

文章编号: 2095-2163(2020)11-0001-08

中图分类号: TP391

文献标志码: A

基于轻量化网络的图像超分辨率研究综述

王宇, 宁媛

(贵州大学 电气工程学院, 贵阳 550025)

摘要: 近几年通过深度学习来进行图像超分辨率的研究越来越多,但更多的研究在于通过改变网络结构的深度和宽度来提升图像超分的质量,很少有研究采用轻巧而有效的网络来提高超分的效率而不影响其性能。因此,本文主要阐述几种轻量化网络,对其原理进行阐述,并对未来图像超分的发展趋势进行了展望。

关键词: 超分辨率; 轻量化网络; 深度学习

An overview of image super-resolution research based on lightweight networks

WANG Yu, NING Yuan

(School of Electrical Engineering, Guizhou University, Guiyang 550025, China)

[Abstract] In recent years, more and more research has been conducted on image super-resolution through deep learning, but more research lies in improving the quality of image super-score by changing the depth and width of the network structure, and few studies have adopted lightweight and effective networks to improve the efficiency of super-score without affecting its performance. Therefore, this paper mainly describes several lightweight networks, analyzes their principles and advantages and disadvantages, and analyzes the current status of image super resolution and looks forward to the future development trend of image super resolution.

[Key words] Super-resolution; Lightweight networks; Deep learning

0 引言

近年来,为了提升图像的质量,人们从设备着手,通过对硬件进行升级改造可以提升成像系统性能,提高图像分辨率。然而,考虑到各方面的因素,诸如硬件的制作成本、制作工艺等一些限制,学者通过研究对原始图像进行图像处理操作来获得更高分辨率的图像,因此产生了图像超分辨率技术^[1-2]。

基于深度学习的图像 SR 积累了大量的关注度,它已经延伸到各种现实世界的应用中。如医学成像、视频监控、遥感、图像分类、检测、识别和去噪。然而,现有的用于图像 SR 的卷积神经网络一般有两个局限性:一是网络深度很深,不仅削弱了自下而上的信息流,而且模型容量大,计算负担大;其二网络架构往往是前馈式的,使得前几层无法捕捉到后几层的有用信息,限制了特征学习能力。

因此,根据网络模型中存在的大量冗余参数,研究者提出了网络模型压缩方法,并将模型压缩方法分为浅层压缩和深层压缩两大类。具体分类如图 1 所示。本文主要从轻量化网络模型出发,介绍提出的几种轻量化网络模型。




图 1 模型压缩分类

Fig. 1 Model compression classification

1 轻量化网络

神经网络轻量化的原则是获得更高效的网络,优化网络结构和卷积计算,减少网络参数的同时不损失性能,加强对网络内部的理解。下面将主要介绍近年来的几种轻量化压缩网络。

1.1 LGCN

文献[3]中提出了一种针对 SISR 的快速轻量级组卷积网络(LGCN)模型,该模型结构如图 2 所示。其主要由三部分组成:特征提取网(F-Net)、级联记忆群卷积网(C-Net)和重建网(R-Net)。创新之处主要集中在 C-Net 上,即级联多个记忆群卷积

作者简介: 王宇(1996-),男,硕士研究生,主要研究方向:图像处理;宁媛(1968-),女,硕士,教授,硕士生导师,主要研究方向:计算机视觉。

通讯作者: 宁媛 Email: ee.yning@gzu.edu.cn

收稿日期: 2020-09-12

网(MGCN),结构如图3所示。具体来说,MGCN包含一个记忆单元和一个通道注意单元。记忆单元由多个交替的组卷积层和 1×1 卷积层组成,采用密集连接的结构建立记忆机制。与DenseNet^[4]不同,利用 1×1 卷积层作为中间层,逐步收集局部信息。因

此,MGCN中的 1×1 卷积层不仅可以对组卷积层的输出进行线性组合,而且可以逐步收集局部信息。信道关注单元的灵感来自于挤压和激励网^[5]的思想,本文将挤压和激励网^[5]中的完全连接层替换为 1×1 卷积层,以更好地模拟通道方面的关系。




图2 LGCN整体框架结构

Fig. 2 LGCN overall framework structure




图3 MGCN内部结构

Fig. 3 Internal structure of MGCN

通过实验比较了LGCN与几种轻量级SISR方法。其中包括Bicubic、SRCNN^[6]、VDSR^[7]、LapSRN^[8]、MS-LapSRN^[9]、DRRN^[10]和IDN^[11]。实验在4个基准数据集上评估了超分辨率图像的平均峰值信噪比(PSNR)和结构相似度(SSIM)值,其结果见表1。在大多数缩放因子下,提出的LGCN方法在大多数数据集上实现了最佳性能。模型在Set5上与IDN相比,在 $2\times$ 和 $4\times$ 尺度上的PSNR表现稍差。需要注意的是,Set5数据集是最小的数据集,只包含5张图片。以 $4\times$ 尺度为例,模型在Set14数据集上比IDN高0.05 dB,在具有挑战性的Urban 100数据集上比IDN提高0.08 dB。此外,在所有数据集上,LGCN在所有缩放因子下都能获得最高的SSIM值,并且能够生成与原始高分辨率图像具有高度结构相似性的图像。

此外,还选择了两种非轻量级SISR方法,即SRResNet^[12]和EDSR^[13]进行比较,结果见表2。由表2可见,两种方法都优于LGCN。这是一个合理的结果,因为其有更深、更广的网络结构,包含大量的卷积层和参数。实际上,SRResNet和EDSR的参数分别为1 543K和43 000 K,而LGCN的参数只有660 K。

表1 对比最新的SISR算法的量化结果

Tab. 1 Comparison of quantification results of the latest SISR algorithm

Algorithm	Scale	Set5	Set14	BSD 100	urban 100
		PSNR/SSIM	PSNR/SSIM	PSNR/SSIM	PSNR/SSIM
Bicubic	2	33.66/0.930	30.24/0.869	29.56/0.843	26.88/0.841
SRCNN	2	36.66/0.954	32.45/0.906	31.36/0.888	29.50/0.895
VDSR	2	37.53/0.958	33.05/0.913	31.90/0.896	30.77/0.914
LapSRN	2	37.52/0.959	33.08/0.913	31.80/0.895	30.41/0.910
DRRN	2	37.74/0.959	33.23/0.913	32.05/0.897	31.23/0.919
MS-LapSRN	2	37.72/0.959	33.24/0.914	32.00/0.898	31.01/0.917
IDN	2	37.83/0.960	33.30/0.914	32.08/0.899	31.27/0.920
LGCN(Ours)	2	37.75/0.960	33.31/0.918	32.05/0.901	31.27/0.924
Bicubic	3	30.39/0.868	27.55/0.774	27.21/0.739	24.46/0.735
SRCNN	3	32.75/0.909	29.3/0.822	28.41/0.786	26.24/0.799
VDSR	3	33.67/0.921	29.78/0.832	28.83/0.799	27.14/0.830
LapSRN	3	33.82/0.922	29.87/0.832	28.82/0.798	27.07/0.828
DRRN	3	34.03/0.924	29.96/0.835	28.95/0.800	27.53/0.837
MS-LaSRN	3	34.01/0.924	29.96/0.836	28.92/0.801	27.39/0.835
IDN	3	34.11/0.925	29.99/0.835	28.95/0.801	27.42/0.836
LGCN(Ours)	3	34.12/0.926	30.01/0.837	28.96/0.803	27.47/0.840
Bicubic	4	28.42/0.810	26.00/0.703	25.96/0.668	23.14/0.658
SRCNN	4	30.48/0.863	27.52/0.753	26.91/0.712	24.53/0.724
VDSR	4	31.35/0.882	28.02/0.769	27.29/0.726	25.18/0.753
LapSRN	4	31.54/0.885	28.19/0.772	27.32/0.727	25.21/0.756
DRRN	4	31.68/0.888	28.21/0.772	27.38/0.728	25.44/0.764
MS-LapSRN	4	31.74/0.888	28.25/0.773	27.42/0.731	25.45/0.765
IDN	4	31.82/0.890	28.25/0.773	27.41/0.730	25.41/0.763
LGCN(Ours)	4	31.79/0.891	28.30/0.780	27.42/0.735	25.49/0.766

注:表中分别为缩放因子 $2\times$ 、 $3\times$ 和 $4\times$ 的平均PSNR/SSIM。最好的性能用粗体标出,次好的性能用下划线标出。

表 2 对比非轻量化网络结果

Tab. 2 Comparison of non-lightweighted network results

	Scale	EDSR	SRResNet	LGCN(Ours)
Set5	2	38.11/0.960	37.85/0.959	37.75/0.960
	3	34.65/0.928	34.25/0.925	34.12/0.926
	4	32.46/0.896	32.00/0.891	31.79/0.891
Set14	2	33.92/0.919	33.55/0.918	33.31/0.918
	3	30.25/0.846	30.27/0.839	30.01/0.837
	4	28.80/0.787	28.50/0.779	28.30/0.780
BSD100	2	32.32/0.901	32.08/0.900	32.05/0.901
	3	29.25/0.809	28.97/0.803	28.96/0.803
	4	27.71/0.742	27.49/0.736	27.42/0.735
Urban100	2	32.93/0.935	31.90/0.929	31.27/0.924
	3	28.80/0.865	28.00/0.847	27.47/0.840
	4	26.64/0.803	26.05/0.781	25.49/0.766
Parameters		43 000 K	1 543 K	660 K

实验同时在 Set14 数据集上进行了四倍缩放因子的视觉比较,如图 4 所示。在图 4 中可以观察到,大部分的比较方法都会因高频信息的丢失而导致红框中的花朵出现模糊伪影。相比之下,LGCN 方法可以清晰地恢复花上的红点。

在每个区块训练了不同分组大小,即 $G = 1、2$ 和 4 时所提出的 LGCN,并在表 4 中显示了它们的参数和 PSNR。 $G = 1$ 是无组的标准卷积。当分组大小为 2 时,性能下降 0.11 dB,对于 222 K 参数减少。当分组大小改为 4 时,性能比 $G = 2$ 时降低 0.16 dB,参数减少 110 k。可以看出,随着组数的增加,性能越来越差,而参数数却迅速减少。因此在最终的 LGCN 模型中选择 $G = 2$ 。从图 5 中可以看出,LGCN 在 $G = 2$ 时,实现了一个相对轻量级的模型,同时表现出了优异的重建质量。




图 4 set14 数据集的四倍因子的视觉比较

Fig. 4 Visual comparison of the four-fold factor for the set14 dataset

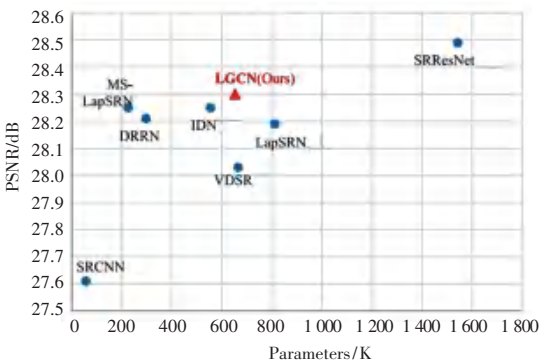


图 5 模型参数对比

Fig. 5 Comparison of model parameters

2.2 FRNN

2019 年,xu^[14]提出了一种基于反馈的轻量级复用神经网络(FRNN)。FRNN 是由一系列递归的密集连接块(DCBs)与低分辨率(LR)图像特征和输出前的 DCB 作为输入。每个 DCB 自适应地融合来自侧面输出中间特征图的多层次特征,生成强大的特征表示。同时,DCB 级联了一组多尺度残差块(MRB),每一个 MRB 都有一个放大的视场,以充分捕捉多尺度的上下文信息。

图 6 介绍了 MFRSR 的网络框架,包括一个上采样分支和一个残差学习分支。

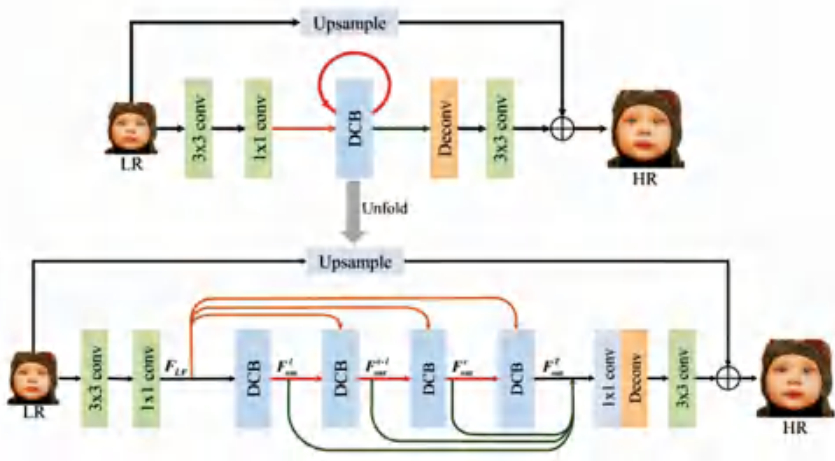


图 6 MFRSR 的结构图

Fig. 6 Structure of the MFRSR

上采样分支利用一个简单的双线性上采样核来调整 LR 输入的大小,使其与 HR 输出的大小相同。残差学习分支由 LR 特征提取块(LRFEB)组成。

如图 8 所示,密集连接块包含 N 个多尺度残差块,展示了 MRB 的内部结构,利用不同的内核来捕捉具有跳转连接的多尺度上下文信息。




图 7 DCB 结构

Fig. 7 DCB structure




图 8 MRB 结构

Fig. 8 MRB structure

针对几种算法 (SRCNN、VDSR、MSRN^[15]、D-DBRN^[16]、SRFBN^[17]) 进行了仿真实验。由图 9 可以看出,其它几种算法都会产生更多错误的文本方向或令人不快的伪影。相比之下,MFRSR 能够生成精确和真实的 SR 图像,准确地重建细节。

文献[14]的创新之处在于:

(1)提出了一种基于反馈的轻量级 RNN,用于高精度的 SISR。该网络充分利用了 LR 图像中丰富的多尺度上下文信息,生成了强大的特征呈现,这对于精确的 SISR 来说至关重要。

(2)设计了一种新型的多核融合机制,能够在

多尺度输入的情况下动态调整输出特征表征的感受野大小。因此,网络不需要通过加深层数来扩大输出表征的接受场大小,从而实现模型容量的轻量化。

(3)提出的 MFRSR 是轻量级的,只有 4.5M 的参数,如图 10 所示。但却在 5 个基准数据集上的 PSNR 和 SSIM 方面达到了最先进的性能。




图 9 不同算法实验效果对比

Fig. 9 Comparison of the experimental effects of different algorithms

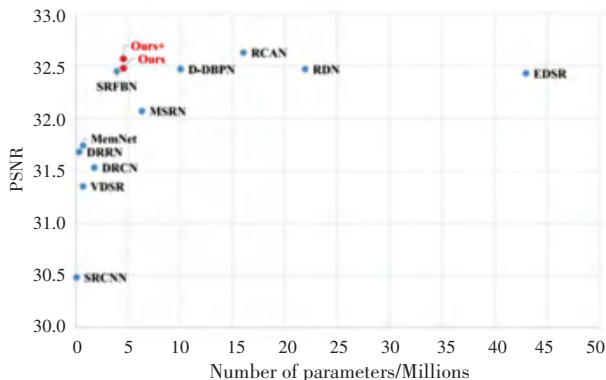


图 10 不同算法 PSNR 对比

Fig. 10 Comparison of different algorithms PSNR

2.3 AMSRN

Liu^[18]提出了一种针对 SISR 的轻量级网络,即基于注意力的多尺度残差网络 (AMSRN)。整个网络的主框架由一个残差空间金字塔池化 (ASPP) 块

以及一个空间和信道感知的注意力残差(SCAR)块交替堆叠构成。残差 ASPP 块利用不同扩张率的平行扩张卷积,来达到捕捉多尺度特征的目的。SCAR 块在双层卷积残差块的基础上增加了通道注意力(CA)和空间注意力(SA)机制。此外,在 SCAR 块中还引入了分组卷积,在防止过拟合的同时进一步降低参数。同时还设计了一个多尺度特征注意模块,为浅层特征提供指导性的多尺度注意信息。特别是提出了一种新颖的升标模块,采用双路径联合使用亚像素卷积层和最近插值层,对特征进行升标,而不是单独使用解卷积层或亚像素卷积层。

为了使网络集中在重要的特征上以增强其表示能力,根据通道和空间位置的相互依赖性,设计了一个空间和通道感知的注意力残差块,将 SA 单元和 CA 单元结合成残差块。图 11 描述了所提出的空间

和通道感知注意力模块。




图 11 空间-通道注意力模块结构

Fig. 11 Spatial-channel attention module structure

AMSRN 的框架如图 12 所示,其中包括 5 个部分:初始特征提取阶段、多尺度特征提取阶段、深层特征提取阶段、上尺度特征提取阶段以及重建阶段。




图 12 AMSRN 的整体结构

Fig. 12 Overall structure of the AMSRN

定量的角度对提出的 AMSRN 模型与一些最先进的方法进行评估,包括 SRCNN、VDSR、DRCN^[19]、LapSRN、MemNet^[19]、EDSR、CARN^[20]、MSRN、DCSR^[21]、AWSRN^[22]和 DADN^[23]。

图 13 描述了 Set14 图像的平均 PSNR 与运行时间的权衡。值得注意的是,所提出的方法在保证重建性能的前提下,速度相对较快。

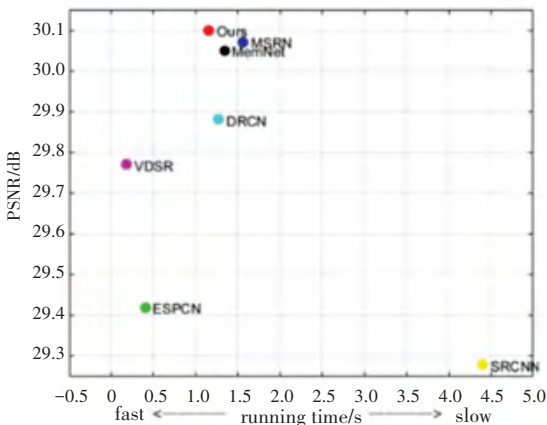


图 13 不同方法的精度和速度的比较

Fig. 13 Comparison of accuracy and speed of different methods

通过实验, Liu^[18]提出的模型达到了与最先进

的方法相媲美的效果,网络非常轻巧。然而,在升级因子较大的情况下存在不足。

2.4 LIN

Zhao 等^[24]提出了一种轻量化横向抑制网路来进行精准磁共振(MR)图像超分辨率(SR)。所提出的网络是受横向抑制机制的启发,其假设相邻神经元之间存在抑制效应。网络的主干由若干个侧向抑制块组成。其中,抑制效果是由一个级联的局部抑制单元明确实现的。当模型规模较小时,明确抑制特征激活,能进一步探索模型的表达能力。为了更有效地提取特征,还使用了多个并行的扩张卷积,直接从输入图像中提取浅层特征。

为了提取不同接受场的浅层特征大小,在特征提取子网中使用一组 3x3 稀释率不同的 conv 层,如图 14 所示,只应用一个 3x3 的 conv 层来重建最终输出。

通过适度的模型参数和计算开销,实现了高精度和快速的 SR 重建。在横向抑制机制的激励下,设计了一个局部抑制单元(LIU),明确地对特征图进行抑制调节,减轻了模型的表示负担。通过整合不同接受场大小的浅层特征,提升了模型性能。通过这种策略增加提取特征的多样性。将侧向抑制机制与浅层特

征提取相结合策略提高了深度模型的性能。

通过对几种典型图像超分辨率算法(NLM^[25]、SRCNN、VDSR、IDN、RecNet^[26]、FSCWRN^[27])进行实验对比分析,这些方法的定量结果直接利用峰值

信噪比(PSNR)和结构性分析,并且只比较与LIN模型参数数量大致相似的模型。此外,还采用了几何自编的技巧来进一步提高模型的性能,在这种情况下,其被表示为LIN+,见表3。




图 14 横向抑制网络的整体结构

Fig. 14 Overall structure of the transverse suppression network

表 3 几种典型 SR 模型之间的定量比较

Tab. 3 Quantitative comparison between several typical SR models

Mode	Methods	Scale	Params	MultiAdds	PD	T1	T2
SD	Bicubic [2D]	$\times 2$	N/A	N/A	35.04 / 0.9664	33.80 / 0.9525	33.44 / 0.9589
	NLM	$\times 2$	N/A	N/A	37.26 / 0.9773	35.80 / 0.9685	35.58 / 0.9722
	SRCNN	$\times 2$	24.5K	52.7G	38.96 / 0.9836	37.12 / 0.9761	37.32 / 0.9796
	VDSR	$\times 2$	0.67M	612.6G	39.97 / 0.9861	37.67 / 0.9783	38.65 / 0.9836
	IDN	$\times 2$	0.73M	170.8G	40.27 / 0.9869	37.79 / 0.9787	39.09 / 0.9846
	RecNet	$\times 2$	1.33M	275.0G	40.43 / 0.9873	37.86 / 0.9792	39.13 / 0.9848
	FSCWRN	$\times 2$	3.50M	1170.0G	40.72 / 0.9880	37.98 / 0.9797	39.44 / 0.9855
	The proposed LIN [Ours]	$\times 2$	1.33M	306.2G	40.86 / 0.9884	38.04 / 0.9798	39.50 / 0.9856
	The proposed LIN+ [Ours]	$\times 2$	1.33M	306.2G	41.03 / 0.9886	38.19 / 0.9803	39.62 / 0.9860
	Bicubic [2D]	$\times 3$	N/A	N/A	31.20 / 0.9230	30.15 / 0.8900	29.80 / 0.9093
	NLM	$\times 3$	N/A	N/A	32.81 / 0.9436	31.74 / 0.9216	31.28 / 0.9330
	SRCNN	$\times 3$	24.5K	52.7G	33.60 / 0.9516	32.17 / 0.9276	32.20 / 0.9440
	VDSR	$\times 3$	0.67M	612.6G	34.66 / 0.9599	32.91 / 0.9378	33.47 / 0.9559
	IDN	$\times 3$	0.83M	76.8G	34.96 / 0.9619	33.06 / 0.9394	33.92 / 0.9591
RecNet	$\times 3$	1.33M	275.0G	34.96 / 0.9623	33.05 / 0.9399	33.85 / 0.9588	
FSCWRN	$\times 3$	3.50M	523.5G	35.37 / 0.9653	33.24 / 0.9423	34.27 / 0.9618	
The proposed LIN [Ours]	$\times 3$	1.37M	141.2G	35.39 / 0.9654	33.23 / 0.9421	34.26 / 0.9616	
The proposed LIN+ [Ours]	$\times 3$	1.37M	141.2G	35.56 / 0.9661	33.41 / 0.9440	34.41 / 0.9627	
Bicubic [2D]	$\times 4$	N/A	N/A	29.13 / 0.8799	28.28 / 0.8312	27.86 / 0.8611	
NLM	$\times 4$	N/A	N/A	30.27 / 0.9044	29.31 / 0.8655	28.85 / 0.8875	
SRCNN	$\times 4$	24.5K	52.7G	31.10 / 0.9181	29.90 / 0.8796	29.69 / 0.9052	
VDSR	$\times 4$	0.67M	612.6G	32.09 / 0.9311	30.57 / 0.8932	30.79 / 0.9240	
IDN	$\times 4$	0.96M	43.9G	32.47 / 0.9354	30.74 / 0.8966	31.37 / 0.9312	
RecNet	$\times 4$	1.33M	275.0G	32.58 / 0.9378	30.86 / 0.9005	31.30 / 0.9310	
FSCWRN	$\times 4$	3.50M	297.3G	32.91 / 0.9415	30.96 / 0.9022	31.71 / 0.9359	
The proposed LIN [Ours]	$\times 4$	1.36M	85.6G	32.94 / 0.9417	31.01 / 0.9033	31.72 / 0.9361	
The proposed LIN+ [Ours]	$\times 4$	1.36M	85.6G	33.12 / 0.9432	31.28 / 0.9073	31.88 / 0.9376	

根据表 4,执行最慢的是 NLM,因为其是基于迭代优化处理的。此外,基于深度 CNN 方法的运行时间也很相似,都是每卷小于 5 s。本文模型的效率与其它快速模型相当。例如, IDN 和 RecNet,由于这

些模型规模相似,提出的 LIN 和 LIN+的性能明显优于这些模型,见表 3。该模型不仅在 SR 性能上有很高的准确性,而且在实际应用中也有实际作用。

表 4 比较模型处理的运行时间

Tab. 4 Comparison of model processing runtimes

scale	Bicubic	NLM	SRCNN	VDSR	IDN	RecNet	FSCWRN	LIN
$r = 2$	0.1543	90.423 8	0.302 1	1.764 4	0.812 3	0.823 1	2.190 6	0.850 1
$r = 3$	0.157 8	63.535 7	0.321 1	2.648 8	0.441 5	0.965 2	1.140 3	0.968 9
$r = 4$	0.161 0	46.035 8	0.328 4	2.413 1	0.277 3	1.027 7	0.747 7	1.078 8

在不同的 MR 图像上进行的广泛实验表明(如图 15),所提出的模型优于其他轻量级 SR 模型。由

于模型规模和性能之间更好的权衡, LIN 模型更适合现实世界的应用和部署。




图 15 多种模型实验仿真

Fig. 15 Experimental Simulation of Various Models

3 结束语

本文介绍了几种轻量化网络模型,这一些网络模型在很大程度上都比传统的神经网络在网络参数、视觉效果上都有很明显的优势。特别是在移动设备上的应用,小型化的神经网络的研究将会使得移动设备图像超分辨率拥有更广泛的发展前景。特别是解决传统神经网络运算需求过大而无法在移动设备上高效运行的问题,但是其具有任务单一、泛化性差的缺点,因此,未来需要对网络搜索算法进行研究,在不同的应用场景下,可以根据网络搜索对该场景下最优的轻量化网络进行搜索并应用,使得不同的轻量化网络都能发挥出其最优的性能。基于轻量化网络搜索的超分辨率将是未来的一个研究方向。

参考文献

- [1] NASROLLAHI K, MOESLUND T B. Super-resolution: A comprehensive survey [J]. *Machine Vision and Applications*, 2014, 25(6):1423-1468.
- [2] WANG X W, LIU Y. Survey of image super-resolution investigation [J]. *Information Technology*, 2009, 7:236-240.
- [3] YANG Aiping, YANG Bingwang, JI Zhong, et al. Lightweight group convolutional network for single image super-resolution [J]. *Information Sciences*, 2020, 516:220-233.
- [4] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks [C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017: 2261-2269.
- [5] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018:7132-7141.
- [6] DONG C, LOY C C, HE K, et al. Image super-resolution using deep convolutional networks [J]. *IEEE Trans. Pattern Anal. Mach. Intell.* 2016, 38(2): 295-307.
- [7] KIM J, J. Kwon Lee, K. Mu Lee, Accurate image super-resolution using very deep convolutional networks [C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016:1646-1654.
- [8] LAI W S, HUANG J B, AHUJA N, et al. Deep laplacian pyramid

- networks for fast and accurate super-resolution [C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017:5835-5843.
- [9] LAI W S, HUANG J B, AHUJA N, et al. Fast and accurate image super-resolution with deep laplacian pyramid networks [J]. *IEEE Trans. Pattern Anal. Mach. Intell.*, 2018, 23(3):2599-2613.
- [10] TAI Y, YANG J, LIU X. Image super-resolution via deep recursive residual network [C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017: 2790-2798.
- [11] HUI Z, WANG X, GAO X. Fast and accurate single image super-resolution via information distillation network [C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018: 723-731.
- [12] LEDIG C, THEIS L, HUSZÁR F. Photo-realistic single image super-resolution using a generative adversarial network [C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017:4681-4690.
- [13] LIM B, SON S, KIM H, et al. Enhanced deep residual networks for single image super-resolution [C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition workshops*, 2017:1132-1140.
- [14] XU W, SONG H, ZHANG K, et al. Learning lightweight Multi-Scale Feedback Residual network for single image super-resolution [J]. *Computer Vision and Image Understanding*, 2020, 197-198:103005.
- [15] LI Juncheng, FANG Faming, MEI Kangfu, et al. Multi-scale residual network for image super-resolution [C]// *Proceedings of the European Conference on Computer Vision*, 2018:17-532.
- [16] Haris, Muhammad, Shakhnarovich, Gregory, Ukita, Norimichi. Deep backprojection networks for super-resolution [C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018:1664-1673.
- [17] Li Zhen, YANG Jinglei, LIU Zheng, et al. Feedback network for image super-resolution [C]// *The IEEE Conference on Computer Vision and Pattern Recognition*, 2019.
- [18] LIU H, CAO F, WEN C, et al. Lightweight multi-scale residual networks with attention for image super-resolution [J]. *Knowledge-Based Systems*, 2020, 203:106103.