

基于密集连接与激励模块的图像超分辨率网络

胡诗语, 王国栋*, 赵毅, 王岩杰, 潘振宽

青岛大学计算机科学技术学院, 山东 青岛 266071

摘要 针对基于卷积神经网络的超分辨率技术在纹理恢复时存在信息丢失、边缘模糊的现象, 将密集块和激励模块结合, 对图像进行低分辨率到高分辨率的端对端处理。密集连接融合后组成的密集块结构使图像区域的上下文信息得到有效利用。激励模块将有价值的全局信息选择性放大并将无用特征加以抑制。图像重建部分中的多个 1×1 卷积层结构减小了前一层的尺寸, 在加速计算的同时减少了信息丢失。直接处理的原始图像缩短了训练时间, 卷积层和滤波器的优化显著降低了计算复杂度。

关键词 图像处理; 超分辨率技术; 密集连接; 激励模块; 1×1 卷积层; 计算复杂度

中图分类号 TP391

文献标识码 A

doi: 10.3788/LOP56.201005

Image Super-Resolution Network Based on Dense Connection and Squeeze Module

Hu Shiyu, Wang Guodong*, Zhao Yi, Wang Yanjie, Pan Zhenkuan

College of Computer Science and Technology, Qingdao University, Qingdao, Shandong 266071, China

Abstract Aiming at the loss of information and edge blurring during texture recovery using super-resolution technology based on convolution neural networks, we combine dense block and squeeze module to learn the mapping from low-resolution to high-resolution in an end-to-end manner. The dense block structure formed by the fusion of dense connection utilizes context information of image region effectively. The squeeze module amplifies valuable global information selectively and suppresses the useless features. The multiple 1×1 convolution layer structures in the image reconstruction section reduce the dimension of the previous layers, and speed up the calculation while reducing the loss of information. Processing the original image directly shortens the training time, and the optimization of convolution layers and filters reduces the computational complexity significantly.

Key words image processing; super-resolution technology; dense connection; squeeze module; 1×1 convolution layer; computational complexity

OCIS codes 100.2000; 100.2980; 200.4260; 100.1830

1 引言

单图像超分辨率(SISR)^[1]旨在通过对低分辨率(LR)图像训练生成视觉上更加清晰、边缘更加锐化的高分辨率(HR)图像。SISR在处理计算机视觉任务方面拥有较强的性能,例如医学图像、图像增强和安全与监视成像^[2]。

LR到HR映射的多样性使图像恢复更加艰难。特别当比例因子变大时,产生的冗余信息会导致局部

特征提取困难,高频细节丢失。为解决这个问题,人们提出大量的图像算法,主要包括基于插值的算法^[3]、基于重建的算法^[4]、基于学习的算法。此前的研究表明,不同深度的网络学习冗余特征的能力不同。基于密集连接与激励模块的图像超分辨率网络(DSSR)主要利用密集连接块和激励模块从顶层到底层创建短路径,屏蔽无用路径,使底层的低频特征可以作为潜在的附加信息来重建顶层的HR图像。短路径传递的特征信息易于训练,从底层重用特征有利

收稿日期: 2019-04-12; 修回日期: 2019-05-16; 录用日期: 2019-05-21

基金项目: 山东省自然科学基金(ZR2019MF050)、“十二五”国家科技支撑计划(2014BAG03B05)

* E-mail: doctorwgd@gmail.com

于减少特征冗余,从而减少网络深度带来的副作用,得到更加精确的卷积神经网络(CNN)模型^[5]。

本文使用密集连接^[6]融合后的密集块、激励模块^[7]及 1×1 卷积层^[8],缩短训练时间的同时使图像恢复效果得到提升。主要贡献有4个方面:

- 1) 使用密集块充分利用原始图像中的分层特征,对通过网络的不同域信息流保留尽可能多的特征。
- 2) 使用激励监督模块,将有价值的特征信息放大利用,规避无用的特征信息,提高特征利用率。
- 3) 使用多个 1×1 卷积降低维度,减少特征丢失,添加非线性机制,增强网络表达能力。
- 4) 本文网络可自适应训练不同尺度(尺度因子为2,3,4)的图像,且都获得了较好的性能。

2 相关工作

众多SISR方法^[9-16]中,插值方法因易于实施得到广泛应用。但这种线性模型对全局特征输出的不确定性,会造成图像边缘模糊等情况。稀疏性技术常用于具有丰富图像先验^[17]的线性模型。均假设任何的自然图像块都可由原子字典稀疏表示。字典可由补丁数据库^[18]形成,也可从数据库中学习获得。这种基于字典的学习方法的缺点是获得稀疏编码相关系数的过程耗时耗力。此外,还有一些其他较为复杂的算法用于模拟LR图像到HR图像的空间映射,包括随机森林^[19]和CNN等。

其中基于CNN的算法^[20-23]更为普及。最早由Dong等^[12]提出超分辨率卷积神经网络(SRCNN),将三层卷积神经网络引入超分辨图像中学习LR到

HR的端到端映射,取得了比较理想的效果,但在图像训练过程中易出现梯度消失及过拟合^[24]现象。快速超分辨率卷积神经网络(FSRCNN)^[14]通过对卷积层的微调,将SRCNN中的滤波器大小统一调整为 3×3 ,大大缩短了训练与测试的时间。随后使用非常深的卷积网络实现精确的图像超分辨率(VDSR)^[15],通过使用残差学习将网络深度增加到20层,从而提高图像恢复质量。VDSR提出残差学习的概念,使网络更易优化并且在深度增加的同时提高了准确性,平均精度相比SRCNN高0.95 dB,为图像超分辨开辟了新思路。随后Tong等^[16]正式提出密集网络(DenseNet)的概念,它允许任意两层之间直连后再输出至下一层,充分利用局部特征及浅层特征,减少数据丢失,成为近来最受欢迎的网络之一。在此之后的一系列算法,如基于CNN的单幅图像超分辨^[25]和基于CNN的深度图超分辨率重建^[26],基本都使用相同的网络深度,只是在特征提取和特征合并时做出改变。提取特征的数量与丢失特征的数量在一定程度上成正比。这些算法都通过网络加深的方式在特征提取阶段尽可能多地提取特征,但同时也加深了信息丢失的潜在性。

上述基于深度学习的图像超分辨(SR)方法都对传统方法做了某些改进,但在训练初始阶段均丢失了部分有用的分层特征。本文使用密集连接融合后的密集块,然后对图像进行 1×1 卷积进行重建,使网络有效地提取和自适应LR空间中的所有层特征。如图1所示,本文算法在训练阶段保存了更多的有效特征,恢复出比其他方法更加清晰的建筑物边缘。




图1 DSSR(上方)与LapSRN(下方)算法处理不同图像的效果图。(a)采用不同的比例因子处理图像的效果;(b)处理建筑物边缘的效果

Fig. 1 DSSR (top) and LapSRN (bottom) algorithms deal with different images. (a) Images processed with different scale factors; (b) building edges result

3 基本原理

3.1 网络结构

如图2所示,本文模型主要分为2个部分,特征

提取网络和重建网络。每个卷积层都含有权重、偏置、非线性层的级联。使用中间添加了非线性激励模块的2个密集连接块,充分获取上下文信息。在密集连接结合所有特征后,引入 1×1 卷积层,降低

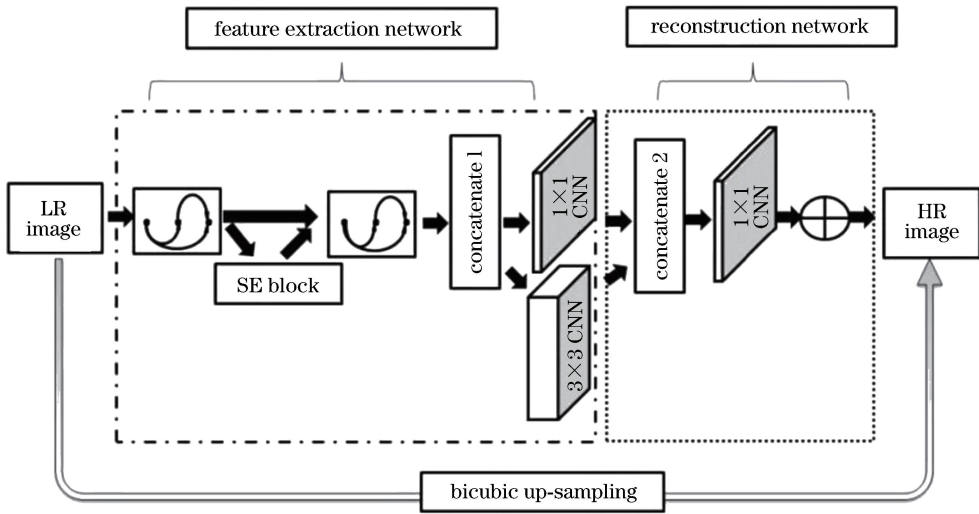


图 2 DSSR 结构图

Fig. 2 Structure of DSSR

参数量,缩短训练时间。提出的模型主要学习 LR 图像与原始 HR 图像的残差,网络以像素级方式进行。上采样后的每个像素对于深层 CNN 都具有较大计算量,所以本文使用原始图像。

3.2 密集块与激励监督模块

在提取浅层特征时将网络中所有卷积层两两连接,密集块使浅层特征得到有效利用,避免参数增加,防止信息丢失,提高了精度。密集块(DB)共包含卷积层、激活层、融合层 3 部分,如图 3 所示。在密集块的卷积层之间使用密集连接确保特征的充分提取。密集连接主要拥有 2 个特性:




图 3 密集块结构图

Fig. 3 Structure of dense block

1) 一定程度上减轻甚至解决梯度消失问题,由图 3 可知,在传递信息时每一层都会接受其后所有层的梯度信号,所以随着网络深度的增加,靠近输入层的梯度会变得越来越大。

2) 从 96 到 32 个卷积核的递减性趋势使得少量的卷积核也能得到大量的特征,最终获得轻量级模型。

随着网络深度的增加,网络可能出现梯度爆炸的现象,训练时易出现难以拟合甚至过拟合的情况。残差学习^[27]可以自适应学习特征之间的差异,使特

征可以得到尽可能多的利用,减小了模型训练饱和和精度下降的副作用。表 1 中详细展示了本文为获得最佳性能而对参数所做的修改。最终选取了两个密集块作为特征提取网络的主要组成部分。

表 1 部分参数(密集块个数,滤波器个数)在比例因子为 3 时的微调结果(粗体表示最佳性能)

Table 1 Some parameters fine-tuned (number of dense blocks, number of filters) when the scale factor is 3. Bold fonts indicate the best performance

Dataset	2 DBs (filters: 128)		
	3 DBs	2 DBs	2DBs
Set5	33.65	33.76	33.87
Set14	29.70	29.82	29.87
B100	28.80	28.85	28.90
Urban100	27.17	27.21	27.31

图 4 为激励块的具体结构,由全局平均池化层(GAP)^[24]、全连接层(FC)^[25]、修正线性单元(ReLU)激活层^[28]与 sigmoid 激活层^[29]组成。使用 GAP 屏蔽掉空间的分布信息,将空间所有信息点平均成近似值,使通道计算更加准确。全连接层充分利用通道间的相关性,可基于全部数据集训练,具有较强的全局性。第一个全连接层将通道压缩以降低计算量,第二个全连接层将激活特征恢复至原通道。

在轻量级模型中,使用密集块与激励块的有机结合,充分获取浅层特征与高频信息并融合,短路径压缩训练时间的同时提高了特征的重用率,从而得到边缘清晰、重点可见的 HR 图像。如图 1 所示,DSSR 与 LapSRN 使用相同图片在不同尺度下进行测试,DSSR 恢复的图像层次分明,棱角清晰。




图 4 激励块结构图

Fig. 4 Structure of squeeze module

3.3 多个 1×1 卷积层

双三次插值^[30]法无法解决 SR 问题,还会增大计算复杂度,所以本文直接处理原始图像。与将图像进行插值处理再放大到 HR 空间的方法不同,基于去卷积的快速图像超分辨率方法^[31]等都使用转置卷积层来学习升级滤波器,这也是恢复图像细节的重要思想之一,转置卷积层被称为卷积层的逆操作,可以学习多样化的内核。为获得更好的性能效果,需将反卷积层深度堆叠,由此提出并行 CNN 结构,由多个 1×1 卷积层组成。 1×1 卷积层不仅减少了前一层的尺寸,信息损失更少、计算速度更快,并且增加了更多的非线性单元。本研究共使用两次 1×1 卷积,分别有 64 个滤波器,32 个滤波器,这种 1×1 卷积层只需要一个参数,主要是对输入的特征进行一个比例缩放,缩小数据量。在网络第一次融合

信息使用带参式修正线性单元(PReLU)^[29]激活特征后首次使用 1×1 卷积,输入映射后输出。第二次 1×1 卷积在重建网络训练结束前使用,目的是更好地学习深层网络的表达,增强网络的表达能力。使用 1×1 卷积可以在加深网络结构的同时获得轻量级模型,相比其他算法减少了训练时间。

4 分析与讨论

4.1 实验数据

实验数据选自 Berkeley 分割数据集里的由 200 个自然图像组成的 B200 数据集^[30]和孙超等^[31]提出的 91 张图片,对实验数据进行四倍图像数据增广,由原图、水平翻转图像、旋转 180° 图像、垂直翻转图像组成,如图 5 所示。使用 4 个标准基准数据集 Set5^[32]、Set14^[33]、B100^[34]、Urban100^[35]进行测试。数据集 Set5 和 Set14 通常用于 SR 的基准测试。使用包含 100 个具有挑战性图像的 Urban100 数据集评估所提方法的性能,提高实验数据权威性。在不同的比例因子下对这些数据集进行所有实验,将峰值信噪比(PSNR)^[36]和时间作为评估指标。如图 6 所示,YCbCr 颜色空间中不同的 3 个通道,分别表示图像的亮度、图像的蓝色浓度偏移量、图像的红色偏移量。由图 6 可知只有 Y 通道在 SR 空间执行,因此只在 Y 通道上计算 PSNR 和时间。



图 5 图像数据增广示例。(a)原图;(b)水平翻转图;(c)旋转 180° 图;(d)垂直翻转图

Fig. 5 Example of image data augmentation. (a) Original image; (b) horizontal flip image; (c) rotate 180° image; (d) vertical flip image




图 6 图像分解图。(a) Y 通道分解图像;(b) Cb 通道分解图像;(c) Cr 通道分解图像

Fig. 6 Image decomposition map. (a) Decomposed image of Y channel; (b) decomposed image of Cb channel; (c) decomposed image of Cr channel

4.2 实现细节

输入设为 x_{i-1} , 则第 i 层的输入可表示为

$$x_i = \max(0, w_i * x_{i-1} + b_i), \quad (1)$$

式中, w_i 和 b_i 分别表示卷积层或反卷积层的权重和偏置。大部分算法使用 ReLU 作为激活单元, 但 ReLU 会丢掉所有权重小于零的特征, 对特征恢复、图像重建增加了一定的难度。PReLU 作为非饱和激活函数其负值部分的斜率并非预先定义, 而是依据权重决定。在训练时只增加极少量的参数, 意味着网络的计算量及过拟合的危险性都只增加一点。所以本文选用 PReLU 作为激活函数, 在权值小于零时保存潜在特征。每个卷积层或者反卷积层之后的激活层用于除重建部分以外的非线性映射。第 i 层的激活公式可表示为

$$f(x_i) = \max(0, x_i) + a_i \min(0, x_i), a_i \in (0, 1), \quad (2)$$

式中, a_i 是不确定的常数, 它保证当输入为负数时某些浅层特征不丢失。使用原始的初始化方法将偏置和 PReLU 的系数归零。将初始学习率设为 0.001, 在 5 个

循环训练内, 如果 loss 值一直不变则学习率减小一半直至减少到 2×10^{-5} 为止。图 7 清晰地展示不同物体不同场景下的某个训练输出。在网络中将所有卷积层的过滤器尺寸设定为 3×3 , 并固定输出, 每个卷积层固定输出 64 个特征信息, 如图 8 所示。使用稳健性更好的 Adam 方法优化网络。训练期间设置最小批量的图像大小为 32×32 。训练时, 最小化误差使模型更好地拟合训练数据, 将参数规则化以防止过拟合。每 5 个训练循环后保存一次模型, 方便训练结束后的评估及参数的调整。其他设置与基准模型基本相似。现存较为普遍的两种损失函数 L1 和 L2, L1 范数是向量中各个元素的绝对值之和, L2 正则化则是各像素的平方差组合, 显然 L1 的稳健性更强。在处理图像时, L2 将图像处理得更加平滑, 但不利于边缘的恢复, 所以模型训练时使用 L1, 最终结果显示使用 L1 比使用 L2 时 PSNR 平均高 0.2 dB。表 2 为不同算法的实现细节汇总及对比, DSSR 规避了其余算法的缺陷, 将激活函数、损失函数等基准技术先优化后结合。最终算法在 GTX 1080Ti 设备上训练 3.9 h, 共迭代 62079 次。

表 2 各超分辨算法的技术实现及参数细节

Table 2 Technical implementation and parameter details of each super-resolution algorithm

Parameter	SRCNN	VDSR	DRCN	LapSRN	DCSCN	DSSR
Number of CNN layers	3	20	20	24	11	10
Network input	LR with bicubic	LR with bicubic	LR with bicubic	LR	LR	LR
Residual learning	No	Yes	No	Yes	Yes	Yes
Loss function	L2	L2	L2	Charbonnier	L2	L1
Activation function	ReLU	ReLU	ReLU	ReLU	ReLU	PReLU
Parameter number /k	57	665	1775	812	87	72



图 7 不同图像的非线性输出。(a)自然物体的非线性输出;(b)文本的非线性输出;
(c)建筑物的非线性输出;(d)人物的非线性输出

Fig. 7 Nonlinear output of different images. (a) Nonlinear output of nature image; (b) nonlinear output of text image;
(c) nonlinear output of building image; (d) nonlinear output of person

4.3 实验结果与分析

表 3 提供了不同方法下 4 个常见基准数据集的最终评估结果, 表中算法包括双三次插值法、调整锚定邻域回归以获得快速超分辨率的方法 (A+) [37]、

基于维纳滤波器的相似域单图像超分辨率方法 (WSD-SR) [38]、SRCNN [12]、深度递归卷积网络的图像超分辨率方法 (DRCN) [39]、VDSR [15]、LapSRN [40]、具有跳跃连接和网中网卷积结构的快




图 8 特征提取阶段和图像重建阶段的非线性输出。
(a)第1层卷积层的非线性映射部分特征图;(b)第1个融合层的非线性映射部分特征图

Fig. 8 Nonlinear feature maps of feature extraction and image reconstruction. (a) Nonlinear mapping part feature map of the first convolution layer; (b) nonlinear mapping part feature map of the first concatenate layer

速准确的图像超分辨率(DCSCN)^[19]以及本文所提方法DSSR。与其他7种方法相比,DSSR在性

能和时间上都有大幅改善。为增加说服力,图9~11分别给出不同数据集针对不同比例因子的局部放大展示图。图9是一幅选自数据集B100的图像,比例因子为2,图9(j)修复的自然物边缘和纹理比其他自然物更清晰,可以清晰地看出自然物有更多的角落和结构,图9(b)恢复的图像轮廓模糊,其他方法均具有不同程度的细节损失。当比例因子增加到3时,如图10所示,其他算法在重建蝴蝶颜色以及翅膀轮廓时,纹理严重损失,而DSSR可以更加清楚地展示不同部位之间的层次。图10表明即使比例因子增加,DSSR的物体重建算法同样具有显著的优势。图11表明当比例因子为4时,DSSR同样可以更好地恢复图中青椒的纹理轮廓。综上,DSSR模型成功重建了HR图像中的纹理边缘并具有更好的输出特性。




图 9 数据集 B100 的 img_020 放大 2 倍后的各方法效果图。(a)原图;(b) Bicubic^[28]的结果;(c) A+^[37]的结果;(d) SRCNN^[12]的结果;(e) WSD-SR^[38]的结果;(f) VDSR^[15]的结果;(g) DRCN^[39]的结果;(h) LapSRN^[40]的结果;(i) DCSCN^[19]的结果;(j) DSSR

Fig. 9 Super-resolution results of “img_020” (bsd100) with scale factor $\times 2$. (a) Original image; (b) result from Bicubic^[28]; (c) result from A+^[37]; (d) result from SRCNN^[12]; (e) result from WSD-SR^[38]; (f) result from VDSR^[15]; (g) result from DRCN^[39]; (h) result from LapSRN^[40]; (i) result from DCSCN^[19]; (j) DSSR




图 10 数据集 Set5 的 img_003 放大 3 倍后的各方法效果图。(a)原图;(b) Bicubic 的结果;(c) A+ 的结果;(d) SRCNN 的结果;(e) WSD-SR 的结果;(f) VDSR 的结果;(g) DRCN 的结果;(h) LapSRN 的结果;(i) DCSCN 的结果;(j) DSSR

Fig. 10 Super-resolution results of “img_003” (Set5) with scale factor $\times 3$. (a) Original image; (b) result from Bicubic; (c) result from A+; (d) result from SRCNN; (e) result from WSD-SR; (f) result from VDSR; (g) result from DRCN; (h) result from LapSRN; (i) result from DCSCN; (j) DSSR



图 11 数据集 Set14 的 img_012 放大 4 倍后的各方法效果图。(a)原图;(b) Bicubic 的结果;(c) A+ 的结果;(d) SRCNN 的结果;(e) WSD-SR 的结果;(f) VDSR 的结果;(g) DRCN 的结果;(h) LapSRN 的结果;(i) DCSCN 的结果;(j) DSSR

Fig. 11 Super-resolution results of “img_012” (Set14) with scale factor $\times 4$. (a) Original image; (b) result from Bicubic; (c) result from A+; (d) result from SRCNN; (e) result from WSD-SR; (f) result from VDSR; (g) result from DRCN; (h) result from LapSRN; (i) result from DCSCN; (j) DSSR

表 3 4 个基准数据集 Set5, Set14, B100 和 Urban100 上不同比例因子的平均 PSNR 和时间(粗体表示最佳性能)

Table 3 Average PSNR and time of different scale factors on the four benchmark datasets Set5, Set14, B100 and Urban100 (Bold fonts indicate the best performance)

Algorithm	Scale	Set5	Set14	B100	Urban100
		PSNR /time	PSNR /time	PSNR /time	PSNR /time
Bicubic	2	33.66/0.00 s	30.24/0.00 s	29.56/0.00 s	26.88/0.00 s
A+	2	36.54/0.58 s	32.26/0.86 s	31.21/0.59 s	29.20/2.96 s
WSD-SR	2	37.21/0.34 s	32.83/0.75 s	31.41/0.45 s	30.29/2.96 s
SRCNN	2	36.66/2.19 s	32.42/4.32 s	31.36/2.51 s	29.50/22.12 s
VDSR	2	37.53/0.13 s	33.03/0.25 s	31.90/0.16 s	30.76/0.98 s
DRCN	2	37.63/—	33.06/—	31.85/—	30.76/—
LapSRN	2	37.52/0.058 s	33.08/0.174 s	31.08/0.09 s	30.41/0.752 s
DCSCN	2	37.64/0.12 s	33.05/0.21 s	31.91/0.18 s	30.75/1.51 s
DSSR	2	37.73 /0.010 s	33.15 /0.154	32.02 /0.088 s	30.96 /0.780 s
Bicubic	3	30.39/0.00 s	27.55/0.00 s	27.21/0.00 s	24.46/0.00 s
A+	3	32.58/0.32 s	29.13/0.56 s	28.29/0.33 s	26.03/1.67 s
WSD-SR	3	33.50/0.27 s	29.72/0.34 s	28.53/0.79 s	26.95/1.41 s
SRCNN	3	32.75/2.23 s	29.28/4.40 s	28.41/2.58 s	26.24/19.35 s
VDSR	3	33.66/0.13 s	29.77/0.26 s	28.82/0.21 s	27.14/1.08 s
DRCN	3	33.85/—	29.89/—	28.81/—	27.16/—
LapSRN	3	33.82/0.097 s	29.87/0.13 s	28.82/0.105 s	27.07/0.57 s
DCSCN	3	33.75/0.51 s	29.80/0.21 s	28.80/0.14 s	27.14/1.35 s
DSSR	3	33.89 /0.147 s	29.90 /0.139 s	28.90 /0.065 s	27.17 /0.878 s
Bicubic	4	28.42/0.00 s	26.00/0.00 s	25.96/0.00 s	23.14/0.00 s
A+	4	30.28/0.24 s	27.32/0.38 s	26.82/0.26 s	24.32/1.21 s
WSD-SR	4	31.39/0.44 s	27.98/0.48 s	27.08/0.43 s	25.16/1.36 s
SRCNN	4	30.48/2.19 s	27.49/4.39 s	26.90/2.51 s	24.52/18.46 s
VDSR	4	31.35/0.12 s	28.01/0.25 s	27.29/0.21 s	25.18/1.06 s
DRCN	4	31.56/—	28.15/—	27.24/—	25.18/—
LapSRN	4	31.54/0.11 s	28.19/0.20 s	27.32/0.15 s	25.21/0.56 s
DCSCN	4	31.40/0.22 s	28.02/0.44 s	27.31/0.36 s	25.20/1.47 s
DSSR	4	31.67 /0.145 s	28.21 /0.12 s	27.37 /0.059 s	25.24 /0.952 s

5 结 论

本文旨在通过密集块与激励块的有机结合使网络获得更精确的 HR 图像。在卷积神经网络中,局

部特征和整体特征通过密集连接和激励监督结合后输出至重建网络。为降低输入特征维度,两次使用 1×1 卷积层,获得更加准确的 HR 图像且未增加计算负担。在重建网络部分,降维后的全局特征与残

差学习后的特征结合得到最后输出的 HR 图像。除此以外,本文模型处理了不同尺度的图像,都取得了较好的结果。综上所述,DSSR 在结合这些方法后取得了更高的 PSNR 值。随着深度学习的深入,SISR 任务现在更倾向于构建计算量小的模型。最后值得一提的是,这项研究是一个总体学习模型。深度学习本身就具有很强的解决某些复杂问题的能力,但大部分方法都为获得较好的结果而付出巨大的计算代价,因此需从整体考虑。日后以深度学习为基础的超分辨工作可以以本方法为基础,获得速度更快、精度更高的 HR 图像。这种方法同样适用于其他以深度学习为基础的工作。

参 考 文 献

- [1] Irani M, Peleg S. Improving resolution by image registration [J]. *CVGIP: Graphical Models and Image Processing*, 1991, 53(3): 231-239.
- [2] Zou W W W, Yuen P C. Very low resolution face recognition problem[J]. *IEEE Transactions on Image Processing*, 2012, 21(1): 327-340.
- [3] Li K P, Wu Z Y, Peng K C, *et al.* Tell me where to look: guided attention inference network[C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE, 2018: 9215-9223.
- [4] Zhang K B, Gao X B, Tao D C, *et al.* Single image super-resolution with non-local means and steering kernel regression [J]. *IEEE Transactions on Image Processing*, 2012, 21(11): 4544-4556.
- [5] Wagner R, Thom M, Schweiger R, *et al.* Learning convolutional neural networks from few samples[C] // The 2013 International Joint Conference on Neural Networks (IJCNN), August 4-9, 2013, Dallas, TX, USA. New York: IEEE, 2013: 14027213.
- [6] Huang G, Liu Z, van der Maaten L, *et al.* Densely connected convolutional networks [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI. New York: IEEE, 2017: 4700-4708.
- [7] Hu J, Shen L, Sun G. Squeeze-and-excitation networks [C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE, 2018: 7132-7141.
- [8] Lin M, Chen Q, Yan S. Network in network [J/OL]. (2014-03-04) [2019-03-29]. <https://arxiv.org/abs/1312.4400>.
- [9] Kim K I, Kwon Y. Single-image super-resolution using sparse regression and natural image prior [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2010, 32(6): 1127-1133.
- [10] Yang J C, Wang Z W, Lin Z, *et al.* Coupled dictionary training for image super-resolution [J]. *IEEE Transactions on Image Processing*, 2012, 21(8): 3467-3478.
- [11] Salvador J, Pérez-Pellitero E. Naive Bayes super-resolution forest [C] // 2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015, Santiago, Chile. New York: IEEE, 2015: 325-333.
- [12] Dong C, Loy C C, He K M, *et al.* Learning a deep convolutional network for image super-resolution[M] // Fleet D, Pajdla T, Schiele B, *et al.* Computer vision - ECCV 2014. Lecture notes in computer science. Cham: Springer, 2014, 8692: 184-199.
- [13] Larsson G, Maire M, Shakhnarovich G. Fractalnet: ultra-deep neural networks without residuals [J/OL]. (2017-05-26) [2019-04-01]. <https://arxiv.org/abs/1605.07648>.
- [14] Dong C, Loy C C, Tang X O. Accelerating the super-resolution convolutional neural network[M] // Leibe B, Matas J, Sebe N, *et al.* Computer vision - ECCV 2016. Lecture notes in computer science. Cham: Springer, 2016, 9906: 391-407.
- [15] Kim J, Lee J K, Lee K M. Accurate image super-resolution using very deep convolutional networks[C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 1646-1654.
- [16] Tong T, Li G, Liu X J, *et al.* Image super-resolution using dense skip connections [C] // 2017 IEEE International Conference on Computer Vision (ICCV), October 22-29, 2017, Venice, Italy. New York: IEEE, 2017: 4799-4807.
- [17] Badran Y K, Salama G I, Mahmoud T A, *et al.* Single image super resolution based on learning features to constrain back projection [C] // 2019 International Conference on Innovative Trends in Computer Engineering (ITCE), February 19-21, 2019, Aswan, Egypt. New York: IEEE, 2019: 18473424.

- [18] Nam Y, Mun J, Jang Y, *et al.* Single image super-resolution with self-similarity [C] // 2019 IEEE International Conference on Consumer Electronics (ICCE), January 11-13, 2019, Las Vegas, NV, USA. New York: IEEE, 2019: 18504375.
- [19] Yamanaka J, Kuwashima S, Kurita T. Fast and accurate image super resolution by deep CNN with skip connection and network in network[M] // Liu D, Xie S, Li Y, *et al.* Neural information processing. Lecture notes in computer science. Cham: Springer, 2017, 10635: 217-225.
- [20] Shi Z T, Wang Z R, Wang R, *et al.* Single image super-resolution based on convolutional neural network [J]. Laser & Optoelectronics Progress, 2018, 55(12): 121001.
史紫腾, 王知人, 王瑞, 等. 基于卷积神经网络的单幅图像超分辨[J]. 激光与光电子学进展, 2018, 55(12): 121001.
- [21] Li S M, Lei G Q, Fan R. Depth map super-resolution reconstruction based on convolutional neural networks [J]. Acta Optica Sinica, 2017, 37(12): 1210002.
李素梅, 雷国庆, 范如. 基于卷积神经网络的深度图超分辨率重建 [J]. 光学学报, 2017, 37(12): 1210002.
- [22] He K M, Zhang X Y, Ren S Q, *et al.* Deep residual learning for image recognition [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 770-778.
- [23] Yang X, Mei H Y, Zhang J Q, *et al.* DRFN: deep recurrent fusion network for single-image super-resolution with large factors [J]. IEEE Transactions on Multimedia, 2019, 21(2): 328-337.
- [24] Hsiao T Y, Chang Y C, Chiu C T. Filter-based deep-compression with global average pooling for convolutional networks [C] // 2018 IEEE International Workshop on Signal Processing Systems (SiPS), October 21-24, 2018, Cape Town, South Africa. New York: IEEE, 2018: 18358100.
- [25] Ayhan T, Altun M. Approximate fully connected neural network generation [C] // 2018 15th International Conference on Synthesis, Modeling, Analysis and Simulation Methods and Applications to Circuit Design (SMACD), July 2-5, 2018, Prague, Czech Republic. New York: IEEE, 2018: 18009058.
- [26] Li Y H, Song B, Guo J, *et al.* Super-resolution of brain MRI images using overcomplete dictionaries and nonlocal similarity [J]. IEEE Access, 2019, 7: 25897-25907.
- [27] Xu L, Choy C S, Li Y W. Deep sparse rectifier neural networks for speech denoising [C] // 2016 IEEE International Workshop on Acoustic Signal Enhancement (IWAENC), September 13-16, 2016, Xi'an, China. New York: IEEE, 2016: 16049811.
- [28] Imtiaz M S, Wahid K A. Image enhancement and space-variant color reproduction method for endoscopic images using adaptive sigmoid function [C] // 2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, August 26-30, 2014, Chicago, IL, USA. New York: IEEE, 2014: 3905-3908.
- [29] Cosmo D L, Salles E O T. Multiple sequential regularized extreme learning machines for single image super resolution [J]. IEEE Signal Processing Letters, 2019, 26(3): 440-444.
- [30] Sekar K, Duraisamy V, Remimol A M. An approach of image scaling using DWT and bicubic interpolation [C] // 2014 International Conference on Green Computing Communication and Electrical Engineering (ICGCCEE), March 6-8, 2014, Coimbatore, India. New York: IEEE, 2014: 14665866.
- [31] Sun C, Lü J W, Li J W, *et al.* Method of rapid image super-resolution based on deconvolution [J]. Acta Optica Sinica, 2017, 37(12): 1210004.
孙超, 吕俊伟, 李健伟, 等. 基于去卷积的快速图像超分辨率方法 [J]. 光学学报, 2017, 37(12): 1210004.
- [32] Bevilacqua M, Roumy A, Guillemot C, *et al.* Low-complexity single-image super-resolution based on nonnegative neighbor embedding [C] // Proceedings of the British Machine Vision Conference 2012, September 3-7, 2012, Surrey, UK. Durham, England: BMVA Press, 2012: 135.
- [33] Zeyde R, Elad M, Protter M. On single image scale-up using sparse-representations [M] // Boissonnat J D, Chenin P, Cohen A, *et al.* Curves and surfaces. Lecture notes in computer science. Berlin, Heidelberg: Springer, 2012, 6920: 711-730.
- [34] Martin D, Fowlkes C, Tal D, *et al.* A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics [C] // Proceedings Eighth IEEE International Conference on Computer Vision. ICCV 2001, July 7-14, 2001, Vancouver, BC, Canada.

- New York: IEEE, 2001: 7024307.
- [35] Huang J B, Singh A, Ahuja N. Single image super-resolution from transformed self-exemplars [C] // 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE, 2015: 5197-5206.
- [36] Zhang H, Patel V M. Density-aware single image de-raining using a multi-stream dense network [C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE, 2018: 695-704.
- [37] Kim J, Lee J K, Lee K M. Deeply-recursive convolutional network for image super-resolution[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 1637-1645.
- [38] Lai W S, Huang J B, Ahuja N, *et al.* Deep Laplacian Pyramid networks for fast and accurate super-resolution [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI. New York: IEEE, 2017: 624-632.
- [39] Timofte R, de Smet V, van Gool L. A+: adjusted anchored neighborhood regression for fast super-resolution[M]//Cremers D, Reid I, Saito H, *et al.* Computer vision-ACCV 2014. Lecture notes in computer science. Cham: Springer, 2015, 9006: 111-126.
- [40] Cruz C, Mehta R, Katkovnik V, *et al.* Single image super-resolution based on Wiener filter in similarity domain[J]. IEEE Transactions on Image Processing, 2018, 27(3): 1376-1389.