成式对抗网络

生成式对抗网络(Generative Adversarial Networks, GANs)是由 Goodfellow 等提出,灵感来源于博弈论中的二人零和博弈思想。GANs 的图片生成能力特别强大,因此被广泛应用于图像修复、图像合成、超分辨率等方面<sup>[10]</sup>。

生成对抗网络的基本框架是由一个生成模型  $G$  和一个判别模型  $D$  组成,该网络通过对抗过程用于迭代更新生成模型的性能。GANs 的流程由图 1 给出。




图 1 生成对抗网络的流程示意图

可以看到,生成模型  $G$  通过真实数据样本  $x$  的训练,生成新的数据样本  $G(z)$  作为判别模型  $D$  的输入,

而  $D$  是一个二分类器,用于判断输入样本是来自于原始数据  $x$  还是由生成模型产生  $G(z)$ 。整个 GANs 过程中网络生成模型  $G$  与判别模型  $D$  同时在运行,判别模型的目标是降低  $D(G(z))$  出现的概率,使其尽可能接近 0,生成模型的目标则是保证  $G(z)$  与  $x$  尽可能地相近,两者之间不断地循环往复,直到二者在博弈中达到纳什平衡。生成式对抗网络的目标函数可以表示为:

$$\min_G \max_D (D, G) = E_{x, P(x)} [\log D(x)] + E_{z, P(z)} [\log(1 - D(G(z)))] \quad (1)$$

式中: $x$  是真实数据样本; $z$  表示潜在表征; $P$  表示概率分布; $E$  表示期望。

### 1.2 残差网络

残差网络(Residual Networks, ResNets)<sup>[11]</sup>是在 2015 年被提出的,该网络由残差块构成,主要通过跳跃连接将模型中的某一层激活信息迅速反馈给更深层。该网络的优点是通过跳跃连接有效加深网络训练深度,提高识别准确率,从而解决了深度卷积神经网络随着深度的增加会导致梯度弥散、梯度爆炸、退化问题的产生。

图 2 为残差网络的残差块结构示意图。可以看出,残差网络是在传统网络的基础上引入跳跃连接,而且 ResNets 中存在两种映射关系:恒等映射和残差映射。恒等映射是将浅层  $C^{(l)}$  的信息  $x$  在保持输出不变的情况下通过跳跃一层或者  $n$  层传递到更深层  $C^{(l+n)}$  的节点;残差映射是指目标输出值  $H(x) = F(x) + x$  与输入值  $x$  之间的差值,即中间层输出值  $F(x)$ 。ResNet 网络训练的目标是将残差结果逼近于 0。




图 2 残差网络的基本模块

## 2 算法简介

本征图像分解就是将由弥散材料组成的图像以像素为单位拆分成反照率  $A$  和阴影  $S$  的乘积:

$$I(x) = A(x) \cdot S(x) \quad (2)$$

式中: $I$  表示输入图像; $x$  表示像素。

由于本征分解问题是不适定的, $A$  和  $S$  存在许多满足上述方程式的可能性都遵循上述解,并且  $I$  的大小取决于未知的采集参数,例如曝光、光照等。因此,

基于深度学习研究的学者采用“尺度不变”理论,即遵循  $I = \alpha A \cdot \beta S$ 。这要求分别对  $\alpha$  和  $\beta$  进行手动优化,但是会容易引起失真和不一致性<sup>[12]</sup>。相反,本文认为为了使  $A$  和  $S$  的后续原则化和联合标准化,能量守恒非常重要,即按照  $I = \alpha A \cdot S / \alpha$  调整  $\alpha$ 。 $A$  是由物理属性定义的,应被视为绝对值,该绝对值对于照明变化和采集噪声是不变的。

### 2.1 网络架构

首先,训练一个具有参数  $\phi$  的生成全卷积网络  $N_\phi$ ,以便根据输入图像  $I$  预测相干对  $(\hat{A}, \hat{S})$ :

$$N_\phi(I) = (\hat{A}, \hat{S}) \quad (3)$$

#### 2.1.1 预测

本文将网络表示为首先估计阴影  $S$ ,然后严格遵守式(2),在预测过程中  $I = \hat{A} \cdot \hat{S}$ ,通过除法推导  $A$ ,整体架构如图 3 所示。因此,只要预测出  $A$  或  $S$  中的一个,可以通过对等式(2)的元素乘积求逆来推导另一个。这一步骤可以在卷积层末端按像素引入图像  $I$  和预测  $S$ ,在卷积神经网络中实现,图 3 中  $P$  位置表示上述步骤。由于两个预测元素都可以用于损失函数中,甚至可以自然融合梯度并可以安全地反向传播,因此不会妨碍 CNN 训练。




图 3 本文网络的整体架构示意图

#### 2.1.2 残差学习

输入图像  $I$  与阴影  $S$  (或反照率  $A$ ) 具有很多共同点,因此识别函数存在一个良好的初始估计值。但是,当解决方案接近真值时,CNN 容易出现发散和不稳定的情况。而残留网络可以很好地解决深度网络的这一缺点,基于此点考虑,本文将残差模块引入提出的分解网络中,以方便估算  $S$ 。

图 4 给出了图 2 中 CNN 分支的具体组成情况,该分支学习了从  $I$  到  $S$  的映射。该网络中的一个残差块由两个 64 通道的  $3 \times 3$  卷积层组成,每次卷积操作后使用批量归一化作为网络的正则化。然后,进行 ReLU。在第二次卷积的 ReLU 之前完成与输入的逐元素求和。本网络分支中存在 10 个依次连接的残差块。最后,因为生成网络是完全卷积的,因此它可以在测试时处理任何大小的图像。

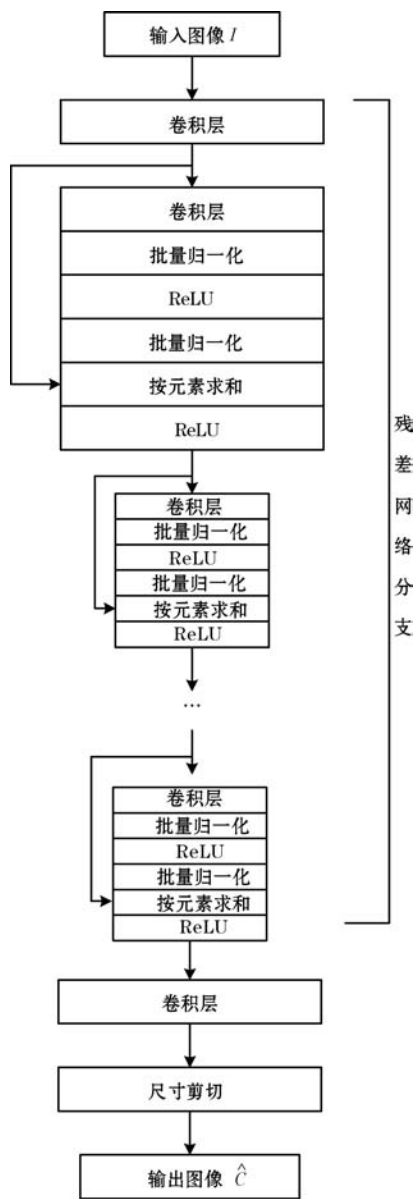


图 4 残差生成器网络示意图

### 2.2 损失函数

假设  $I_{gt}, A_{gt}, S_{gt}$  分别表示真实的输入图像、反照率、阴影。一般来说,学习任务的目标是将预测值  $\hat{A}, \hat{S}$  与真值  $A_{gt}, S_{gt}$  尽可能地接近。在形式上,通过训练网络参数  $\phi$  以使损失函数  $L$  最小,本文的损失函数  $L$  由数据损失  $L_{data}$ 、数据梯度损失  $L_\nabla$  和对抗损失  $L_{adv}$  三项组成:

$$L(\hat{A}, \hat{S}) = L_{data}(\hat{A}, \hat{S}) + L_\nabla(\hat{A}, \hat{S}) + \lambda L_{adv}(\hat{A}, \hat{S}) \quad (4)$$

首先,数据损失项可以确保预测值适应真实数据。本文采用一种对规模敏感的措施,可以保证全局强度的一致性。因此,将该损失项定义为反照率和阴影的 L2 范数:

$$L_{data}(\hat{A}, \hat{S}) = \|A_{gt} - \hat{A}\|^2 + \|S_{gt} - \hat{S}\|^2 \quad (5)$$

其次,对于数据梯度损失,由于反照率和阴影都会呈现出锐利的不连续性,需要进行平滑。为了有利于显示变化估计以及避免过度平滑,在反照率和阴影的

梯度上用 L2 范数补充损失:

$$L_{\nabla}(\hat{A}, \hat{S}) = \|\nabla A_{\text{gt}} - \nabla \hat{A}\|^2 + \|\nabla S_{\text{gt}} - \nabla \hat{S}\|^2 \quad (6)$$

由于典型的 CNN 容易产生视觉伪像,因此,为避免伪像的产生,为  $A$  和  $S$  引入了对抗性损失。鉴别器网络采用两个二进制 CNN 分类器,两个分类器可以表示为:  $D_A(A)$  和  $D_S(S)$ 。鉴别器网络的目的是区分生成网络输出的数据与真实数据之间的差异范围。因此,生成器网络的目的就是欺骗鉴别器,使其无法区分生成图像与真实图像。

形式上,本文分别在预测  $\hat{A}$  和  $\hat{S}$  之后附加两个鉴别器网络  $D_A$  和  $D_S$ ,形成整体的 GAN 网络。然后,将  $D_A$  和  $D_S$  作为生成网络的感知驱动损失函数:

$$L_{\text{adv}}(\hat{A}, \hat{S}) = -\log(D_A(\hat{A}) \cdot D_S(\hat{S})) \quad (7)$$

鉴别器在生成器训练迭代期间是固定的,它仅用作感知度量。通过鉴别器的反向传播可以将误差信息转化为更具表现力形式,从而丰富了误差信息,指导网络学习能力。但是,其缺点是强度可能会超过来自较深处的其他误差信息,因此需要在式(4)中加入权重因子  $\lambda$ 。鉴别器的体系结构遵循标准的分类体系结构:卷积层和最大池化层在前,后面是几个完全连接层,鉴别器网络架构如图 5 所示。




图 5 鉴别器网络架构示意图

鉴别器使用二进制分类损失函数进行训练:

$$L_{\text{Dis}}(C_{\text{gt}}, \hat{C}) = -\log(D_C(C_{\text{gt}})) - \log(1 - D_C(\hat{C})) \quad (8)$$

当  $D_C$  无法将  $\hat{C}$  分类为生成图像时,  $L_{\text{Dis}}(C_{\text{gt}}, \hat{C})$  较小。

### 3 实验

本文所有实验在一台配置为 Intel(R) Core(TM) i7-7820X CPU @ 3.60 GHz 和 8 GB RAM 的机器上进行,所有测试均在 TensorFlow 环境下实现。生成网络在批次大小为 5 的 8 000 次迭代过程中得到了有效的训练。由于生成器网络的最初估算很差,因此在前 400 次迭代中不使用对抗训练来提高训练稳定性。然后,采用与生成器同样的参数对鉴别器进行训练:在迭代过程中,3 个鉴别器使用固定生成器进行更新,然后生成器采用固定鉴别器更新。根据经验,参数  $\lambda = 10^{-4}$  在执行任务时最为有效。本文采用 ADAM 优化方法,学习率从  $10^{-4}$  开始,随后降低到  $10^{-6}$ 。最后,遵循双重交叉验证程序来产生测试结果,该结果是使用在相互测试和训练集上训练的网络进行的两次评估的平均值。

#### 3.1 数据集

本文采用 MPI Sintel 数据集<sup>[8]</sup>进行测试。Sintel 是一部开源的计算机动画短片,其中包含复杂的室内和室外场景。出于研究目的,从中选取多种格式,如固有的阴影和反照率,形成了 MPI Sintel 数据集。数据集包含 18 个序列,其中 17 个序列由 50 帧组成,另一个序列由 40 帧组成,共计 890 帧。反照率图像是在没有照明的情况下渲染的,阴影图像包括照明效果,并且是通过使用恒定的灰色反照率进行渲染而生成的。本文将数据集中的图像随机分配一半用于训练,另一半则用于测试。在训练过程中,使用标准的数据增强技术,即在以  $[0.8, 1.2]$  区间内的随机因子进行缩放,以最大  $15^\circ$  的随机角度旋转以及使用随机水平镜像,可能性为 0.5。

#### 3.2 评价指标

为了进行定量评估,必须选择误差指标。考虑经常使用的指标:两个与数据相关的指标 (si-MSE 和 si-LMSE) 和一个基于感知动机的指标 (DSSIM)。但是,由于这些指标对规模不敏感,因此需要另外考虑对规模敏感的指标。

### 3.2.1 尺度不变度量

尺度不变均方误差  $si\_MSE$  的数学公式可以被定义为:

$$si\_MSE(\hat{C}) = \|C_{gt} - \alpha \hat{C}\|^2 / N \quad (9)$$

式中:  $C \in \{A, S\}$ ;  $\alpha = \operatorname{argmin}_{\alpha} \|C_{gt} - \alpha \hat{C}\|^2$ ;  $N$  表示  $C_{gt}$  中的像素数。注意,  $\alpha$  分别针对  $\hat{A}$  和  $\hat{S}$  进行了优化。因此, 它们中任何一个的任何尺度偏移都不会影响误差, 并且两个预测之间的尺度相关性误差也不会受到影响。

尺度不变局部均方误差  $si\_LMSE$  的数学公式可以表示为:

$$si\_LMSE(\hat{C}) = \frac{1}{P} \sum_{\hat{P} \in \hat{C}} si\_MSE(\hat{P}) \quad (10)$$

式中:  $P$  表示图像块的数量;  $\hat{P}$  表示一个正方形图像块, 取自  $\hat{C}$  最大尺寸的 10%。在网格上定期提取图像块, 以便相邻图像块之间有 50% 的重叠。在这种情况下, 比例参数  $\alpha$  分别针对每个图像块进行了优化。该指标评估局部结构的相似性比 MSE 的粒度更细。

结构相似性 SSIM 是一种出于感动动机的度量, 它考虑了多个独立的结构和亮度差异。本文将采用其差异度量形式 DSSIM:

$$DSSIM(\hat{C}) = (1 - SSIM(\hat{C})) / 2 \quad (11)$$

### 3.2.2 规模感知指标

本文认为反照率具有独特的物理价值, 在提取时应该严格遵守式(2)的理论原则。因此,  $(A, S)$  对应该是唯一的。采用下面两个数据指标, 用于测量与一致性联合尺度相关的重建偏差。

传统的对比例敏感的指标是 MSE, 用于衡量总体目标, 在数值上会尽可能接近真实值:

$$MSE(\hat{C}) = \|C_{gt} - \hat{C}\|^2 / N \quad (12)$$

相对尺度均方误差  $rs\_MSE$ :

$$rs\_MSE(\hat{A}, \hat{S}) = \min_{\alpha} (\|A_{gt} - \alpha \hat{A}\|^2 + \|S_{gt} - \hat{S} / \alpha\|^2) / 2N \quad (13)$$

此措施仅允许相对比例优化, 以便保留以下关系:

$$I = \alpha A \cdot S / \alpha \quad (14)$$

因此与式(2)一致, 即这种措施可以容忍相对一致的强度变化, 同时必须保留整体强度以及结构信息。

## 3.3 测试结果

本文采用 MPI Sintel 数据集进行测试, 利用尺度不变度量和规模感知指标进行评估本文算法的性能, 并且与 ParCNN<sup>[8]</sup>、ERDIN<sup>[9]</sup>、ADM-ALM<sup>[13]</sup>等方法进

行对比验证。

图6给出了 MPI Sintel 数据集中选择的图像的视觉比较。可以看到, 文献[13]的测试结果中纹理细节模糊, 文献[8]、文献[9]可以实现平坦的反照率, 但是无法保留细节并产生锯齿状边缘。相比较而言, 本文模型产生可恢复更好细节的高质量图像, 在空间和颜色域中的清晰度更高, 反照率图中可以看到清晰的背景轮廓, 阴影图中可以很好地观测到图中人物头发。



(a) 真实图像的反照率和阴影



(b) ParCNN<sup>[8]</sup>的反照率和阴影



(c) ERDIN<sup>[9]</sup>的反照率和阴影



(d) ADM-ALM<sup>[13]</sup>的反照率和阴影



(e) 本文方法的反照率和阴影

图6 MPI Sintel 数据集中选择的图像的视觉比较

表1-表3给出了测试图像在尺度不变度量和规模感知指标上的定量评估结果。可以看出, 相对于其他本征图像分解算法, 本文方法的分解性能更佳, 对噪声更具鲁棒性, 对局部结构错误的纠正能力强, 而且拥有更好的泛化能力。

表1 在 Sintel 图像分割上进行两次交叉验证后的测试结果

方法	si_MSE			si_LMSE		
	A	S	平均	A	S	平均
基线:阴影	5.31	4.88	5.10	3.26	2.84	3.05
基线:反照率	3.69	3.78	3.74	2.40	3.03	2.72
ParCNN <sup>[8]</sup>	1.63	1.71	1.67	1.06	1.12	1.09

续表 1

方法	si_MSE			si_LMSE		
	A	S	平均	A	S	平均
ERDIN <sup>[9]</sup>	1.24	1.28	1.26	0.83	0.85	0.84
ADM-ALM <sup>[13]</sup>	3.07	2.77	2.92	1.85	1.90	1.88
本文	<b>1.00</b>	<b>0.92</b>	<b>0.96</b>	<b>0.69</b>	<b>0.70</b>	<b>0.70</b>

表 2 Sintel 图像在基于感知动机的指标的测试结果

方法	DSSIM		
	A	S	平均
基线:阴影	21.40	20.60	21.00
基线:返照率	22.80	18.70	20.75
ParCNN <sup>[8]</sup>	15.14	14.85	15.00
ERDIN <sup>[9]</sup>	13.28	13.54	15.41
ADM-ALM <sup>[13]</sup>	19.60	16.50	18.05
本文	<b>12.63</b>	<b>12.13</b>	<b>12.38</b>

表 3 Sintel 图像在规模感知指标上的测试结果

方法	MSE			$rs\_MSE$
	A	S	平均	
ParCNN <sup>[8]</sup>	2.29	2.45	2.37	2.12
ERDIN <sup>[9]</sup>	2.14	2.21	2.18	1.93
ADM-ALM <sup>[13]</sup>	2.50	4.83	3.66	3.09
本文	<b>2.10</b>	<b>2.19</b>	<b>2.15</b>	<b>1.85</b>

## 4 结 语

本文提出一种基于深度残差生成对抗网络的本征图像分解算法,用于解决现有方法分解质量不佳、纹理细节分解不够清晰的问题。该算法是基于一个全卷积神经网络,引入端到端的残差网络模块和生成对抗网络。为了避免网络过拟合现象的产生,提出一个由数据损失、数据梯度损失和对抗损失三项组成的加权损失函数用于监督网络的训练过程。本文算法在不需要任何物理先验和几何信息前提下,实现了单幅图像本征分解。实验结果表明,本文方法比其他分解算法具有更明显的性能优势,而且获得的反照率对尺度敏感性高。

## 参 考 文 献

[1] 邢冠宇,袁霞,李龙,等. 单幅 RGB-D 图像本征图像交

互分解算法[J]. 计算机辅助设计与图形学学报,2017,29(7):1283-1291.

- [2] Aswathy V S, Sajeer M. Intrinsic image decomposition for image enhancement[C]//2018 2nd International Conference on Trends in Electronics and Informatics (ICOEI), 2018: 20-23.
- [3] Yue H, Yang J, Sun X, et al. Contrast enhancement based on intrinsic image decomposition[J]. IEEE Transactions on Image Processing, 2017, 26(8): 3981-3994.
- [4] Lettry L, Vanhoey K, Van G L. Unsupervised deep single-image intrinsic decomposition using illumination-varying image sequences[J]. Computer Graphics Forum, 2018, 37(7): 409-419.
- [5] Chen X, Zhu W, Zhao Y, et al. Intrinsic decomposition from a single spectral image[J]. Applied Optics, 2017, 56(20): 5676-5684.
- [6] Janner M, Wu J, Kulkarni T D, et al. Self-supervised intrinsic image decomposition[C]//2017 Advances in Neural Information Processing Systems (NIPS), 2017: 5936-5946.
- [7] Baslamisli A S, Le H A, Gevers T. CNN based learning using reflection and retinex models for intrinsic image decomposition[C]//2018 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2018: 6674-6683.
- [8] Yuan Y, Sheng B, Li P, et al. Deep intrinsic image decomposition using joint parallel learning[C]//2019 36th Computer Graphics International Conference (CGI), 2019: 336-341.
- [9] Liu R, Yang C, Ma L, et al. Enhanced residual dense intrinsic network for intrinsic image decomposition[C]//2019 IEEE International Conference on Multimedia and Expo (ICME), 2019: 1462-1467.
- [10] Liang T, Stokes J. Interaction matters: A note on non-asymptotic local convergence of generative adversarial networks [C]//2019 22nd Artificial Intelligence and Statistics (AISTATS), 2019: 1-15.
- [11] Niu Y, Lu Z, Wen J R, et al. Multi-modal multi-scale deep learning for large-scale image annotation[J]. IEEE Transactions on Image Processing, 2019, 28(4): 1720-1731.
- [12] Ma W C, Chu H, Zhou B, et al. Single image intrinsic decomposition without a single intrinsic image[C]//2018 15th European Conference on Computer Vision (ECCV), 2018: 201-217.
- [13] Wang Y, Li K, Yang J, et al. Intrinsic decomposition from a single RGB-D image with sparse and non-local priors [C]//2017 IEEE International Conference on Multimedia and Expo (ICME), 2017: 1201-1206.