Journal of Image and Signal Processing 图像与信号处理, 2018, 7(2), 96-104
Published Online April 2018 in Hans. http://www.hanspub.org/journal/jisp
https://doi.org/10.12677/jisp.2018.720011

Hans汉斯

Super-Resolution Reconstruction of Cascaded Multi-Scale Crossover Networks Based on Depthwise Separable Convolutions

Lijuan Shang, Zilu Ying, Ying Xu*

School of Information Engineering, Wuyi University, Jiangmen Guangdong
Email: *xuying117@163.com

Received: Apr. 3rd, 2018; accepted: Apr. 20th, 2018; published: Apr. 27th, 2018

Abstract

Deep convolutional neural networks have achieved remarkable results in accuracy and speed for single image super-resolution. However, when the depth of the network is increased, the flow of information is weakened and training is difficult to achieve. At the same time, most existing network structures use a single-stream structure, and context information is difficult to obtain under different receptive domains. To improve information flow to get enough details and reduce network parameters, in this paper, a Cascaded Multiscale Crossing Network (CMSC) based on a deeply separable network is proposed. In each cascading sub-network, multiple multi-scale crossover modules are stacked to fuse complementary multi-scale information, thereby effectively improving cross-layer information flow. At the same time, a residual learning strategy was introduced at each stage to make full use of the low-resolution feature information to further enhance the reconstruction performance. The evaluation of the benchmark datasets shows that the proposed method outperforms the most mainstream superresolution methods.

Keywords

Single Image Super-Resolution, Depthwise Separable Convolution, Multi-Scale Crossover Network, Cascading

基于深度可分离卷积的级联多尺度交叉网络的超分辨率重构

商丽娟，应自炉，徐　颖*

五邑大学信息工程学院，广东 江门
Email: *xuying117@163.com

*通讯作者。

文章引用: 商丽娟, 应自炉, 徐颖. 基于深度可分离卷积的级联多尺度交叉网络的超分辨率重构[J]. 图像与信号处理, 2018, 7(2): 96-104. DOI: 10.12677/jisp.2018.720011

收稿日期：2018年4月3日；录用日期：2018年4月20日；发布日期：2018年4月27日

摘 要

深度卷积神经网络进行单幅图像超分辨率在精度和速度方面取得了显著成果。然而随着网络的层次加深，信息流动减弱，训练难以实现。同时，大多数模型采用单流结构，在不同的感受域下的上下文信息很难获取。改善信息流动获取足够的细节信息并减少网络参数量，本文提出了基于深度可分离卷积的级联多尺度交叉网络(Cascaded Multiscale Crossing Network, CMSC)，在每个级联子网络中，堆叠多个多尺度交叉模块以便融合互补多尺度的信息，从而有效改善跨层的信息流。同时，在每个阶段引入残差学习策略，充分利用低分辨率特征信息，进一步提升重建性能。在基准数据集的评估表明本文方法优于最主流的超分辨率方法。

关键词

单图像超分辨率，深度可分离卷积，多尺度交叉模块，级联

Copyright © 2018 by authors and Hans Publishers Inc.
This work is licensed under the Creative Commons Attribution International License (CC BY).
http://creativecommons.org/licenses/by/4.0/
Open Access

1. 引言

目前，基于卷积神经网络(Convolution Neural Network, CNN)模型在单图像超分辨(Single image super-resolution, SISR)方面已经取得了巨大的成功。利用深度网络模型强大学习能力，这些 CNN 模型通过训练大量参数而学习一种有效的从低分辨率(Low-Resolution, LR)到高分辨率(High-Resolution, HR)图像的非线性映射关系。超分辨率(Super-Resolution, SR)的端到端学习架构去掉了繁琐的特征提取前的图像预处理过程和后续重叠的 HR 图像聚合过程。受 Timofte [1]算法启发，Dong 等[2]最早提出利用卷积神经网络对图像进行超分辨率重构(Super Resolution Using Convolutional Neural Networks, SRCNN)，该网络省去特征提取预处理过程和后续高分辨率图像块聚合过程，利用卷积神经网络学习低分辨率到高分辨率的端到端映射关系，重构超分辨率图像。后来，Dong 等[3]在 SRCNN 方法基础上提出一种快速超分辨率(Fast Super-Resolution by Convolutional Neural Networks, FSRCNN)方法，该方法以低分辨率图像作为网络输入，通过减小特征图维度和卷积核尺寸，减少网络训练参数，提高了网络运算速度。Shi 等[4]提出一种利用亚像素卷积层的超分辨率(Super-Resolution Using Efficient Sub-Pixel CNN, ESPCN)重构方法，该方法在最后一层重新对特征图进行排列，得到高分辨率图像，大幅提高了网络运算速度。以上 CNN 模式的一个共同之处在于它们的网络层数少于 5，实验表明，这些深层结构在 4 或 5 层并没有达到更好的效果，训练更深层网络的难度导致“越深越好”思想在 SR 中实现遇到重重阻碍。2014 年生成对抗网络模型[5]被提出,该网络模型包括生成模型和判别模型。Ledig [6]将生成对抗网络应用到图像超分辨率重建上。由于是由噪声生成的图片，训练过程中存在不稳定性，得到的图片可能会和期望图片相差较大。同时受到 imagenet 中利用非常深网络成功的启发[7] [8] [9]，Kim 等[10] [11]提出两个非常深的卷积神经网络，分别是极深网络超分辨率重构(Super-Resolution Using Very Deep Convolutional Networks, VDSR)和递归网络(Deeply-Recursive Convolutional Network, DRCN)超分辨率重构。这两个网络模型均引入残差思想，使深度网络能够应用于 SR 领域。而随着深度加深，网络的感受野变得越来越宽，使网络不仅仅具备局部特

征，也能捕捉到更加全局的特征。近年，毛等[12]提出一个 30 层卷积自动编码器网络命名为 RED30 用于图像恢复，它使用对称跳过连接来帮助训练。以上三个模型学习残差图像即内插 LR (ILR)图像与真实 HR 图像的残差，然后残差图像被添加到内插 LR 图像中进行估计 HR 图像。胡等[13]提出单图像级联网络交叉网络进行超分辨率重构，但该网络结构参数巨大，不容易训练，以上几个模型优于之前介绍的深度学习方法和非 DL 方法。在 SR 中表现出“越深越好”的思想。以上网络均结构复杂，参数量巨大，网络训练难度加大。为了进一步提高网络重构性能，本文提出基于深度可分离思想的采用级联多尺度交叉网络(Cascaded Multi-scale Crossing Network, CMSC)进行超分辨率重构，在每个级联子网络中，堆叠多个多尺度交叉(MSC)模块以融合互补多尺度的信息从而有效改善跨层的信息流。同时，在每个阶段引入残差特征学习，进一步提升重建性能。为了降低网络模型参数量和计算复杂度，本文结合深度可分离卷积的思想，极大地降低了网络计算复杂度。

2. 理论基础

2.1. 卷积神经网络

典型 CNN 是一个多层的神经网络，主要由输入层、卷积层、池化层、全连接层和输出层组成，其结构如图 1 所示。

CNN 中一个典型层包含三级运算，在第一级运算中，多个卷积核并行计算产生一组线性的激活响应，第二级运算是每一个线性激活响应进行非线性激活函数处理，增加网络非线性性。对于第三级运算，利用池化层来调整某一层输出。池化函数形式多种多样。

2.2. 残差神经网络

在堆叠层上采用残差学习策略，构建残差块定义如下：

$$f(x)=F(x,\{W_i\})+x$$

其中 x 表示输入，$f(x)$ 表示输出。函数 $F(x,\{W_i\})$ 表示学到的残差映射。一个构建块如图 2 所示。

图中一个残差块包含 2 层，$F=W_2\sigma(W_1x)$，其中 σ 表示 ReLU，$f(x)+x$ 操作表示输入数据通过跳跃连接与映射进行逐像素加法，然后将获取的结果经过非线性激活函数处理。图中跳跃连接过程中并未添加额外参数量以及计算复杂度。残差函数 F 形势是灵活多变的，可以两层或者三层，甚至是更多层，若只有一层，则就退化为简单的线性函数：$y=w_ix+x$,不具有任何优势。同时，这种结构不仅可以应用到全连接层，就卷积层而言依然可以适用，$F(x,\{W_i\})$ 表示多个卷积层堆叠映射，在通道之间的两个特征图逐像素级进行求和。

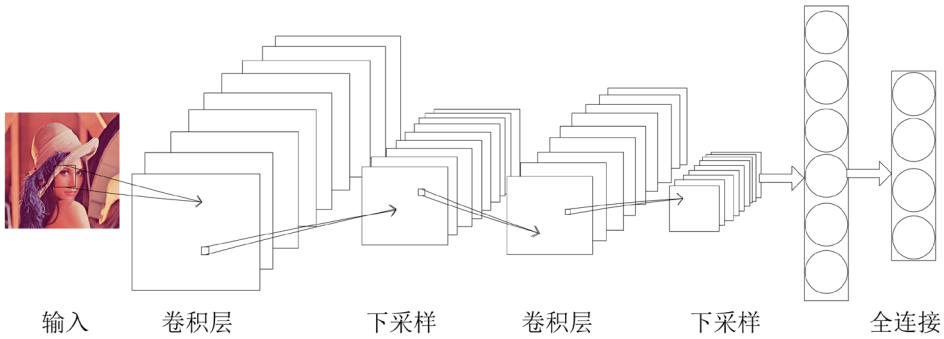

Figure 1. Diagram of convolutional neural network architecture
图 1. 卷积神经网络结构示意图

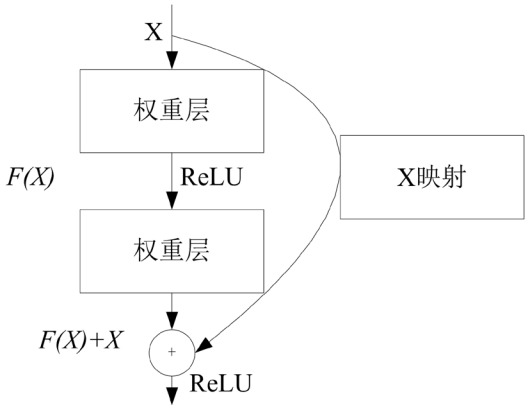

Figure 2. Residual block model
图 2. 残差块模型

3. 本文方法

3.1. 多尺度交叉模块

残差网络通过恒等映射跳跃连接模式使深度网络在图像超分辨率重构领域可以实现，同样的，为了进一步减少训练难度并提高信息流动，受在分类任务中[14]所用方法启发,考虑到不同的感受域的卷积网络的可以提供不同的上下文信息，这对 SR 来说非常重要的。本文采用 MSC 来充分获取上下文中有用信息，模块结构如图 3 所示。

在 MSC 组块有两个残差模块进行并行处理，在残差分支上，对输入进行平均处理，将处理结果传输到各自分支去，在该模块中每层卷积层采用不同大小的卷积核获取不同信息。每个残余分支在 MSC 模块中包含两个卷积层，每个卷积层之后采用 LeakyReLU [15]激活函数。此外，图 3 下面“+”运算符表示在 LeakyReLU 之前进行求和运算，而残差块交叉过程中的“+”运算符表示平均操作。由于 BN 层会致使部分细节信息丢失有价值信息，和消耗与卷积层等量内存，致使训练速度减慢，所以，本文不引入 BN 层，利用这种设计，这些分支结构可以提取到丰富的互补的背景信息，在多个尺度上进一步合并和运行组合映射。

受残差网络瓶颈结构[16]启发，本文方法采用深度可分离卷积代替残差结构中的卷积，将标准卷积分解为一个逐深度卷积和一个标准1×1卷积，逐深度卷积对应着每一个输入特征图通道，1×1标准卷积是将逐深度卷积所提取特征进行融合，可分离卷积结构示意图如图 4 所示。

图 4 可以看出，每一个通道用一个卷积核进行卷积之后，得到对应通道输出，然后再利用1×1卷积核进行特征融合，通过特征提取和特征融合分离可以有效降低计算复杂度和模型容量。

H^{b1} 和 H^{b2} 分别表示残差分支的映射函数，两个残差分支函数模块可以用矩阵形式表示如下。

$$\begin{bmatrix} x_o^{b1} \\ x_o^{b2} \end{bmatrix} = G\begin{pmatrix} x_i^{b1} \\ x_i^{b2} \end{pmatrix} = \begin{bmatrix} H^{b1}\left(x_i^{b1}\right) \\ H^{b2}\left(x_i^{b2}\right) \end{bmatrix} + \frac{1}{2}\begin{bmatrix} I & I \\ I & I \end{bmatrix}\begin{bmatrix} x_i^{b1} \\ x_i^{b2} \end{bmatrix} \tag{1}$$

其中 x_i^{b1} 和 x_i^{b2} 表示残差模块输入， x_o^{b1} 和 x_o^{b2} 是残差模块输出模块，G 表示 MSC 模块映射函数，I 表示单位映射矩阵。P 是合并和运行的转换映射矩阵。通过这种多尺度信息融合结构，MSC 模块可以利用各种各样的情境信息来推断缺失的高频信息。另一方面，转换合并运行映射中的矩阵 P 是幂等的，而 MSC 模块同样具有幂等性质，不仅有助于丰富信息流过不同的模块，也支持渐变训练期间的反向传播。

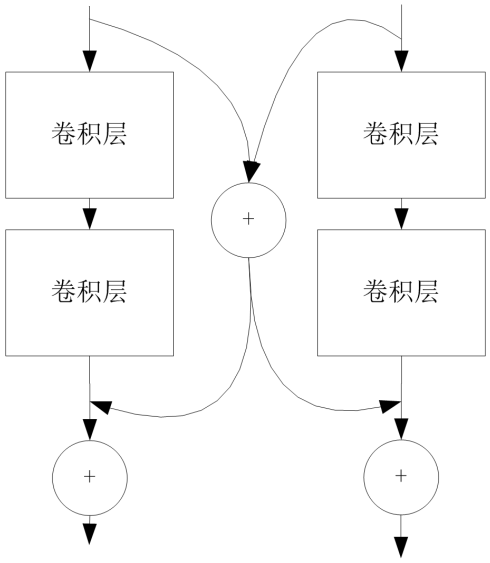

Figure 3. Diagram of cross module
图 3. 交叉模块示意图

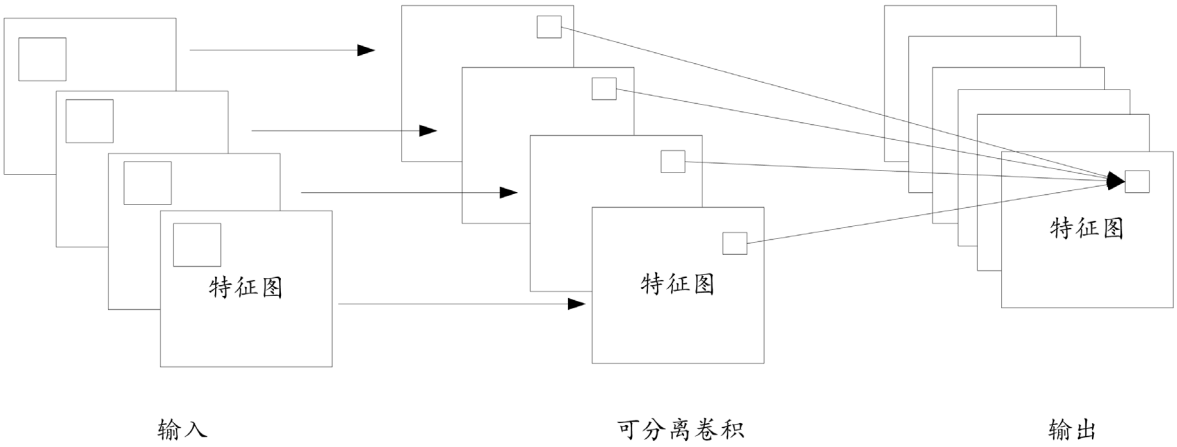

Figure 4. Diagram of depthwise separable convolution
图 4. 深度可分离卷积示意图

3.2. 残差特征子网络学习

为了提取更加高效的 HR 图像特征，本文建立了残差特征学习(residual-features learni, RFL)网络结构。网络结构如图 5 所示。

该子网络包含卷积层和一系列多尺度交叉(MSC)模块。在最后一个 MSC 模块结束时，两个分支的两个输出与它们的输入的平均值通过加法进行融合，这可以表述如下:

$$x_o = G^{last}\left(\begin{bmatrix} x_i^{b1} \\ x_i^{b2} \end{bmatrix}\right) = H^{b1}\left(x_i^{b1}\right) + H^{b2}\left(x_i^{b2}\right) + \frac{1}{2}\left(x_i^{b1} + x_i^{b2}\right) \tag{2}$$

其中 x_o 表示最后一个 MSC 模块的输出，其他符号的含义与公式(1)中的符号含义相同。子网中的第一个卷积层是用来将子网络的输入变换为指定数量的特征映射。然后，用并行和相交的结构，使用堆叠的多

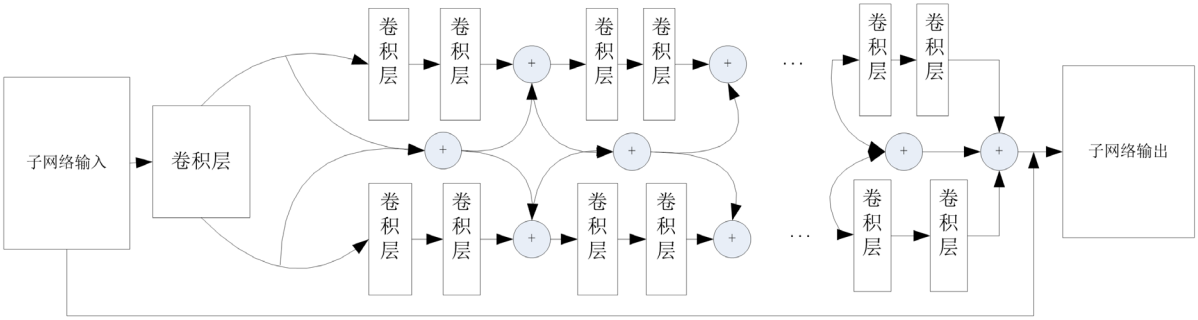

Figure 5. Residual network structure based on crossover module
图 5. 基于交叉模块的残差网络结构

尺度交叉(MSC)模块通过不同的卷积核进行处理得到不同特征信息。同时，子网中有多个并行映射用来整合来自不同分支的信息，也创造新的捷径传递中间分支信息到后面的模块中。

由于 HR 图像的特征与相应 LR 特征是高度相关的，本文子网从输入分支到子网的末端介绍残差特征通过添加恒等映射来学习。不是直接推断 HR 图像特征，而是建立子训练网络以估计 LR 和 HR 之间的残差。D_{q-1} 和 D_q 表示为第 q 个子网络的输入和输出，M 作为堆叠的 MSC 模块的数量，和 f_q 表示第一个卷积层的卷积运算。从而，第 q 个子网的输出可以表示为：

$$Dq=\varepsilon^{q}\left(D_{q-1}\right)=G^{last}\left(G^{(M-1)}\left(\begin{bmatrix} f_q\left(D_{q-1}\right) \\ f_q\left(D_{q-1}\right)\end{bmatrix}\right)\right)+D_{q-1}=G^{last}\left(G\left(\cdots G\left(\begin{bmatrix} f_q\left(D_{q-1}\right) \\ f_q\left(D_{q-1}\right)\end{bmatrix}\right)\cdots\right)\right)+D_{q-1} \tag{3}$$

其中 G 是 MSC 模块函数，在公式(1)中描述一样，G^{last} 表示最后 MSC 模块的函数，含义与公式(2)中一样。

由于存在 M 个 G 模块，每个 MSC 模块均采用并行残差结构融合不同感受域特征，因此，子网络能够捕获不同的特征并重构出超分辨率图像。

3.3. 具有级联结构的整体模型

为了重建高分辨率图像和降低获取细节信息的难度，本文建立一个级联子网络结构，利用特征提取器提取到的 LR 特征去估计 HR 特征，所有的子网络使用相同的结构，在同步监督下联合训练网络。在级联误差逐步最小化约束下，子网的每个阶段所期望估计的图像特征更接近本地真实 HR 特征。来自子网络的所有估计的 HR 特征被传输到相应的重建层来重建 HR 图像。整个模型如图 6 所示，称为级联多尺度交叉网络(CMSC)。

本文使用一层卷积层提取图像特征，然后使用 LeakyReLU 层为特征引入非线性因素从而提取更加有效的输入 LR 图像的特征，特征提取网络表示如下。

$$D_O=F\left(X\right) \tag{4}$$

其中 F 表示特征提取网络的操作，D_O 是提取到的特征图，然后将提取的特征图送入子网的第一阶段。假设有 S 个交叉残差子网级联后逐步推断高分辨率图像特征，推理过程是表示如下。

$$D_s=\varepsilon^{s}\left(\varepsilon^{s-1}\left(\cdots\left(\varepsilon^{1}\left(D_O\right)\right)\cdots\right)\right) \tag{5}$$

$\varepsilon^{q}\left(q=1,2,\cdots,S\right)$ 表示第 q 个函数子网络，如公式(3)所定义。为了使这个从每个级联子网络输出更接近地面真相高分辨率图像特征，本文同步监督级联的所有观测子网络。每个子网输出均被传入到重构网络，在重构层，将每个阶段网络输出作为输入传入到卷积层中重构出相应 HR 残差图像，因此产生来自

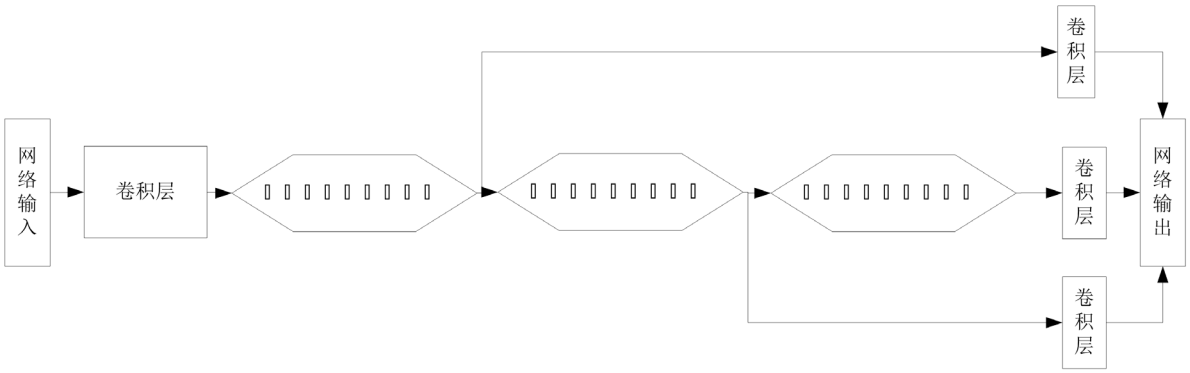

Figure 6. Cascading network structure
图 6. 级联网络结构

级联阶段的中间估计图像，如图 4 所示。本文采用了全局残差学习(Global residual learning, GRL)，网络通过从输入添加恒等映射分支到重建网络进而重建出 HR 图像。因此，第 $q\left(q=1,2,\cdots,S\right)$ 中间预测表示为：

$$\hat{y}_q = R_q\left(D_q\right) + x \tag{6}$$

其中 D_q 是第 q 阶段的输出特征，R_q 表示为相应的重建层。然后，通过加权平均将所有 S 中间估计进行汇总生成最终 HR 图像，该过程表示为：

$$\hat{y} = \sum_{q=1}^{s} w_q.\hat{y}_q \tag{7}$$

其中 w_q 表示第 q 个估计子网的权重。上述等式中的所有权重在训练期间的学习过程均属于监督学习过程。

给定一组训练集 $\left\{x^{(i)}, y^{(i)}\right\}_{i=1}^{N}$，超分辨率学习目标使获得一个映射 f 去预测相应 HR 图像，表示为：$\hat{y} = f\left(x\right)$, 其中，$\hat{y}$ 是估计出的 HR 图像。本文模型的损失函数定义为：

$$L\left(\theta\right) = \alpha\sum_{K=1}^{K}\frac{1}{2K}\left\|y^{(k)} - \sum_{q=1}^{s} w_q.\hat{y}_q^{(k)}\right\|^2 + \left(1-\alpha\right).\sum_{\alpha=1}^{s}\sum_{k=1}^{k}\frac{1}{2SK}\left\|y^{(k)} - \hat{y}_q^{(k)}\right\|^2 \tag{8}$$

其中 θ 表示参数集。α 平衡网络输出，当网络的深度被定义为最长的路径时，从输入到输出，整体模型的深度可以计算为：

$$D_{epth} = \left(M \times 2 + 1\right) \times S + 2 \tag{9}$$

其中 S 和 M 表示级联子网的数量以及每个子网中 MSC 模块的数量。2 乘以 M 表示两个卷积层。在 MSC 模块的一个分支中，括号中的 1 表示每个子网络中的第一个卷积层。公式中最后加 2 表示两个卷积层分别进行特征提取和网络重构重构。

4. 实验结果

文在 Timofte 数据集中进行超分辨率重构。为防止网络过拟合，采用尺度缩放和旋转两种方式对训练图像进行增强。具体地，对在数据集中每幅图像进行降采样，缩放到原图像尺寸的 0.6、0.7、0.8、0.9 倍。然后将数据集中图像按顺时针分别旋转 90˚、180˚、270˚。通过图像尺度缩放和旋转处理后，原数据库扩增 20 倍。

为得到满足要求的低分辨率图像及增强网络对不同尺度超分辨率的泛化能力，网络训练前，本文对增强后数据集进行尺度变换预处理，将不同尺度因子作用下的数据集混合在一起作为网络输入训练得到

的模型，不仅支持多种尺度因子图像超分辨率重构，并且在多种尺度因子的情况下参数共享。

实验结果与分析

本文采用峰值信噪比(Peak Signal to Noise Ratio，PSNR)对重构算法进行评价，假设输入图像表示为 $f(x,y)$，其大小为 $M\times N$。$g(x,y)$ 表示估计图像，期望其尽可能逼近与输入图像 $f(x,y)$，定义 MSE 为：

$$MSE=\frac{1}{M\times N}\sum_{x=0}^{M-1}\sum_{y=0}^{N-1}\left[g(x,y)-f(x,y)\right]^2 \tag{10}$$

PSNR 表示为：

$$PSNR=10\times\log\left(255^2/MSE\right)\ (\mathrm{dB}) \tag{11}$$

PSNR 值越大，说明图像失真越小，重构效果越好。

为测验所提图像 SR 方法有效性，本文实验在 SR 领域中基准测试集 Set5、Set14、BSD100 上进行测试，并将测试结果与 Bicubic、A+ [5]、SRCNN [1]、FSRCNN [3]、VDSR [10]等主流方法进行对比。

从表 1 可看出，本文方法针对不同测试集进行超分辨率重构均能获得较好的实验效果，表明本文所提网络泛化能力较好。现有主流方法存在网络可重用性较差，需分别训练针对不同尺度因子网络，而本文网络适用多尺度超分辨率重构，具有可增强网络泛化能力的优点。同时，本文算法重构效果优于其他主流超分辨率重构算法。

5. 结论

本文研究了一个深度级联多尺度跨网络(CMSC)并进行超分辨率重建，级联一系列子网以级联监督形式逐步改善高分辨率特征。在每个级联子网，多个多尺度交叉(MSC)模块堆叠不仅用于融合补充不同感受域信息，也提高信息流跨越层。此外，要充分利用相关信息高分辨率和低分辨率功能之间，残差特征学习被引入到级联子网络中进一步提升重构性能。虽然深度可分离卷积能够减少网络模型及计算复杂度，由于所有阶段 CMSC 中的子网都有相同的结构和相同的目标，跨越级联模型有可能采用递归连接方式进行改善，实现网络参数共享。在未来的工作中，将探索如何共享级联内参数，从而控制模型参数。另一方面，将 CMSC 模型扩展到其他图像退化领域。

致　谢

基金支持：国家基金项目 No. 61372193，No. 61771347；广东高校优秀青年教师培训计划资助项目

Table 1. Average PSNR comparison of super resolution algorithm on the Set5, Set14, B100 datasets
表 1. 超分辨率算法在 Set5、Set14、B100 数据集上 PSNR 平均值

数据集	尺度因子	双三次插值	A+ [1]	SRCNN [2]	FSRCNN [3]	VDSR [10]	本文方法
Set5	3	30.29	32.59	32.35	33.06	33.66	34.24
Set14	3	27.54	29.13	29.01	29.37	29.78	30.09
B100	3	27.21	28.36	28.21	28.41	28.83	29.01
Set5	4	28.42	30.28	30.15	30.55	31.53	31.91
Set14	4	26.00	27.32	27.44	27.50	28.02	28.35
B100	4	25.96	26.83	26.69	26.90	27.29	27.46

No. SYQ2014001；广东省特色创新项目 No. 2015KTSCX143，2015KTSCX145，2015KTSCX148；广东省青年创新项目 No. 2015KQNCX172，No. 2016KQNCX171，江门市科技计划项目 No. 201501003001556，No. 201601003002191.

参考文献

[1] Timofte, R., Smet, V.D. and Gool, L.V. (2014) A+: Adjusted Anchored Neighborhood Regression for Fast Super-Resolution. Computer Vision—ACCV 2014. Springer International Publishing, 111-126.

[2] Dong, C., Chen, C.L., He, K., *et al.* (2014) Learning a Deep Convolutional Network for Image Super-Resolution. Computer Vision—ECCV 2014. Springer International Publishing, 184-199.

[3] Dong, C., Chen, C.L. and Tang, X. (2016) Accelerating the Super-Resolution Convolutional Neural Network. European Conference on Computer Vision. Springer: Cham, 391-407.

[4] Shi, W., Caballero, J., Huszar, F., *et al.* (2016) Real-Time Single Image and Video Super-Resolution Using an Efficient Sub-Pixel Convolutional Neural Network. 1874-1883.

[5] Goodfellow, I.J., Pouget-Abadie, J., Mirza, M., *et al.* (2014) Generative Adversarial Nets. *International Conference on Neural Information Processing Systems*, MIT Press, 2672-2680.

[6] Ledig, C., Wang, Z., Shi, W., *et al.* (2016) Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network. *IEEE Conference on Computer Vision and Pattern Recognition* (*CVPR*), Honolulu, 21-26 July 2017, 105-114.

[7] He, K., Zhang, X., Ren, S., *et al*. (2015) Deep Residual Learning for Image Recognition. *Computer Vision and Pattern Recognition*, **1**, 770-778.

[8] Simonyan, K. and Zisserman, A. (2014) Very Deep Convolutional Networks for Large-Scale Image Recognition. Computer Science. arXiv:1409.1556 [cs.CV]

[9] Szegedy, C., Liu, W., Jia, Y., *et al.* (2015) Going Deeper with Convolutions. *IEEE Conference on Computer Vision and Pattern Recognition*, Boston, 7-12 June 2015, 1-9.

[10] Kim, J., Lee, J.K. and Lee, K.M. (2015) Accurate Image Super-Resolution Using Very Deep Convolutional Networks. *IEEE Conference on Computer Vision and Pattern Recognition* (*CVPR*), Las Vegas, 27-30 June 2016, 1646-1654.

[11] Kim, J., Lee, J.K. and Lee, K.M. (2015) Deeply-Recursive Convolutional Network for Image Super-Resolution. *IEEE Conference on Computer Vision and Pattern Recognition* (*CVPR*), Las Vegas, 27-30 June 2016, 1637-1645.

[12] Mao, X.J., Shen, C. and Yang, Y.B. (2016) Image Restoration Using Very Deep Convolutional Encoder-Decoder Networks with Symmetric Skip Connections. arXiv:1603.09056.

[13] Hu, Y., Gao, X., Li, J., *et al*. (2018) Single Image Super-Resolution via Cascaded Multi-Scale Cross Network. arXiv: 1802.08808.

[14] Zhao, L., Wang, J., Li, X., *et al*. (2016) Deep Convolutional Neural Networks with Merge-and-Run Mappings. arXiv: 161107718.

[15] Maas, A.L., Hannun, A.Y. and Ng, A.Y. (2013) Rectifier Nonlinearities Improve Neural Network Acoustic Models. *Proceedings of the* 30*th International Conference on Machine Learning*, Atlanta, Jun.

[16] He, K., Zhang, X., Ren, S., *et al*. (2015) Deep Residual Learning for Image Recognition. *IEEE Conference on Computer Vision and Pattern Recognition* (*CVPR*), Las Vegas, 27-30 June 2016, 770-778.

Hans 汉斯

知网检索的两种方式：

1. 打开知网页面 http://kns.cnki.net/kns/brief/result.aspx?dbPrefix=WWJD
   下拉列表框选择：[ISSN]，输入期刊 ISSN：2325-6753，即可查询
2. 打开知网首页 http://cnki.net/
   左侧“国际文献总库”进入，输入文章标题，即可查询

投稿请点击：http://www.hanspub.org/Submission.aspx
期刊邮箱：jisp@hanspub.org