

基于多尺度稠密卷积网络的单图像超分辨率重建

唐家福, 穆平安

(上海理工大学 光电信息与计算机工程学院, 上海 200093)

摘要: **目的** 针对已有网络对于卷积特征图利用率低下, 从而导致高倍数图像重建质量不高的情况, 提出一种多尺度稠密卷积网络 (SRMD)。**方法** 对 SRDenseNet 的稠密连接模块进行改进, 去除批规范化层, 参考已有网络, 设计多尺度特征提取层和 1×1 的信息整合层, 从而构成多尺度稠密卷积模块。SRMD 通过一个多尺度特征提取层堆叠 64 个底层特征图, 再由 8 个多尺度稠密卷积模块经过稠密连接堆叠 1024 个特征图, 最后通过信息整合和子像素卷积模块输出超分辨率重建图像。**结果** 在 Set5, Set14, B100 和 U100 数据集上进行测试, SRMD 重建图像的峰值信噪比分别为 30.1570, 26.9952, 25.7860, 23.4821 dB, 结构相似性分别为 0.8813, 0.7758, 0.7243, 0.7452。**结论** 与已有网络相比, SRMD 与 DRCN, VDSR 表现相当, 优于 SRDenseNet 和 BiCubic 方法。

关键词: 图像超分辨; 卷积神经网络; 多尺度信息; 稠密连接

中图分类号: TP391 **文献标识码:** A **文章编号:** 1001-3563(2020)13-0267-07

DOI: 10.19554/j.cnki.1001-3563.2020.13.038

Single Image Super-resolution Reconstruction Based on Multiscale DenseNet

TANG Jia-fu, MU Ping-an

(School of Optical-electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

ABSTRACT: This paper aims to propose a multi-scale dense convolution network (SRMD) to solve the problem of low utilization of convolution feature map and low reconstruction quality of high-power image. In this paper, the dense connection module of SRDenseNet was improved, and the batch normalization layer was removed. Referring to the existing network, the information integration layer of multi-scale feature extraction layer and 1×1 was designed to form a multi-scale dense convolution module. SRMD stacked 64 low-level feature images through a multi-scale feature extraction layer, and then stacked 1024 feature images through 8 multi-scale dense convolution modules after dense connection. Finally, SRMD output super-resolution reconstruction images through information integration and sub-pixel convolution modules. In this paper, the test is carried out on Set5, Set14, B100 and U100. The peak signal-to-noise ratio of SRMD reconstructed image is 30.1570, 26.9952, 25.7860 and 23.4821 dB, respectively, and the structural similarity is 0.8813, 0.7758, 0.7243 and 0.7452. Compared with the existing networks, SRMD, DRCN and VDSR have the same performance, superior to SRDenseNet and BiCubic methods.

KEY WORDS: image super-resolution; convolutional neural network; multiscale information; dense connection

收稿日期: 2019-11-05

作者简介: 唐家福 (1995—), 男, 上海理工大学硕士生, 主攻图像处理、深度学习。

通信作者: 穆平安 (1964—), 男, 硕士, 上海理工大学教授, 主要研究方向为机器视觉与智能检测、信息获取与处理技术。

外包装的机器视觉检测方法受限于硬件设计及其成本,经常采用局部放大来获得亚像素检测精度,旨在从一张低分辨率图像(Low Resolution, LR)重建高分辨率图像(High Resolution, HR),即单图像超分辨率重建(Single Image Super-Resolution, SISR)。

近年来,基于深度学习的 SISR 得到广泛关注, SISR 是一个病态问题,其上采样是关键,根据上采样在模型中的位置, SISR 结构可以分为 4 种框架:预先采样 SISR,后上采样 SISR,渐进上采样 SISR 和迭代上下采样 SISR。Dong 等^[1]提出 SRCNN 模型,将深度学习方法引入到 SISR 中来,对于通过双三次插值预先采样;然后经过特征提取与表示、特征非线性映射和超分辨率重建三层卷积神经中,从而实现了端到端学习 LR 图像块与 HR 图像块稀疏编解码字典关系^[2],并使用 GPU 加速训练,网络结构简单,在保证高质量重建效果的同时能够快速重建;随后 Dong 等^[3]进一步提出了 FSRCNN,该模型是对 SRCNN 的改进,其网络层数更深,利用小卷积核代替了 FSRCNN 的大卷积核,并利用反卷积层的后上采样代替双三次插值预先采样。双三次插值预先采样导致后续计算都在高分辨率图像上进行,增加了计算复杂度,插值过程中引入了更多的噪声如振铃效应、混叠效应、块效应和模糊效应。FSRCNN 将反卷积层放在模型最后,减少了模型计算复杂度,训练速度也更快,效果更好。进一步,为了更好地实现超分辨率重建的上采样过程,Wenzhe Shi 等^[4]提出 ESPCN,该网络提出一种新型的亚像素卷积层(sub-pixel convolutional layer),能够更好地实现上采样过程,当需要重建 r 倍 HR 图像时,通过将 $H \times W \times r^2$ 的特征图按照一定顺序重新排列成 $rH \times rW \times 1$ 图像。在此过程中,没有增加额外参数,所有计算都在低分辨率图像上进行,训练速度更快。上述 3 种模型都是单通道浅层网络,更深的网络在 SISR 图像质量上更有效,于是残差学习被引入到超分辨率的重建中来。Kim 等^[5]提出 VDSR,该网络为残差学习网络^[6],输入为双三次插值图像,参考利用 20 个 3×3 卷积层来学习 HR 图与插值图像之间残差,由于其网络更深,取得不错的超分辨率重建,但是由于其预先采样导致其计算量更大。近 2 年,各种网络结构被应用到 SISR 中,更深的级联网络 LapSRNet^[7],递归学习网络 RNN^[8-11],稠密连接的 SRDenseNet^[12-13]和多路径学习结构^[10-11]被应用到超分辨率重建中。

参考上述网络设计,文中对 SRDenseNet 的稠密连接模块进行改进,去除批规范化层,设计多尺度特征提取层和 1×1 的信息整合层,最终构成多尺度稠密卷积模块,多尺度稠密卷积模块能够大大增加特征图的利用率,在无需额外计算条件下可以快速堆叠大量

特征图,包括图像底层特征,深层特征以及多尺度信息,充分地利用输入图像的特征信息,能够有效地重建高分辨率图像的细节信息。SRMD 实现端到端的训练,无需增加额外的先验信息,通过 1 个多尺度特征提取层堆叠 64 个底层特征图,再由 8 个多尺度稠密卷积模块经过稠密连接堆叠 1024 层特征图,最后通过信息整合和子像素卷积模块输出超分辨率重建图像。

1 相关工作

1.1 DRCN 与 DRCN

DRCN^[8]与 VDSR^[5]为 Jiwon Kim 等于 2016 年提出,首次将 ResNet^[6]中的残差学习引入 SISR 中。DRCN 利用递归网络增加感受野,DRCN 分为 3 个部分:特征提取、递归学习非线性映射和图像重建。递归学习部分由若干个共享参数的卷积层组成,所有卷积层的加权平均得到最终输出。VDSR 利用深度网络增加感受野,VDSR 将网络层数加深到 20 层,为了缓解不断增加的网络深度引起的退化问题,VDSR 引入了 ResNet 中的残差学习,同时残差学习提高了网络的学习能力。为了更快收敛,VDSR 在训练上使用一个较大的学习率,较大的学习率会带来梯度爆炸问题,利用自适应梯度裁剪(Adjustable Gradient Clipping)限制了梯度范围,从而解决此问题,梯度裁剪公式见式(1)。此外,VDSR 选择双三次插值预先上采样作为输入,选择不同倍数的图像混合在一起进行训练,从而支持不同倍数的图像超分辨率,而整个网络仅仅学习双三次插值图像与 HR 图像之间的残差,残差图像是稀疏的,能够加快收敛。由于网络包含残差信息学习,因而能够获得更高的计算指标。

$$g = \min\left(\frac{\theta}{\|g\|}, 1\right)g \quad (1)$$

1.2 SRDenseNet

SRDenseNet^[11]将 DenseNet^[13]中的稠密卷积模块引入 SISR 中来,DenseNet 在稠密卷积模块(dense block)中将每一层的特征都输入给之后的所有层,使所有层的特征都堆叠起来,而非像 ResNet 那样直接相加。稠密卷积模块对于特征的复用性更强,加强特征传播,减轻梯度消失问题。SRDenseNet 由卷积层学习低层的特征,多个稠密模块学习高层特征并堆叠,降维融合特征组经由上采样层和卷积层生成高分辨率输出,在此基础上,SRDenseNet 对于稠密块学习部分进一步改进,分别对比了 3 种结构:无连接、残差连接和稠密连接,结果表明稠密连接对于 SISR 的效果好于前 2 种连接方式。

1.3 改进稠密卷积模块

SRDenseNet 直接使用 DenseNet 中的稠密卷积模块,包含了批规范化层,参考 EDSR^[10]对 SRResNet^[11]的优化,EDSR 是对 SRResNet 的改进,去除了 SRResNet 中批规范化层,并把残差层数量由 16 层增加至 32 层。EDSR 说明了批规范化层只适合于高层计算机视觉任务中,而图像超分辨率作为底层任务,去除批规范化层后,在消耗相同计算机资源条件下,可以堆叠更多的网络。文中去除了 DenseNet Block 中批规范化层 (Batch Normalization, BN)。BN^[14]于 2015 年被提出,即对数据作批量规范化,使得数据满足均值为 0,方差为 1 的正态分布,其主要作用是缓解 DNN 训练中的梯度消失/爆炸现象,加快模型的训练速度。对于 SISR 任务,批规范化层被证明不仅不会增强网络能力,而且会增加参数量,基于深度学习的 SISR 任务的目标函数是像素的均方误差,BN

等面向特征的网络优化层在 SISR 任务中效果不佳。

2 网络结构

2.1 多尺度稠密卷积

DenseNet 中的稠密卷积模块包含批规范化层,批规范化层并不适合用来处理图像超分辨率任务。文中去除了 DenseNet 中的批规范化层,从 Inception^[14-17]和 MobileNet-V2^[18]获得灵感,对稠密卷积模块进一步改进,使得该模块能够提取多尺度特征信息,每个稠密卷积模块包含多尺度信息整合层、8 个卷积层深度特征提取以及特征融合层。多尺度信息整合层由 4 条不同尺度的支路构成,每条支路都由一个 1×1 卷积核和不同尺度的卷积核构成,分别提取不同尺度信息,最终 4 条支路在深度上进行堆叠,而每个卷积核深度都较小,通过堆叠获得非常深的卷积特征图,并且卷积次数大大减少,效率更高。

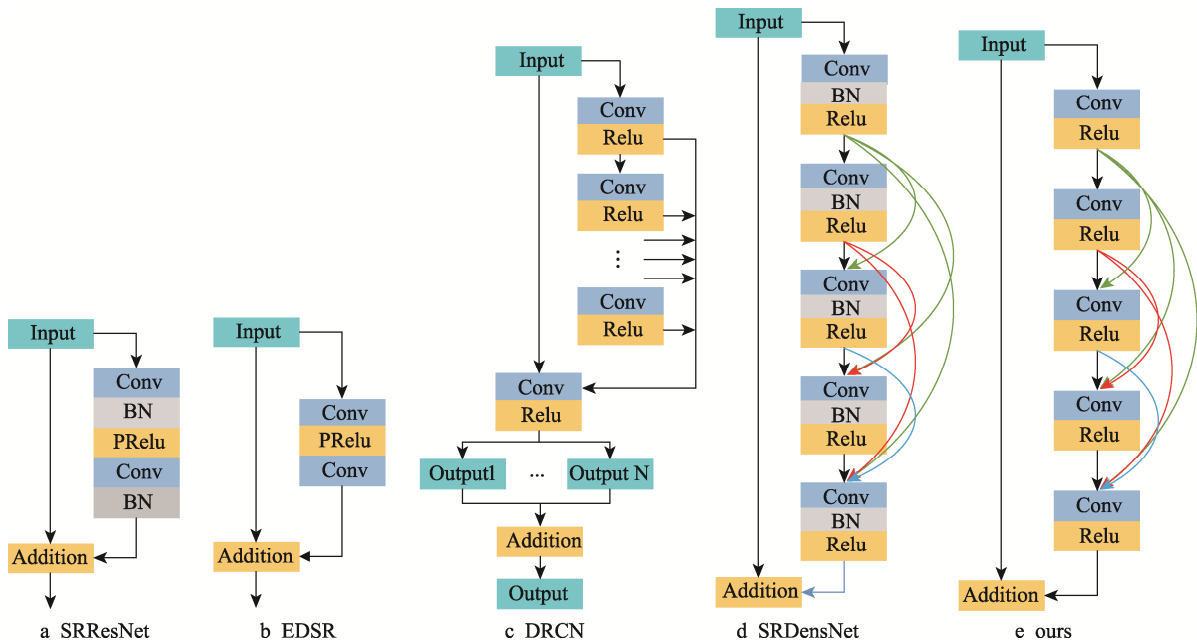


图 1 各种网络模块结构对比

Fig.1 Structure comparison of various network modules




图 2 多尺度稠密卷积模块

Fig.2 Multi-scale dense convolution module

2.2 上采样与目标函数

为了减少参数量，SRDenseNet 采用了子像素卷积的后上采样方法，该采样方法是针对 SISR 任务专门设计出来的，但是只能训练固定超分辨率模型，对于不同倍率的超分辨率，需要重新训练上采样部分，文中只对 4 倍率的 SISR 任务进行研究。

SISR 的目标函数一般为均方差函数，见式 (2)，其中网络权重参数 $\theta=\{W_i, B_i\}$ ， I_{ij}^{HR} 为超分辨率真值图像， \hat{I}_{ij}^{HR} 为超分辨率预测图像， I_{ij}^{LR} 为低分辨率图像。

$$L(\theta) = \sum_{i=1}^n \sum_{j=1}^n |I_{ij}^{HR} - \hat{I}_{ij}^{HR}(I^{LR}, \theta)|^2 \tag{2}$$

2.3 多尺度稠密卷积网络

单层网络映射可表示为：

$$F_i(x) = \max(0, w_i * x_{i-1} + b_i) \tag{3}$$

式中： x_i 为网络的输入； w_i 为网络权重； b_i 为网络偏置参数。

残差块映射可表示为：

$$f_{Res}(x) = F_i(x) - x \tag{4}$$

递归网络可表示为：

$$R_i = g^n(g^{n-1}(\dots(g^1(x) + x)\dots) + x) + x \tag{5}$$

式中： n 为递归模块中的层数。

稠密卷积模块可表示为：

$$F_i(x) = \max(0, w_i * [x_1, x_2 \dots x_{i-1}] + b_i) \tag{6}$$

U 表示上采样层，包括反卷积层和亚像素卷积层，各种网络的数学表达见表 1。

表 1 各类模型的数学表达

Tab.1 Mathematical expression of various models

模型	数学表达
SRCNN	$\hat{y} = F_3(F_2(F_1(x)))$
FSRCNN	$\hat{y} = U(F_{n-1}(F_{n-1}(\dots(F_1(x))\dots)))$
EDSR	$\hat{y} = f_{Rec}(f_{n-1}(f_{n-2}(\dots(f_1(x))\dots))) + x$
DRRN	$\hat{y} = f_{Rec}(R_B(R_{B-1}(\dots(R_1(x))\dots))) + x$
SRDenseNet	$\hat{y} = F_n(F_{n-1}(\dots(F_1(x))\dots))$

文中多尺度模块的数学表达见式 (7)。

$$\hat{y} = F_n(F_{n-1}(\dots(F_1(\sum_{k=1}^4 F_0^k(x))\dots))) \tag{7}$$

式中： n 为模块深度； $k=4$ ，表示 4 个多尺度卷积支路。通过对比各种网络核心模块的数学表达可以发现，稠密连接对于卷积的利用效率远远超过其他网络，在相同的参数下，可以获得更多的特征图，由此带来的冗余的特征图，使得特征融合更加困难。在稠密卷积模块前后都设置有 1×1 卷积，前面的 1×1 用于融合多尺度的底层特征，减少计算量，后面的 1×1 卷积核用于融合改进稠密卷积模块的深层特征。文中在 SRDenseNet 基础上增加了多尺度信息的同时也增加网络的感受野，SRDenseNet 为 16 个 3×3 卷积核，文中的多尺度信息整合层为 4 个 9×9 卷积核，4 个 7×7 卷积核，4 个 5×5 卷积核以及 4 个 3×3 卷积核。

文中模型在底层特征提取部分由 4 条不同卷积核的支路构成，每条支路为 16 个深度，通过堆叠获得 64 个底层特征图。非线性映射部分由 8 个多尺度稠密卷积模块构成，并且模块间也是稠密连接方式。超分辨率重建部分由子像素卷积和一个 3×3 卷积核组成。

3 实验与分析

3.1 模型训练

文中的训练平台参数：CPU IntelI7-9700F，GPU RTX2060S，RAM 32 GB，程序平台 Ubuntu18.04，python3.7，基于 keras/tensorflow 编写了模型代码。训练数据集和验证集均为 DIV2K^[19]，超分辨率重建倍率为 4 倍。权重初始化采用 Glorot^[20]正态分布初始化方法，也称作 Xavier 正态分布初始化，参数由 0 均值，标准差为 $\sqrt{W^{in} + W^{out}}$ 的正态分布产生，其中 W^{in} 和 W^{out} 是权重张量的输入输出（即输入和输出单元数目）。文中对 DIV2K 数据集进行剪裁作为 HR 图像，尺寸为 96×96 ，共计 50 000 余张图像，经由 Bicubic 下采样获得 LR 图像，分别采用 Matlab 和 python 平台完成数据集构建过程，训练曲线见图 4—5。由图 4—5 可知，对于不同计算平台，进行相同的计算过程，其计算结果有明显差异，显然基于 Matlab 构建的数据集，其 loss 更小，评价指标也能获得更大的分数。




图 3 多尺度稠密卷积网络整体结构

Fig.3 Overall structure of multi-scale dense convolution network

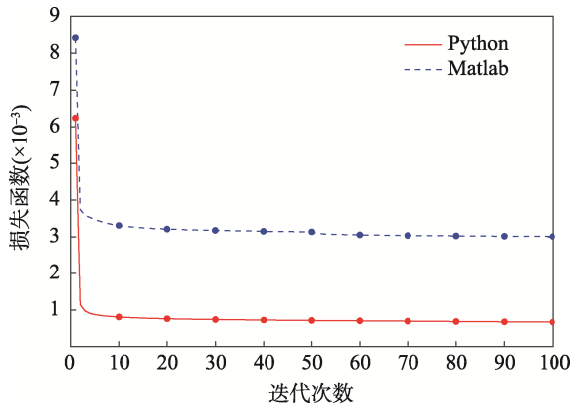


图 4 损失函数收敛曲线

Fig.4 Convergence curve of loss function




图 5 PSNR 迭代曲线

Fig.5 PSNR iteration curve

3.2 实验结果

不同计算机语言导致计算结果不同,为了便于比较,文中统一采用 python 的 skimag(Scikit-Image)模

块中的图像质量评价函数库进行度量,采用峰值信噪比 (Peak Signal-to-Noise Ratio, PSNR) 和结构相似性 (Structural Similarity Index, SSIM) [21]对超分辨率重建图像进行综合评价,2 个评价指标的计算见式 (8—9)。

$$P_{\text{PSNR}} = 10 \times \ln \left(\frac{(2^n - 1)^2}{L_{\text{MSE}}} \right) \quad (8)$$

式中: n 为图像位数; L_{MSE} 为 2 张图像的均方误差。

$$S_{\text{SSIM}}(L, \hat{H}) = \frac{(2\mu_L\mu_{\hat{H}} + c_1)(2\sigma_{L\hat{H}} + c_2)}{(\mu_L^2 + \mu_{\hat{H}}^2 + c_1)(\sigma_L^2 + \sigma_{\hat{H}}^2 + c_2)} \quad (9)$$

式中: $\mu_L, \mu_{\hat{H}}$ 分别为低分辨率图像与超分辨重建图像的像素均值; $\sigma_L, \sigma_{\hat{H}}$ 为像素方差; $\sigma_{L\hat{H}}$ 为协方差, $c_1=(k_1N)^2, c_2=(k_2N)^2$ 均是稳定常数, N 为动态范围。

PSNR 是基于均方误差 MSE 敏感的图像质量评价指标,其对残差信息更敏感。SSIM 是全参考的图像质量评价指标,范围是 0~1,PSNR/SSIM 数值越大表示失真越小。

文中对 BiCubic, VDSR, DRCN, SRDenseNet 以及 SRMD 的结果进行了对比,在 Set5, Set14, B100 和 U100 等 4 个主流数据集上进行测试对比。由 3.1 节发现对于不同语言平台,相同的计算过程,计算结果有明显差异。虽然基于 Matlab 构建数据集训练曲线更好,但在 4 个测试集的峰值信噪比分别为 29.0104, 25.8716, 25.6314 和 23.1273 dB,测试集效果反而变差了。这是由于不同计算平台造成了数据类型等因素的不统一。文中全部基于 python 平台进行数据集制作和模型的搭建,故而也采用 python 进行评价指标的计算。部分图像重建图像见图 6—7, Set14




图 6 Butterfly_GT(Set5) 4 倍超分辨率重建结果

Fig.6 Super resolution reconstruction results of Butterfly_GT(Set5)×4

表 2 Set14 数据集 4 倍超分辨重建结果
Tab.2 Results of super-resolution reconstruction on Set14

Data	Bicubic	DRCN	VDSR	SRDenseNet	Ours
Pepper	27.8829/0.8083	30.4395/0.8594	31.2822/0.8613	30.9043/0.8622	31.3761/0.8616
Monarch	26.2244/0.8711	30.5431/0.9323	30.3354/0.9308	30.7048/0.9343	30.9818/0.9326
Barbara	23.7963/0.6677	24.4715/0.7403	24.4840/0.7410	24.6757/0.7466	25.0070/0.7549
Baboon	20.9071/0.4230	21.2750/0.5279	21.3285/0.5280	21.2854/0.5321	21.4398/0.54028
Lenna	28.5838/0.7894	30.6782/0.8460	30.6226/0.8452	30.7185/0.8491	30.9364/0.8491
Bridge	23.0582/0.5379	23.7932/0.6448	23.8314/0.6470	23.6665/0.6455	24.1028/0.6567
Ppt3	20.7077/0.8064	24.2771/0.9125	24.7026/0.9174	22.1460/0.8485	26.0597/0.9297
Face	30.3405/0.7195	31.4615/0.7819	31.3934/0.7815	30.0068/0.7510	31.4485/0.7833
Comic	20.4154/0.5709	21.7243/0.7223	21.7313/0.7203	21.6444/0.7230	22.0154/0.7319
Foreman	25.9951/0.8425	28.6574/0.9087	28.1034/0.9085	28.3590/0.9051	29.7929/0.9104
Flowers	24.3251/0.7023	26.4782/0.8059	26.4702/0.8056	26.2334/0.7996	26.7209/0.8063
Coastguard	23.9835/0.4835	24.7197/0.5534	24.7616/0.5588	23.3452/0.5349	25.1697/0.5673
Zebra	22.8399/0.6525	25.7158/0.7684	25.4686/0.7665	24.3591/0.7545	26.7199/0.7864
Man	24.4124/0.6445	25.8941/0.7451	25.9122/0.7458	25.2452/0.7201	26.1625/0.7509
mean	24.5337/0.6800	26.4377/0.7678	26.4591/0.7684	25.9496/0.7576	26.9953/0.7758

注：/前面数据表示 PSNR；/后面数据表示 SSIM

表 3 Set5, Set14, B100 和 U100 数据集×4 超分辨重建结果
Tab.3 Results of super-resolution reconstruction on Set5, Set14, B100 and U100

DataSet	Bicubic	DRCN	VDSR	SRDenseNet	Ours
Set5	27.1022/0.7908	30.0928/0.8817	29.9199/0.8802	29.5843/0.8715	30.1570/0.8813
Set14	24.5337/0.6800	26.4377/0.7678	26.4591/0.7684	25.9496/0.7576	26.9952/0.7758
B100	24.6503/0.6446	25.9095/0.7255	25.9727/0.7276	25.7574/0.7231	25.7860/0.7243
U100	21.8089/0.6368	23.7903/0.7514	23.8501/0.7531	23.7648/0.7519	23.4821/0.7452

注：/前面数据表示 PSNR；/后面数据表示 SSIM

中所有图像的重建结果见表 2，4 个数据集重建综合评价结果见表 3。由表 3 可以发现，传统算法 BiCubic 明显低于现有的深度学习算法，并且相差较大，而深度学习算法之间相差较小。SRMD 在 PSNR/SSIM 评价指标上，与已有网络结果表现相当，特别是 SRDenseNet 在 4 个数据集上全部低于 VDSR 和 DRCN，经过文中的改进之后，网络性能明显提高，SRMD 在 Set14 数据集上取得了最佳表现。

4 结 语

文中参考并对比了各种已有网络结构的优缺点，对 SRDenseNet 中稠密卷积模块进行改进，并加入了多尺度特征提取层，构成了多尺度稠密卷积模块，可高效堆叠深度学习网络的特征图，通过多尺度提取底层特征，堆叠若干个该模块完成深层特征提取和非线

性映射，经由融合降维整合多尺度信息和深度特征，最后通过子像素卷积完成高分辨率图像重建过程。实验表明，文中所提出网络与已有网络相比竞争力明显，在未来工作中，可以引入分组卷积，递归学习和共享参数等策略使得网络的特征提取部分效率更高，高倍率超分辨率图像更好。

参 考 文 献：

[1] 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.

[2] TIMOFTE R, DE S V, VAN G L. A+: Adjusted Anchored Neighborhood Regression for Fast Super-resolution[C]// Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intel-

- ligence and Lecture Notes in Bioinformatics), 2015, 9906: 111—126.
- [3] DONG C, LOY C C, TANG X. Accelerating the Super-resolution Convolutional Neural Network[J]. Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 2016, 9906: 391—407.
- [4] SHI W, CABALLERO J, HUSZAR F, et al. Real-Time Single Image and Video Super-resolution Using an Efficient Sub-pixel Convolutional Neural Network[C]// Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016: 1874—1883.
- [5] KIM J, LEE J K, LEE K M. Accurate Image Super-resolution Using Very Deep Convolutional networks[C]// Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016: 1646—1654.
- [6] HE K, ZHANG X, REN S, et al. Deep Residual Learning for Image Recognition[C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Seattle, 2016: 770—778.
- [7] LAI W S, HUANG J B, AHUJA N, et al. Deep Laplacian Pyramid Networks for Fast and Accurate Super-resolution[C]// 30th IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, 2017: 5835—5843.
- [8] KIM J, LEE J K, LEE K M. Deeply-recursive Convolutional Network for Image Super-resolution[C]// Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016: 1637—1645.
- [9] TAI Y, YANG J, LIU X. Image Super-resolution via Deep Recursive Residual Network[J]. Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2790—2798.
- [10] LIM B, SON S, KIM H, et al. Enhanced Deep Residual Networks for Single Image Super-resolution[C]// 30th IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Honolulu, 2017: 1132—1140.
- [11] LEDIG C, THEIS L, HUSZÁR F, et al. Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network[C]// 30th IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, 2017: 105—114.
- [12] TONG T, LI G, LIU X, et al. Image Super-Resolution Using Dense Skip Connections[C]// 16th IEEE International Conference on Computer Vision (ICCV), Venice, ITALY, 2017: 4809—4817.
- [13] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely Connected Convolutional Networks[C]// 30th IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, 2017: 2261—2269.
- [14] SZEGEDY C, LIU W, JIA Y, et al. Going Deeper with Convolutions[C]// IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, MA, 2015: 1—9.
- [15] IOFFE S, SZEGEDY C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift[C]// 32nd International Conference on Machine Learning, 2015: 448—456.
- [16] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the Inception Architecture for Computer Vision[C]// Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016: 2818—2826.
- [17] SZEGEDY C, IOFFE S, VANHOUCKE V, et al. Inception-v4, Inception-resNet and The Impact of Residual Connections on Learning[C]// 31st AAAI Conference on Artificial Intelligence, 2017: 4278—4284.
- [18] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: Inverted Residuals and Linear Bottlenecks[C]// 31st IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Salt Lake City, 2018: 4510—4520.
- [19] AGUSTSSON E, TIMOFTE R. IEEE. NTIRE 2017 Challenge on Single Image Super-resolution: Dataset and Study[C]// 30th IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Honolulu, 2017: 1122—1131.
- [20] GLOROT X, BENGIO Y. Understanding the Difficulty of Training Deep Feedforward Neural Networks[C]// Journal of Machine Learning Research. 2010, 9: 249—256.
- [21] WANG Z, BOVIK A C, SHEIKH H R, et al. Image Quality Assessment: From Error Visibility to Structural Similarity[J]. IEEE Transactions on Image Processing, 2004, 13(4): 600—612.