

融合图像局部和退化表征信息的盲超分辨重建^{*}

刘建军 郝敏钗 李建朝 胡雪花
(河北工业职业技术大学智能制造学院 石家庄 050091)

摘要:针对假设的退化模型与实际模型不一致时图像超分辨性能显著降低的问题,提出了一种融合图像空间局部和退化表征信息的深度卷积神经网络模型。首先对低分辨率图像提取初始特征和退化表达量;然后构建级联的空间局部信息和退化信息模块以及特征融合块,这些模块进一步级联组成特征变换子网络;最后,利用反卷积层得到高分辨率图像。在基准测试数据集上的实验表明,当高斯核宽度不为0时,算法在采样因子为 $\times 2$ 和 $\times 4$ 的盲超分辨重建中均取得了较当前主流算法更高的峰值信噪比值(PSNR),其中 $\times 2$ 盲超分辨时最高的PSNR值为37.56, $\times 4$ 盲超分辨时最高的PSNR值为31.87,并且与主流算法相比也有较高的重建效率和较好重建视觉效果。

关键词:盲超分辨;级联结构;卷积神经网络;深度学习

中图分类号: TN391 **文献标识码:** A **国家标准学科分类代码:** 520.604

Blind super-resolution reconstruction based on fusion of local information and degradation representation of image

Liu Jianjun Hao Minchai Li Jianchao Hu Xuehua

(College of Intelligent Manufacturing, Hebei Vocational University of Industry and Technology, Shijiazhuang 050091, China)

Abstract: Aiming at the problem that the super-resolution performance of image is significantly reduced when the assumed degradation model is inconsistent with the actual model, a deep convolution neural network model integrating the local and degradation representation information of image space is proposed. First, the initial features and degraded expressions are extracted from the low-resolution image, and then the cascaded spatial local information and degraded information modules and feature fusion blocks are constructed. These modules are further cascaded to form the feature transformation sub network. Finally, the high-resolution image is obtained by using the deconvolution layer. The experiments on the benchmark test dataset show that the algorithm achieves higher peak signal-to-noise ratio (PSNR) than the current mainstream blind super-resolution algorithms for both $\times 2$ and $\times 4$ sampling factors when the Gaussian kernel width is not 0, with the highest PSNR value is 37.56 for $\times 2$ blind super-resolution and 31.87 for $\times 4$ blind super-resolution, and also has higher reconstruction efficiency and better reconstruction visual effect compared with the mainstream algorithms.

Keywords: blind super-resolution; cascade structure; convolutional neural network; deep learning

0 引言

图像超分辨(super-resolution, SR)是指从低分辨率(low resolution, LR)图像重建出对应的高分辨率(high resolution, HR)图像的技术^[1]。该技术因其在航空航天、医疗成像、图像通信等领域具有重要的应用价值^[2],受到了

广泛的关注。图像超分辨重建技术经历了基于插值的方法、基于重构的方法、基于浅层神经网络的方法、基于深度卷积神经网络(convolutional neural network, CNN)方法的发展过程^[3-5],其中基于深度卷积神经网络的方法具有更好的图像表征和重建能力,是目前最活跃的研究方向^[6-7]。

收稿日期:2022-09-06

^{*} 基金项目:中央引导地方科技发展资金(216Z1004G)、河北省冶金工业过程数字化控制技术创新中心研究项目(SG2021185)、河北工业职业技术大学博士基金(ZK202102)、河北省高等学校科学技术研究项目(ZC2022016)资助

基于深度 CNN 的图像超分辨方法通常假设图像的退化模型是已知的,当图像的实际退化模型与深度 CNN 假定的退化模型不一致时,会导致图像超分辨重建的性能显著下降。为了解决这个问题,学者们提出了图像盲超分辨重建技术^[8-10]。图像盲超分辨重建是指在图像的退化模型未知的条件下完成低分辨图像的超分辨重建。

针对图像盲超分辨重建,Zhang 等^[11]在训练深度 CNN 模型时,将若干个退化模型(包括多个高斯核、多种噪声)联合训练数据作为整个训练数据来训练深度 CNN 模型,这种模型相对于单一假定的退化模型来说具有更强的适应性,但是当实际的退化模型未包含在训练数据的退化模型中时,图像的超分辨重建性能仍然不佳。为了提高图像盲超分辨的性能,学者们提出了估计退化模型思路。Gu 等^[12]提出了一种迭代估计退化模型的方法,该方法能够较准确的估计出图像的退化模型,具有较高的盲超分辨性能。但是,该方法采用多次迭代的方式估计图像的退化模型,使得算法运行时间较长,不能满足实际应用的需要。为了提高图像盲超分辨重建的效率,Wang 等^[13]提出了一种基于退化表达学习的图像盲超分辨方法,具有较高的图像盲超分辨重建性能和效率。但是该方法在图像盲超分辨重建时,未利用图像的空间局部信息,限制了超分辨重建性能的进一步提高。

为了提高假设的退化模型与实际模型不一致时的图像超分辨性能,本文在退化感知超分辨模型(DASR)^[13]的基础上,提出一种基于图像空间局部信息和退化构建的深

度卷积神经网络模型(spatial local and degradation construction network, SLDCN)用于图像盲超分辨重建。SLDCN 使用退化表达信息的同时,进一步引入空间局部构建信息,同时在单元模块中采用特征融合机制,以增强高价值特征在网络中的传播。相对于 DASR 模型,在利用退化表达信息的同时,引入空间局部信息,增强了图像盲超分辨过程中的高价值信息,从而提高模型的盲超分辨重建性能。在重建单元模块中引入特征融合机制,提高不同层级特征信息的融合能力。建立了 SLDCN,该盲超分辨重建是一种从 LR 图像到 HR 图像的端到端映射模型,具有良好的图像盲超分辨能力。

1 网络模型

本文提出的 SLDCN 模型的结构如图 1(a)所示,图 1(b)为级联空间局部和退化构建模块(spatial local and degradation construction,SLDC)和特征融合模块对应的结构。该模型由退化表达与初始特征提取子网络(degradation representation and initial feature extraction sub-network,DRIFENet)、特征融合变换子网络(feature fusion transformation sub-network,FFTNet)、图像重建子网络(image reconstruction sub-network,IRNet)三部分组成。其中,DRIFENet 完成从输入的 LR 图像中进行退化表达编码和初始特征图提取,FFTNet 通过级联的特征变换模块获取融合了空间局部信息和退化表达信息的高价值特征,IRNet 利用变换后的高价值特征完成图像的超分辨重建。

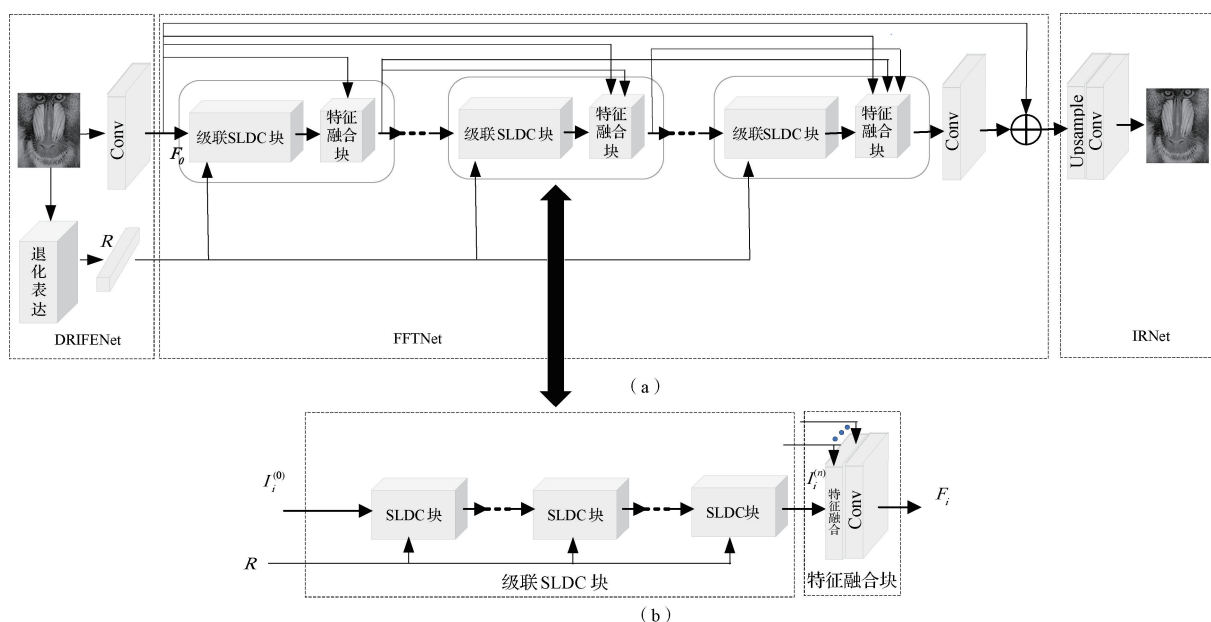


图 1 SLDCN 模型结构

1.1 DRIFENet

DRIFENet 子网络包括退化表达和初始特征提取两个部分,为了提高模型的训练效率,本文借鉴文献^[13]的

方法,不在像素层面估计 LR 图像的准确退化信息,而是利用 6 层的卷积网络得到 LR 图像的退化表达量 R ,该表达量与 LR 图像经卷积网络产生的初始特征 F_0 一起送入

FFTNet子网络进行特征变换。

1.2 FFTNet

在FFTNet子网络中,SLDC块和特征融合块组成的特征变换模块经过级联后,获得对LR图像初始特征的高价值提取和退化信息的学习。FFTNet子网络中,级联SLDC块和特征融合块的结构如图1(b)所示。

1)SLDC块

SLDC块实现对图像特征中空间信息的自主学习,提高模型对高价值特征的关注度,另外,模型还完成对LR图像退化信息的快速高效学习,以实现图像的盲超分辨。SLDC块的结构如图2所示。

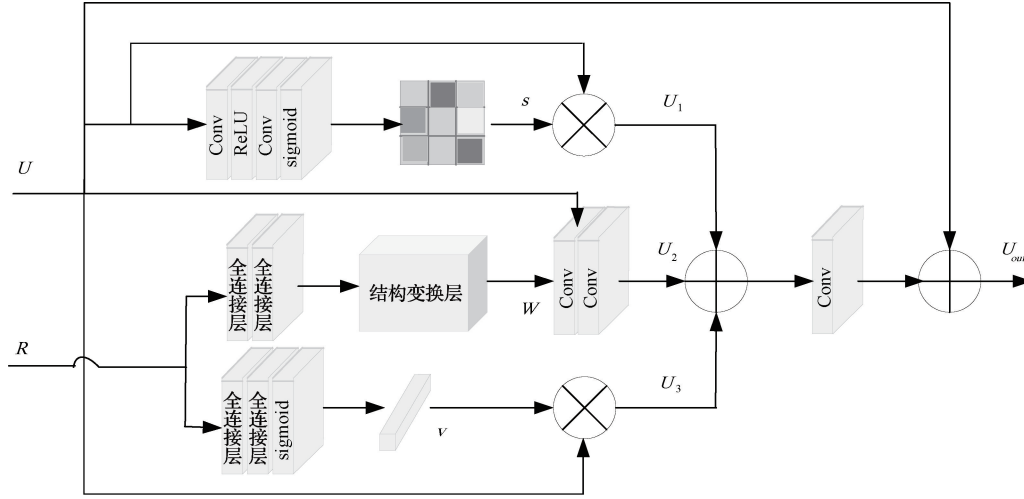


图2 SLDC块结构

图2中,设由前一级模块送到该SLDC模块的特征为 $U = [u_1, u_2, \dots, u_c]$,该特征包含 c 张尺寸为 $H \times W$ 的特征图。为了使模型学习到高价值的空间分布信息,提高模型对高频细节的重建能力,借鉴文献[14]局部计算模型的思想,构建了高价值空间局部信息学习分支,该分支包含两层卷积网络、一个ReLU激活函数、一个Sigmoid激活函数。通过卷积网络和激活函数,得到空间局部特征图 $s \in \mathbf{R}^{1 \times H \times W}$,过程如下:

$$s = \rho(W_s^2 * \delta(W_s^1 * U + b_s^1) + b_s^2) \quad (1)$$

式中: $\rho(\cdot)$ 表示sigmoid激活函数; $\delta(\cdot)$ 表示ReLU激活函数; $*$ 表示卷积运算; W_s^1 和 b_s^1 表示第1个卷积层的参数; W_s^2 和 b_s^2 表示第2个卷积层的参数。利用该空间局部特征图 s 对输入特征 U 进行调制得到调制后的特征 U_1 :

$$U_1 = f(U, s) \quad (2)$$

式中: $f(\cdot)$ 表示局部特征图 s 与输入特征 U 逐元素相乘。

为了使模型快速学习到图像的退化信息,借鉴文献[13]的思想,构建了两个退化特征信息学习分支,一个分支中将初始退化表达量 R 通过两个全连接层和结构变换后得到后续卷积层的卷积核 W ,然后经过两层卷积得到退化表达调制后的特征 U_2 :

$$U_2 = W_R^2 * (W_R^1 * R + b_R^1) + b_R^2 \quad (3)$$

式中: W_R^1 、 b_R^1 和 W_R^2 、 b_R^2 分别表示两个卷积层的参数。另一个分支将退化表达量 R 通过两个全连接层和sigmoid激活函数后,得到通道调节分量 V ,然后该调节分量与输入特征 U 按通道相乘后得到退化表达调制后的特征 U_3 :

$$U_3 = g(U, V) \quad (4)$$

U_1 、 U_2 、 U_3 经过特征聚合后,再经过卷积网络变换并与残差分支聚合后得到SLDC块的输出 U_{out} ,可以表示为:

$$U_{out} = W_{SLDC} * [U_1 + U_2 + U_3] + b_{SLDC} + U \quad (5)$$

式中: W_{SLDC} 、 b_{SLDC} 表示卷积层的参数。

2)级联SLDC与特征融合块

设FFTNet子网络中,第 i 个级联SLDC与特征融合块的输入为 $I_i^{(0)}$ 和 R ,如图1(b)所示,经过 n 个SLDC块级联后的输出为 $I_i^{(n)}$:

$$I_i^{(n)} = H(I_i^{(0)}, R) \quad (6)$$

式中: $H(\cdot)$ 表示 n 个SLDC块的级联模型。

第 n 个SLDC块的输出 $I_i^{(n)}$ 与前面 $i-1$ 个级联SLDC块与特征融合块的输出 $[F_1, F_2, \dots, F_{i-1}]$ 以及初始特征 F_0 ,在特征融合块中沿通道域进行拼接,然后经一层卷积网络得到第 i 个特征融合块的输出,可以表示为:

$$F_i = W_{fusion}^{(i)} * [I_i^{(n)}, F_0, F_1, F_2, \dots, F_{i-1}] + b_{fusion}^{(i)} \quad (7)$$

式中: $W_{fusion}^{(i)}$ 、 $b_{fusion}^{(i)}$ 表示第 i 个特征融合块卷积层的参数。

通过SLDC块的级联,使得模型学习到的高价值空间局部信息和图像退化信息得到加强。通过特征融合块的融合,使得模型不仅学习到本级模块的特征信息,而且使得前端模块学习到的信息得到保持。

3)FFTNet

在FFTNet子网络中,多个级联SLDC块与特征融合块经过级联并通过一个卷积层后,与从输入端到输出端的恒等映射构成残差学习模型,FFTNet的学习过程可以表示为:

$$F_{FFTNet} = f_{FFTNet}(F_0) + F_0 \quad (8)$$

式中： F_{FFTNet} 表示 FFTNet 子网络的输出； $f_{FFTNet}(\cdot)$ 表示 FFTNet 子网络模型。

通过级联 SLDC 块及特征融合块的级联以及前端至后端的融合链接，不仅使得学习到的高价值特征和图像退化信息得到加强，而且使得前端学习到的信息得到保持。

1.3 IRNet

IRNet 包括一层亚像素卷积层和一层卷积网络层，得到高分辨重建后的 HR 图像，可以表示为：

$$Y_{SR} = f_{IRNet}(F_{FFTNet}) \quad (9)$$

式中： Y_{SR} 表示输出的高分辨重建图像； f_{IRNet} 表示 IRNet 子网络模型。

2 本文模型相对于 DASR 模型的改进

本文的 SLDCN 模型是在 DASR 模型^[13]的基础上进行改进构建的，相对于 DASR 模型，本文 SLDCN 模型的改进主要有如下两点。

1) 在 SLDC 模块中增加了空间局部信息学习分支(图 2 中生成 U_1 的分支)，通过该分支中图像空间局部信息的学习，使得图像超分辨过程中的高价值信息得到加强。

2) 在级联 SLDC 模块的后面增加了特征融合模块(图 1(b)中的特征融合块)，通过增加特征融合模块，不仅使得模型学习到本级模块的特征信息，而且保持了前端模块学习到的信息。

基于以上的改进，本文的 SLDCN 模型不仅保持了 DASR 模型快速学习图像退化表达信息的能力，而且增强了图像盲超分辨的性能。

3 实验与分析

3.1 数据集与实验设置

本文使用 DIV2K 数据集^[15]的 800 张图像作为本文提出模型的训练数据集，使用 Set5、Set14、B100 三个基准测试集作为模型有效性的测试数据集。

实验所用的 LR 图像由 HR 图像与高斯核进行卷积操作后再经过双三次插值下采样以及添加噪声后得到，高斯核尺寸设置为 21×21 ，当采样因子为 $\times 2$ 时，高斯核参数 σ 的选择范围为 $[0.2, 2.0]$ ，当采样因子为 $\times 4$ 时，高斯核参数 σ 的选择范围为 $[0.2, 3.6]$ ，高斯噪声方差的选择范围为 $[0, 15]$ 。从 DIV2K 数据集中随机选择 32 幅 HR 图像，利用随机翻转和旋转变换对选出的 HR 图像进行扩充。随机选择 32 个高斯核参数和高斯噪声参数，生成 HR 图像对应的 LR 图像，在每个 LR 图像中随机剪切 2 个大小为 48×48 的 LR 图像块，总共 64 对 LR 图像和 HR 图像块对组成模型的训练集。

模型训练时，采用 Adam 算法^[16]对模型进行优化，其中超参数 β_1 、 β_2 、 ϵ 分别设为 0.9 、 0.999 、 10^{-8} ，退化表达量 R 按照文献^[13]的方法得到。模型迭代更新 1 000 次，学习率初始化为 10^{-4} ，每经过 250 次迭代更新学习率衰减一半。模型训练采用 L_1 损失函数。LR 图像在训练和测试

前首先利用 DnCNN 算法^[17]进行去噪。

3.2 实验结果及分析

1) 客观量化结果及分析

本文在 Set5、Set14、B100 三个基准测试数据集上对比了本文的 SLDCN 模型与 DASR^[13]算法模型(本文模型所改进的模型)的盲超分辨性能。另外，为了更加充分的测试本文模型的性能，还与近年来几种主流的超分辨算法模型进行了性能对比，包括矩阵转移学习超分辨网络模型(MZSR)^[9]、多种退化超分辨网络模型(SRMD)^[11]、迭代核修正盲超分辨网络模型(IKC)^[12]、残差通道注意网络模型(RCAN)^[18] 4 种模型，其中 SRMD 和 MZSR 模型不具有盲超分辨能力，测试时，将 IKC 模型的退化预测器用于 SRMD 和 MZSR 模型，使其具有盲超分辨能力。本文测试了几种算法模型在采样因子为 $\times 2$ 和 $\times 4$ 时的盲超分辨重建性能，采用峰值信噪比(peak signal-to-noise ratio, PSNR)作为盲超分辨重建性能评价指标，PSNR 值越大表示重建效果越好。测试中，由于 MZSR 模型设计只有采样因子为 $\times 2$ 的超分辨能力，IKC 模型设计只有采样因子为 $\times 4$ 的超分辨能力，因此，实验中 MZSR 模型只用于采样因子为 $\times 2$ 的超分辨，IKC 模型只用于采样因子为 $\times 4$ 的超分辨。各算法模型性能对比结果如表 1、2 所示。

表 1 中黑体数据表示采样因子为 $\times 2$ 时，在测试数据集 Set5、Set14、B100 上当高斯噪声方差分别为 0、5、10 时，高斯核宽度分别为 0、0.8、1.6 时测试算法对应的最大 PSNR 值。表 2 中的黑体数据表示采样因子为 $\times 4$ 时，在测试数据集 Set5、Set14、B100 上当高斯噪声方差分别为 0、5、10 时，高斯核宽度分别为 0、1.6、3.2 时测试算法对应的最大 PSNR 值。从两个表中可以看出，当高斯核宽度设置为 0 时，此时的退化为双三次退化，这种情况下 RCAN 模型的超分辨性能最好，当高斯核宽度不为 0，RCAN 模型的性能显著降低，说明该模型对不同的退化适应能力较低。SRMD+退化预测、MZSR+退化预测、IKC、DASR 几种模型都具有退化预测能力，对不同的图像退化具有一定的适应能力。本文的 SLDCN 模型中结合了空间局部信息和退化预测构建，在高斯核宽度为 0.8、1.6 的 $\times 2$ 的超分辨重建以及高斯核宽度为 1.6、3.2 的 $\times 4$ 的超分辨重建中，都具有更高的 PSNR 值，说明本文的模型具有更优的图像盲超分辨性能。

2) 模型运行时间对比

本文的 SLDCN 算法模型与 RCAN、SRMD、MZSR、IKC、DASR 几种算法的平均运行时间如表 3 所示。从表 3 可以看出，SRMD 算法运行效率最高，但是该算法不具有盲超分辨重建能力，当图形退化模型与算法实际退化模型不一致时，算法超分辨重建能力显著降低。由于 IKC 算法通过迭代估计图像的退化模型，该算法的运行效率最低。本文的 SLDCN 算法的运行效率低于 DASR 算法，但是显著高于 IKC 算法。

表1 采样因子为×2时,不同算法模型的PSNR值对比

方法	噪声	Set5 上不同高斯核 宽度对应的 PSNR 值			Set14 上不同高斯核 宽度对应的 PSNR 值			B100 上不同高斯核 宽度对应的 PSNR 值		
		0	0.8	1.6	0	0.8	1.6	0	0.8	1.6
		RCAN	0	38.30	34.52	28.75	34.17	30.62	26.84	32.39
	5	38.12	34.12	28.37	33.82	30.29	26.58	32.07	30.15	27.16
	10	37.58	33.64	27.89	33.51	29.94	26.15	31.84	29.87	26.79
SRMD+退化预测	0	34.89	34.57	33.95	31.40	31.15	30.39	30.82	30.12	29.47
	5	34.64	34.21	33.64	31.12	30.86	30.05	30.57	29.91	29.15
	10	34.26	33.78	33.15	30.79	30.57	29.68	30.14	29.67	28.76
MZSR+退化预测	0	35.91	35.46	33.97	31.95	31.14	30.26	30.70	29.58	29.12
	5	35.64	35.18	33.75	31.68	30.85	29.84	30.35	29.34	28.78
	10	35.27	34.76	33.38	31.29	30.37	29.38	30.14	28.97	28.46
DASR	0	37.84	37.38	36.57	33.30	32.87	32.25	32.10	31.75	31.16
	5	37.16	36.67	35.78	32.62	32.18	31.78	31.65	30.85	30.61
	10	36.48	35.89	35.10	31.75	31.64	30.92	30.86	30.24	30.17
SLDCN(本文)	0	37.95	37.56	36.87	33.52	32.96	32.34	32.26	31.98	31.28
	5	37.24	36.70	35.86	32.71	32.25	31.84	31.72	30.90	30.72
	10	36.51	35.95	35.25	31.82	31.70	31.12	30.91	30.32	30.24

表2 采样因子为×4时,不同算法模型的PSNR值对比

方法	噪声	Set5 上不同高斯核 宽度对应的 PSNR 值			Set14 上不同高斯核 宽度对应的 PSNR 值			B100 上不同高斯核 宽度对应的 PSNR 值		
		0	1.6	3.2	0	1.6	3.2	0	1.6	3.2
		RCAN	0	32.69	28.86	25.48	28.90	26.24	24.12	27.75
	5	32.35	28.58	25.17	28.78	25.96	23.39	27.56	25.69	24.16
	10	32.10	28.24	24.79	28.35	25.64	23.12	27.24	25.34	23.78
SRMD+退化预测	0	30.65	29.32	28.97	27.72	26.28	26.16	27.18	26.20	26.14
	5	30.04	28.54	28.28	27.15	25.76	25.47	26.54	25.69	25.55
	10	29.69	28.15	27.85	26.86	25.38	25.19	26.26	25.34	25.21
IKC	0	31.94	31.25	29.86	28.60	28.32	27.67	27.54	27.30	27.04
	5	31.16	30.67	29.18	27.95	27.85	26.86	26.79	26.75	26.59
	10	30.75	30.24	28.77	27.56	27.48	26.54	26.57	26.48	26.25
DASR	0	32.05	31.80	30.97	28.58	28.38	27.95	27.61	27.48	27.10
	5	31.27	31.08	30.14	27.80	27.96	27.21	26.90	26.85	26.67
	10	30.87	30.66	29.74	27.46	27.58	26.87	26.62	26.57	26.32
SLDCN(本文)	0	32.10	31.87	31.02	28.64	28.46	28.07	27.70	27.51	27.24
	5	31.35	31.16	30.22	27.87	27.98	27.32	26.98	26.92	26.75
	10	30.96	30.70	29.81	27.52	27.60	26.91	26.72	26.61	26.42

表3 不同算法模型的平均运行时间对比

算法模型	RCAN	SRMD	MZSR	IKC	DASR	SLDCN(本文)
运行时间/ms	168	8	92	521	75	87

3)视觉效果对比

本文比较了几种算法模型在噪声水平为5,高斯核宽度为1.6,采样因子为×4时在Set14测试数据集中“zebra”图片中取部分纹理图像的盲超分辨效果,视觉效果如图3所示。从图3可以看出,由于图形的退化模型不为双

三次退化模型,RCAN的超分辨效果较差。SRMD与IKC算法估计的退化模型与实际退化模型偏差较大,这两个算法的超分辨效果也不理想。本文算法在利用退化表达信息的同时,引入空间局部信息,并且在重建单元模块中引入特征融合机制,在几种算法中重建效果最佳。




图3 本文方法与其他方法的视觉效果对比结果

4 结论

本文提出了一种基于图像空间局部信息和退化构建的深度卷积神经网络模型,用于图像退化模型未知情况下的盲超分辨率重建。该算法在利用退化表达信息的同时,引入空间局部信息,并在重建单元模块中引入特征融合机制,使得算法模型具有高价值信息学习能力和多层次信息融合能力。实验结果表明,本文算法在峰值信噪比、模型运行效率、视觉效果方面均有所提升。

参考文献

- [1] 陈晓,荆茹韵. 单图像超分辨率方法综述[J]. 电子测量技术, 2022, 45(9): 104-112.
- [2] 张进,李强,王冠等. 傅里叶单像素显微超分辨成像系统设计[J]. 电子测量与仪器学报, 2022, 36(1): 174-179.
- [3] TIMOFTE R, DE V, GOOL L V. Anchored neighborhood regression for fast example-based super-resolution [C]. Proceedings of the 14rd IEEE International Conference on Computer Vision. IEEE, 2013: 1920-1927.
- [4] 石欣,卢灏,秦鹏杰,等. 一种远距离行人小目标检测方法[J]. 仪器仪表学报, 2022, 43(5): 136-146.
- [5] 杨梦薇,肖秦琨,朱毅琳. 基于深度残差网络的图像超分辨率重建[J]. 国外电子测量技术, 2022, 41(4): 170-175.
- [6] DONG C, LOY C C, HE K, et al. Image super-resolution using deep convolutional networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(2): 295-307.
- [7] KIM J, LEE J K, LEE K M. Deeply-recursive convolutional network for image super-resolution[C]. Proceedings of the 29rd IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2016: 1637-1645.
- [8] SHOCHER A, COHEN N, IRANI M. "Zero-shot" super-resolution using deep internal learning [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2018: 3118-3126.
- [9] SOH J W, CHO S, CHO N I. Meta-transfer learning for zero-shot super-resolution[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2020: 3516-3525.
- [10] ZHANG K, GOOL L V, TIMOFTE R. Deep unfolding network for image super-resolution [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2020: 3217-3226.
- [11] ZHANG K, ZUO W, ZHANG L. Learning a single convolutional super-resolution network for multiple degradations[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2018: 3262-3271.
- [12] GU J, LU H, ZUO W, et al. Blind super-resolution with iterative kernel correction[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2019: 1604-1613.
- [13] WANG L, WANG Y, DONG X, et al. Unsupervised degradation representation learning for blind super-resolution[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2021: 10576-10585.
- [14] HU Y, LI J, HUANG Y, GAO X. Channel-wise and spatial feature modulation network for single image super-resolution [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2020, 30(11): 3911-3927.
- [15] TIMOFTE R, AGUSTSSON E, GOOL L V, et al. NTIRE 2017 challenge on single image super-resolution: dataset and study[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2017: 1122-1131.
- [16] KINGMA D P, BA J. Adam: A method for stochastic optimization [C]. Proceedings of the International Conference on Learning Representations, 2015: 1-13.
- [17] ZHANG K, ZUO W, CHEN Y, et al. Beyond a gaussian denoiser: Residual learning of deep CNN for image denoising [J]. IEEE Transactions on Image Process, 2017, 26(7): 3142-3155.
- [18] ZHANG Y, LI K P, LI K, et al. Image super-resolution using very deep residual channel attention networks[C]. Proceedings of European Conference on Computer Vision. Springer, 2018: 294-310.

作者简介

刘建军, 博士, 副教授, 主要研究方向为机器视觉、视觉 SLAM。

E-mail: 550292346@qq.com

郝敏钗, 硕士, 教授, 主要研究方向为机器视觉。

李建朝, 硕士, 副教授, 主要研究方向为机器视觉。

胡雪花(通信作者), 硕士, 讲师, 主要研究方向为计算机视觉。

E-mail: 1482696722@qq.com