

多级跳线连接的深度残差网络超分辨率重建

赵小强^{*①②③} 宋昭漾^①

^①(兰州理工大学电气工程与信息工程学院 兰州 730050)

^②(甘肃省工业过程先进控制重点实验室 兰州 730050)

^③(兰州理工大学国家级电气与控制工程实验教学中心 兰州 730050)

摘要: 由于快速的卷积神经网络超分辨率重建算法(FSRCNN)卷积层数少、相邻卷积层的特征信息之间缺乏关联性,因此难以提取到图像深层信息导致图像超分辨率重建效果不佳。针对此问题,该文提出多级跳线连接的深度残差网络超分辨率重建方法。首先,该方法设计了多级跳线连接的残差块,在多级跳线连接的残差块基础上构造了多级跳线连接的深度残差网络,解决相邻卷积层的特性信息缺乏关联性的问题;然后,使用随机梯度下降法(SGD)以可调节的学习率策略对多级跳线连接的深度残差网络进行训练,得到该网络超分辨率重建模型;最后,将低分辨率图像输入到多级跳线连接的深度残差网络超分辨率重建模型中,通过多级跳线连接的残差块得到预测的残差特征值,再将残差图像和低分辨率图像组合在一起转化为高分辨率图像。该文方法与bicubic, A+, SRCNN, FSRCNN和ESPCN算法在Set5和Set14测试集上进行了对比测试,在视觉效果和评价指标数值上该方法都优于其它对比算法。

关键词: 超分辨率重建; 深度残差网络; 多级跳线连接的残差块; 随机梯度下降法

中图分类号: TP391

文献标识码: A

文章编号: 1009-5896(2019)10-2501-08

DOI: [10.11999/JEIT190036](https://doi.org/10.11999/JEIT190036)

Super-Resolution Reconstruction of Deep Residual Network with Multi-Level Skip Connections

ZHAO Xiaoqiang^{①②③} SONG Zhaoyang^①

^①(College of Electrical Engineering and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China)

^②(Key Laboratory of Gansu Advanced Control for Industrial Processes, Lanzhou University of Technology, Lanzhou 730050, China)

^③(National Experimental Teaching Center of Electrical and Control Engineering, Lanzhou University of Technology, Lanzhou 730050, China)

Abstract: The Fast Super-Resolution Convolutional Neural Network algorithm (FSRCNN) is difficult to extract deep image information due to the small number of convolution layers and the correlation lack between the feature information of adjacent convolutional layers. To solve this problem, a deep residual network super-resolution reconstruction method with multi-level skip connections is proposed. Firstly, a residual block with multi-level skip connections is designed to solve the problem that the characteristic information of adjacent convolutional layers lacks relevance. A deep residual network with multi-level skip connections is constructed on the basis of the residual block. Then, the deep residual network connected to the multi-level skip is trained by using the adaptive gradient rate strategy of Stochastic Gradient Descent (SGD) method and the network super-resolution reconstruction model is obtained. Finally, the low-resolution image is input into the deep residual network super-resolution reconstruction model with the multi-level skip connections, and the residual eigenvalue is obtained by the residual block connected the multi-level skip connections. The residual eigenvalue

收稿日期: 2019-01-15; 改回日期: 2019-06-30; 网络出版: 2019-07-19

*通信作者: 赵小强 xqzhao@lut.cn

基金项目: 国家自然科学基金(61763029, 61873116)

Foundation Items: The National Natural Science Foundation of China (61763029, 61873116)

and the low resolution image are combined and converted into a high resolution image. The proposed method is compared with the bicubic, A+, SRCNN, FSRCNN and ESPCN algorithms in the Set5 and Set14 test sets. The proposed method is superior to other comparison algorithms in terms of visual effects and evaluation index values.

Key words: Super-resolution reconstruction; Deep residual network; Residual network with multi-level skip connections; Stochastic Gradient Descent (SGD)

1 引言

在卫星图像^[1]、医学成像^[2]、人脸识别^[3]等应用领域中,为了得到图像丰富的细节信息,需要对模糊不清的低分辨率(Low Resolution, LR)图像进行处理得到清晰的高分辨率(High Resolution, HR)图像,其中最常用的处理办法是运用图像超分辨率重建技术。随着人工智能^[4,5]的快速发展,超分辨率重建技术也在计算机视觉领域^[6]应用得越来越广泛,同时在计算机视觉的发展带动下,超分辨率重建技术^[7,8]变得越来越重要。

超分辨率重建技术在众多科研工作者的努力研究中取得快速发展,出现了基于插值和基于重建的方法^[9]。例如:双线性插值方法^[10]、双立方插值方法^[11]、凸集投影方法^[12]和最大后验概率方法^[13]等等。虽然基于插值^[14]的方法提高了图像的清晰度,但是存在较严重的震荡问题;而基于重建^[15]的方法需要充分的先验知识,随着放大因子的增加,即使增加低分辨率图像以提供更丰富的先验知识,也很难对图像高频信息进行重建,甚至会造成图像平滑问题。

近年来,随着深度学习^[16,17]的快速发展,卷积神经网络(Convolutional Neural Network, CNN)在图像处理领域内被广泛应用,Dong等人^[18]提出了基于卷积神经网络的超分辨率重建算法(Super-Resolution Convolutional Neural Network, SRCNN),在SRCNN算法中,将超分辨率重建过程分为图像块提取、非线性映射和图像重建3个部分,该算法将这3个部分统一到1个3层的卷积神经网络中,实现从低分辨率图像到高分辨率图像端到端的学习,使得图像重建效果相比传统方法得到了较大提高。但是SRCNN算法仅仅使用3个卷积层提取到的图像信息有限,难以获得图像深层次的特征信息。为了解决这个问题,Dong等人^[19]又提出了基于快速的卷积神经网络超分辨率重建算法(Fast Super-Resolution Convolutional Neural Network, FSRCNN),相对比SRCNN算法,在低分辨率图像上采样操作中,FSRCNN算法使用反卷积层代替双三次插值,在卷积神经网络结构设计上,FSRCNN算法不仅使用大小为 3×3 卷积核,而且将卷积层增

加到8层。虽然使用FSRCNN算法得到的重建效果优于SRCNN算法,但是采用8个卷积层的网络结构提取到的图像深层信息依然有限。Kim等人^[20]提出了基于递归神经网络的超分辨率重建算法(Deeply-Recursive Convolutional Network for Image super-Resolution, DRCN),DRCN算法将递归神经网络结构应用在超分辨率重建中,并利用残差学习加深了网络层数,增加了网络感受野,提高了重建性能。Shi等人^[21]提出了基于亚像素卷积的神经网络超分辨率重建算法(Efficient Sub-Pixel Convolutional Neural Network for Image Super-Resolution, ESPCN),该算法直接在低分辨率图像块上进行特征提取,然后用亚像素卷积对提取得到的特征进行上采样,减少了重建过程的计算复杂度,增加了重建的效率。Ledig等人^[22]提出了基于生成对抗网络的超分辨率重建算法(Super-Resolution Generative Adversarial Network, SRGAN),该算法将生成对抗网络结构应用到超分辨率重建中,并利用感知损失和对抗损失作为损失函数,使得重建的效果更逼真。虽然应用深度神经网络结构在超分辨率重建技术上能够得到更多的图像信息,获得较好的效果,但是为了提取图像深层次信息,只通过简单的堆叠卷积层来构建深度神经网络,会导致训练深度卷积神经网络变得困难,并出现梯度消失和梯度爆炸等问题。同时深度神经网络的卷积层都只是对前一个卷积层的特征向量进行卷积计算,没有利用相邻两个卷积层特征信息之间的相关性,使得在重建过程中图像区域上下文信息缺乏关联。

本文为了解决以上问题,提出多级跳线连接的深度残差网络超分辨率重建方法。首先,本文设计了多级跳线连接的残差块,该残差块是由2个子残差块和 β 倍跳线连接组成,其中子残差块由1个卷积层和 λ 倍跳线连接组成。在多级跳线连接的残差块基础上构造了多级跳线连接的深度残差网络。然后,使用随机梯度下降法(Stochastic Gradient Descent, SGD)以可调节的学习率策略对多级跳线连接的深度残差网络进行训练,得到该网络超分辨率重建模型。最后,使用多级跳线连接的深度残差网络超分辨率重建模型对测试集的低分辨率图像进

行重建, 得到的重建图像不仅拥有更好的视觉效果, 而且具有更高的评价指标数值。

2 残差学习

He等人^[23]在2016年首次提出残差网络。残差网络解决了构建深度神经网络时出现模型退化的问题。残差网络是由多个残差块通过端对端首尾相连组合而成, 残差块结构图如图1所示。

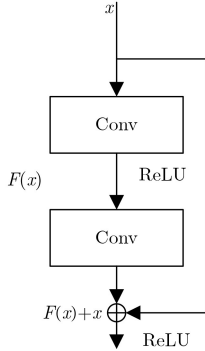


图1 残差块结构图

残差块函数定义为

$$\mathbf{y} = F(\mathbf{x}, \{W_i\}) + \mathbf{x} \quad (1)$$

其中, \mathbf{x} 表示为残差块的输入向量, \mathbf{y} 表示为残差块的输出向量, 函数 $F(\mathbf{x}, \{W_i\})$ 表示要学习的残差映射。图1中的残差块包含了两个卷积层, 即残差函数为 $F = W_2(W_1(\mathbf{x}))$, 其中为了简化表示而省略了偏差。输入向量 \mathbf{x} 通过跳线连接与残差函数 $F(\mathbf{x})$ 相加得到残差块函数 \mathbf{y} 为

$$\mathbf{y} = W_2(W_1(\mathbf{x})) + \mathbf{x} \quad (2)$$

在残差块中, 输入向量 \mathbf{x} 与残差函数 $F(\mathbf{x})$ 的尺寸必须相等。

假设深度神经网络后面的卷积层是恒等映射, $H(\mathbf{x})$ 表示恒等映射函数, 那么训练深度神经网络就简化成学习一个恒等映射函数。如果直接让卷积层去拟合一个恒等映射函数 $H(\mathbf{x}) = \mathbf{x}$ 会比较困难, 但是把深度神经网络设计为 $H(\mathbf{x}) = F(\mathbf{x}) + \mathbf{x}$, 那么训练深度神经网络就可以转换为学习残差函数 $F(\mathbf{x}) = H(\mathbf{x}) - \mathbf{x}$, 只要 $F(\mathbf{x}) = 0$ 时, 就相当于拟合恒等映射函数 $H(\mathbf{x}) = \mathbf{x}$ 。在相同的计算条件下, 让前面卷积层拟合残差函数 $F(\mathbf{x}) = H(\mathbf{x}) - \mathbf{x}$ 比拟合恒等映射函数 $H(\mathbf{x}) = \mathbf{x}$ 容易。

3 多级跳线连接的深度残差网络

3.1 多级跳线连接的残差块

深度神经网络的卷积层都只是对前一个卷积层的特征向量进行卷积计算, 没有利用相邻两个卷积层特征信息之间的相关性, 从而导致图像区域上下

文信息缺乏关联。为了解决此问题, 本文设计了多级跳线连接的残差块, 其结构图如图2所示。

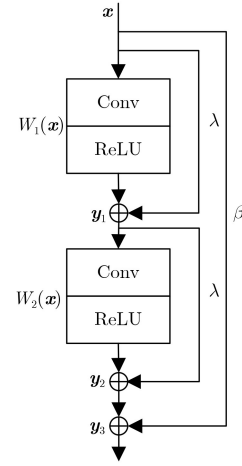


图2 多级跳线连接的残差块结构图

在图2中, 1个卷积层和 λ 倍跳线连接组成1个子残差块, 2个子残差块和 β 倍跳线连接组成1个多级跳线连接的残差块。假设多级跳线连接的残差块输入为 \mathbf{x} , 经过第1个子残差块得到的输出为 \mathbf{y}_1 , 经过第2个子残差块得到的输出为 \mathbf{y}_2 , 经过多级跳线连接的残差块得到的输出为 \mathbf{y}_3 , 则输出

$$\mathbf{y}_1 = W_1(\mathbf{x}) + \lambda \mathbf{x} \quad (3)$$

$$\begin{aligned} \mathbf{y}_2 &= W_2(\mathbf{y}_1) + \lambda \mathbf{y}_1 \\ &= W_2(W_1(\mathbf{x}) + \lambda \mathbf{x}) + \lambda W_1(\mathbf{x}) + \lambda^2 \mathbf{x} \end{aligned} \quad (4)$$

$$\begin{aligned} \mathbf{y}_3 &= \mathbf{y}_2 + \beta \mathbf{x} \\ &= W_2(W_1(\mathbf{x}) + \lambda \mathbf{x}) + \lambda W_1(\mathbf{x}) + (\lambda^2 + \beta) \mathbf{x} \end{aligned} \quad (5)$$

从输出 \mathbf{y}_3 可以分析出, 当输入 \mathbf{x} 经过多级跳线连接的残差块不仅得到 $W_2(W_1(\mathbf{x}))$ 值(本文第1节的残差函数值), 而且得到第1个子残差块的输出值 $\lambda \mathbf{y}_1$ 。所以多级跳线连接的残差块能够提取残差块内部卷积层特征向量的相关信息。

当相邻两个多级跳线的残差块连接在一起的结构图如图3所示, 在图3中, 第3个子残差块的输出 \mathbf{y}_4 为

$$\begin{aligned} \mathbf{y}_4 &= W_3(\mathbf{y}_3) + \lambda \mathbf{y}_3 \\ &= W_3(\mathbf{y}_2 + \beta \mathbf{x}) + \lambda(W_2(\mathbf{y}_1) + \lambda^2 W_1(\mathbf{x})) \\ &\quad + (\lambda^3 + \lambda\beta) \mathbf{x} \end{aligned} \quad (6)$$

第4个子残差块的输出 \mathbf{y}_5 为

$$\begin{aligned} \mathbf{y}_5 &= W_4(\mathbf{y}_4) + \lambda \mathbf{y}_4 \\ &= W_4(\mathbf{y}_4) + \lambda W_3(\mathbf{y}_2 + \beta \mathbf{x}) + \lambda^2(W_2(\mathbf{y}_1)) \\ &\quad + \lambda^3 W_1(\mathbf{x}) + (\lambda^4 + \lambda^2\beta) \mathbf{x} \end{aligned} \quad (7)$$

则第2个多级跳线链接的残差块输出 \mathbf{y}_6 为

$$\begin{aligned}
 \mathbf{y}_6 &= \mathbf{y}_5 + \lambda \mathbf{y}_3 \\
 &= W_4(\mathbf{y}_6) + \lambda W_3(\mathbf{y}_2 + \beta \mathbf{x}) + (\lambda^2 + \beta)(W_2(\mathbf{y}_1)) \\
 &\quad + (\lambda^3 + \lambda\beta)W_1(\mathbf{x}) + (\lambda^2 + \beta)^2 \mathbf{x} \tag{8}
 \end{aligned}$$

从输出 \mathbf{y}_6 中可以分析出，相邻两个多级跳线连接的残差块的每一个卷积层输出值都对前面每个卷积层的特征向量进行卷积，充分利用了相邻残差块内部卷积层特征向量的相关信息，所以该残差块能够提取到更多的特征信息。

3.2 多级跳线连接的深度残差网络

为了提取图像深层信息，同时在训练网络时避免出现梯度消失和梯度爆炸等问题，本文设计了一个多级跳线连接的深度残差网络。该网络总共有18个卷积层，其主要是由8个多级跳线连接的残差块(16个子残差块)端对端的连接组成，该网络结构图如图4所示。在图4中，将低分辨率图像输入到网络中，通过多个多级跳线连接的残差块得到预测的残差特征值，然后将残差特征值和低分辨率图像值组合在一起转化为高分辨率图像值。本文方法使用的激活函数是ReLU，在多级跳线连接的深度残差网络计算过程中，如果采用不同的残差函数

$$F(\mathbf{x}) = \max(0, W_i^* \mathbf{x} + B_i) \tag{9}$$

则由于众多的参数会增加网络计算复杂度，从而导致网络训练速度变慢，所以本文采用相同的残

差函数。即 W_i 为 $64 \times 3 \times 3 \times 64$ 的滤波器， B_i 为64维的偏差。网络输入卷积层的滤波器大小为 $1 \times 3 \times 3 \times 64$ ，网络输出卷积层的滤波器大小为 $64 \times 3 \times 3 \times 1$ 。为了保证通过卷积计算之后的特征图与输入卷积层的特征图保持相同的尺寸，本文设置网络所有卷积层的移动步长为1，填充为1，该网络残差块的跳线连接参数分别为 $\lambda = 0.1, \beta = 0.1$ 。

3.3 训练

本文方法使用均方误差函数(Mean Square Error, MSE)作为损失函数来估计网络参数 θ 。均方误差函数为

$$L(\theta) = \frac{1}{n} \sum_{i=1}^n \|G(Y_i, \theta) - X_i\|^2 \tag{10}$$

通过最小化重建的图像与对应的真实高分辨率图像的损失来估计参数 θ 。其中 $G(Y_i, \theta)$ 表示重建的图像， X_i 表示高分辨率图像样本， Y_i 表示对应的低分辨率图像样本， n 为训练样本的数量， $G(\cdot)$ 表示多级跳线连接的深度残差网络函数。

本文方法采用随机梯度下降算法(SGD)对多级跳线连接的深度残差网络进行优化训练。随机梯度下降算法更新参数 θ 的表达形式为

$$\nabla L(\theta_i^l) = \frac{\partial L}{\partial \theta_i^l} \tag{11}$$

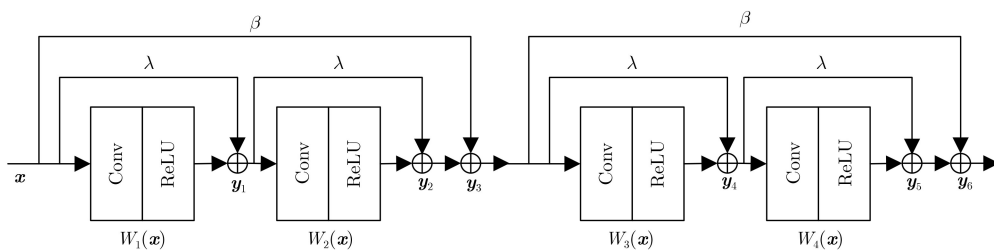


图3 相邻两个多级跳线连接的残差块结构图

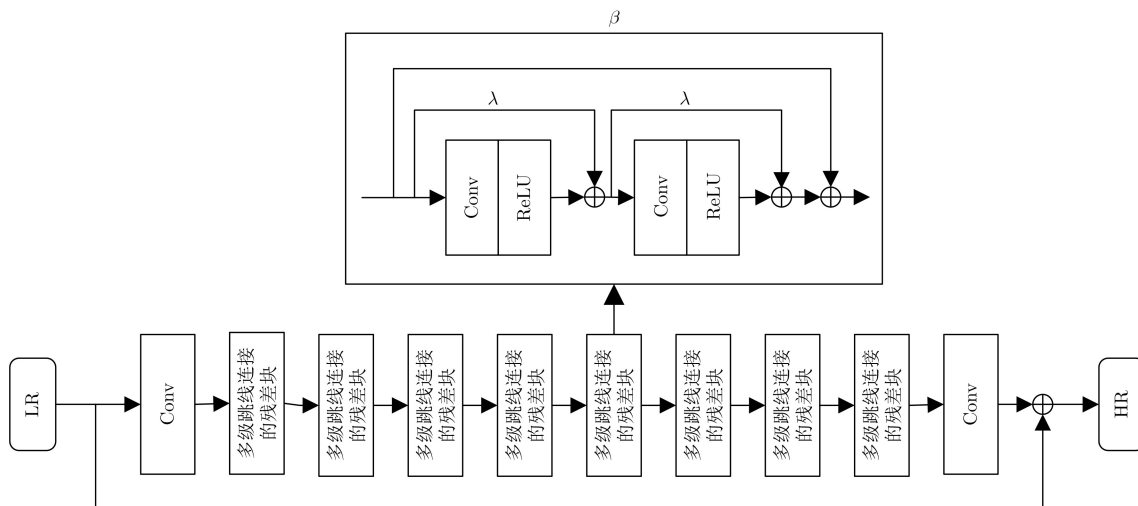


图4 多级跳线连接的深度残差网络结构图

$$\Delta_{i+1} = \mu\Delta_i - \eta\nabla L(\theta_i^l) \quad (12)$$

$$\theta_{i+1}^l = \theta_i^l + \Delta_{i+1} \quad (13)$$

其中, l 表示为卷积层号, i 表示为迭代次数, μ 表示为前一次的迭代权重且 $\mu \in [0, 1]$, η 表示为学习率。在训练多级跳线连接的深度残差网络时, 本文方法使用了可调节的学习率策略, 大大缩短了网络训练时间。训练开始时设置为较大的学习率, 然后每隔一段固定的时间, 减小学习率继续训练, 当学习率减小到设定的数值后保持不变。多级跳线连接的深度残差网络训练的具体步骤如下所示:

步骤 1 选择训练集并对训练集图片进行数据增强处理;

步骤 2 设置每一批次训练样本的数量值 n , 输入训练样本 X_i ;

步骤 3 设置 μ 的值和可调节的学习率策略;

步骤 4 根据设置训练多级跳线连接的深度残差网络;

(1) 采用均值是0、标准差是0.001的高斯分布初始化参数 θ ;

(2) 根据式(10), 计算 $L(\theta)$ 的值;

(3) 根据式(11)—式(13), 更新参数 θ 值, 直到获得所有的卷积层参数后结束;

步骤 5 若网络模型具有较好的训练精度和收敛性能, 则保留此时的网络模型参数。反之, 返回步骤3。

4 实验仿真和结果分析

4.1 实验准备

本文实验使用公开的训练集T91^[24]和BSDS200^[24], 两个训练集图片共有291张, 用Matlab对T91和BSDS200训练集图片通过旋转(0°, 90°, 180°, 270°)和比例缩放(0.8, 0.9, 1.0)的方式进行数据增强。

本文实验所用的深度学习框架为pytorch-cuda9-cudnn7, 在搭载GPU为GTX1080Ti的服务器实验环境下使用Python3.6实现仿真。

本文用峰值信噪比(Peak Signal to Noise Ratio, PSNR)^[25]和结构相似度(Structural SIMilarity, SSIM)^[26]来客观评价本文实验的重建图像质量。PSNR和SSIM指标的计算公式如式(14)和式(15)所示

$$\text{PSNR} = 10 \lg \frac{MN}{\|f - \hat{f}\|^2} \quad (14)$$

$$\text{SSIM} = \frac{(2\mu_f\mu_{\hat{f}} + C_1)(\sigma_{f\hat{f}} + C_2)}{(\mu_f^2 + \mu_{\hat{f}}^2 + C_1)(\sigma_f^2 + \sigma_{\hat{f}}^2 + C_2)} \quad (15)$$

其中, M, N 表示为图像的尺寸, f 表示为真实的高

分辨率图像, \hat{f} 表示为重建的高分辨率图像, μ_f 和 $\mu_{\hat{f}}$ 分别表示为真实高分辨率图像和重建图像的平均灰度值, σ_f 和 $\sigma_{\hat{f}}$ 分别表示为真实高分辨率图像和重建图像的方差, $\sigma_{f\hat{f}}$ 表示为真实高分辨率图像和重建图像的协方差, C_1 和 C_2 为常数。

4.2 训练过程

在多级跳线连接的深度残差网络中参数的初始化为均值是0、标准差是0.001的高斯分布, 偏差的初始化设置为0。该网络总共训练了60个epoch, 为了加快训练速度, 本文采用可调节的学习率策略训练网络。初始学习率设置为0.1, 学习率每隔10个epoch降为原来学习率的0.1倍, 学习率降为0.0001时, 随后一直保持为0.0001, 批大小设置为128。图5为跳线系数分别为 $\beta = \lambda = 0.1$ 和 $\beta = \lambda = 0.2$ 的网络超分辨率模型在放大因子为2的情况下对Set5测试集进行测试得到的峰值信噪比(PSNR)曲线。从图5可以看出, 使用跳线系数 $\beta = \lambda = 0.1$ 的网络重建模型重建的效果明显优于使用bicubic算法和跳线系数 $\beta = \lambda = 0.2$ 的网络重建模型。

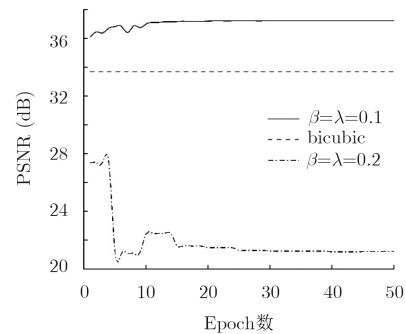


图5 不同跳线系数测得的峰值信噪比(PSNR)曲线

4.3 实验结果分析

为了客观地比较算法的优劣, 实验依次使用bicubic^[27], A+^[28], SRCNN^[18], FSRCNN^[19], ESPCN^[21]算法和本文方法作对比, 分别在放大因子为2, 3, 4的情况下对Set5测试集和Set14测试集^[29]进行了对比测试。在Set5测试集上的对比测试结果如表1所示, 在表1中, 本文方法相比Bicubic, A+, SRCNN, FSRCNN, ESPCN算法得到的平均PSNR和SSIM值在放大因子为2, 3, 4的情况下都有了很大提升。本文方法与FSRCNN算法相比, 获得的平均PSNR值提高了0.35 dB, 与Bicubic算法相比, 获得的平均PSNR值提高了4.29 dB。在Set14测试集上的对比测试结果如表2所示。类似地, 本文方法与Bicubic, A+, SRCNN, FSRCNN, ESPCN算法相比, 在放大因子为2, 3, 4的情况下获得的平均PSNR和SSIM值都得到了很大提升。

表1 在Set5测试集上的测得的PSNR(dB)/SSIM值

放大因子	Bicubic ^[27]	A+ ^[28]	SRCNN ^[18]	FSRCNN ^[19]	ESPCN ^[21]	本文方法
2	33.66/0.9299	36.54/0.9544	36.66/0.9542	37.00/0.9558	37.06/0.9559	37.35/0.9573
3	30.39/0.8682	32.58/0.9088	32.75/0.9090	33.16/0.9104	33.13/0.9135	33.45/0.9162
4	28.42/0.8104	30.28/0.8603	30.48/0.8628	30.71/0.8657	30.90/0.8673	31.07/0.8751

表2 在Set14测试集上的测得的PSNR(dB)/SSIM值

放大因子	Bicubic	A+	SRCNN	FSRCNN	ESPCN	本文方法
2	30.24/0.8688	32.28/0.9056	32.42/0.9063	32.63/0.9088	32.75/0.9098	33.34/0.9143
3	27.55/0.7742	29.13/0.8188	29.28/0.8209	29.43/0.8242	29.49/0.8271	30.09/0.8512
4	26.00/0.7027	27.32/0.7491	27.49/0.7503	27.59/0.7535	27.73/0.7637	28.26/0.7893

使用本文方法, Bicubic, A+, SRCNN, FSRCNN和ESPCN算法在Set5测试集上重建图片如图6所示。从图6可以看出, 使用本文方法, SRCNN, FSRCNN和ESPCN算法重建的baby_GT图片都明显比使用传统的bicubic和A+算法重建的baby_GT图片清晰。使用本文方法与SRCNN, FSRCNN和ESPCN算法相比, 重建的baby_GT图片从清晰度角度看起来没有明显的区别, 但是对baby_GT重

建图片中的右眼进行截取放大观察(在baby_GT重建图片右下角), 可以看出, 使用SRCNN和FSRCNN算法重建的baby_GT右眼整体较模糊, 看不清细节; 使用ESPCN算法重建的baby_GT右眼清晰, 但是对右眼图片放大, 可以看到眉毛比较模糊; 而使用本文方法重建的baby_GT右眼不仅清晰明了, 而且对右眼图片放大, 可以明显地看清楚眉毛细节部分。

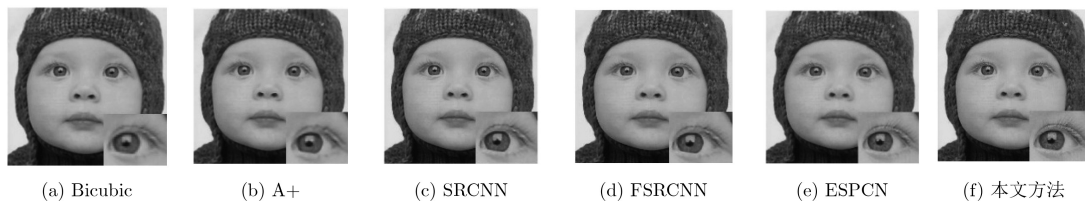


图6 Set5 测试集中的baby_GT重建对比图

总之, 使用本文方法与Bicubic, A+, SRCNN, FSRCNN和ESPCN算法相比, 从表1和表2的PSNR和SSIM测试值可以看出, 使用本文方法在Set5和Set14测试集上测试得到的PSNR和SSIM值均高于使用Bicubic, A+, SRCNN, FSRCNN和ESPCN算法测试得到的PSNR和SSIM值。从图6可以看出, 使用本文方法得到的重建图像不仅清晰明了, 而且细节信息更丰富, 图像纹理更细腻, 更逼真, 视觉效果更好。因此, 使用本文方法在评价指标数值和视觉效果上都优于使用Bicubic, A+, SRCNN, FSRCNN和ESPCN算法。

5 结论

本文为了解决图像特征信息之间缺乏关联性的问题, 提取图像深层信息, 提出了多级跳线连接的深度残差网络超分辨率重建方法。本文方法的网络结构主要是由8个多级跳线连接的残差块端对端连接组成。将低分辨率图像输入到网络中, 通过多级跳线连接的残差块得到预测的残差图像, 最后将残

差图像和低分辨率图像组合在一起转化为高分辨率图像。本文方法与Bicubic, A+, SRCNN, FSRCNN和ESPCN算法相比, 在Set5测试集和Set14测试集进行测试得到的PSNR和SSIM值都得到了提高, 并且使用本文方法得到的重建图像具有更好的视觉效果。

参考文献

- [1] THORNTON M W, ATKINSON P M, and HOLLAND D A. Sub-pixel mapping of rural land cover objects from fine spatial resolution satellite sensor imagery using super-resolution pixel-swapping[J]. *International Journal of Remote Sensing*, 2006, 27(3): 473-491. doi: 10.1080/01431160500207088.
- [2] PELED S and YESHURUN Y. Superresolution in MRI: Application to human white matter fiber tract visualization by diffusion tensor imaging[J]. *Magnetic Resonance in Medicine*, 2001, 45(1): 29-35. doi: 10.1002/1522-2594(200101)45.
- [3] ZOU W W W and YUEN P C. Very low resolution face

- recognition problem[J]. *IEEE Transactions on Image Processing*, 2012, 21(1): 327–340. doi: [10.1109/TIP.2011.2162423](https://doi.org/10.1109/TIP.2011.2162423).
- [4] LU Huimin, LI Yujie, CHEN Min, *et al.* Brain intelligence: Go beyond artificial intelligence[J]. *Mobile Networks and Applications*, 2018, 23(2): 368–375. doi: [10.1007/s11036-017-0932-8](https://doi.org/10.1007/s11036-017-0932-8).
- [5] KOCH M. Artificial intelligence is becoming natural[J]. *Cell*, 2018, 173(3): 531–533. doi: [10.1016/j.cell.2018.04.007](https://doi.org/10.1016/j.cell.2018.04.007).
- [6] LEO M, MEDIONI G, TRIVEDI M, *et al.* Computer vision for assistive technologies[J]. *Computer Vision and Image Understanding*, 2017, 154: 1–15. doi: [10.1016/j.cviu.2016.09.001](https://doi.org/10.1016/j.cviu.2016.09.001).
- [7] ZHU Hong, TANG Xinming, XIE Junfeng, *et al.* Spatio-temporal super-resolution reconstruction of remote-sensing images based on adaptive multi-scale detail enhancement[J]. *Sensors*, 2018, 18(2): 498. doi: [10.3390/s18020498](https://doi.org/10.3390/s18020498).
- [8] SHI Jun, LIU Qingping, WANG Chaofeng, *et al.* Super-resolution reconstruction of MR image with a novel residual learning network algorithm[J]. *Physics in Medicine & Biology*, 2018, 63(8): 085011. doi: [10.1088/1361-6560/aab9e9](https://doi.org/10.1088/1361-6560/aab9e9).
- [9] SU Heng, ZHOU Jie, and ZHANG Zhihao. Survey of super-resolution image reconstruction methods[J]. *Acta Automatica Sinica*, 2013, 39(8): 1202–1213. doi: [10.3724/SP.J.1004.2013.01202](https://doi.org/10.3724/SP.J.1004.2013.01202).
- [10] GRIBBON K T and BAILEY D G. A novel approach to real-time bilinear interpolation[C]. The 2nd IEEE International Workshop on Electronic Design, Test and Applications, Perth, Australia, 2004: 126–131. doi: [10.1109/DELTA.2004.10055](https://doi.org/10.1109/DELTA.2004.10055).
- [11] FRITSCH F N and CARLSON R E. Monotone piecewise cubic interpolation[J]. *SIAM Journal on Numerical Analysis*, 1980, 17(2): 238–246. doi: [10.1137/0717021](https://doi.org/10.1137/0717021).
- [12] STARK H and OSKOUI P. High-resolution image recovery from image-plane arrays, using convex projections[J]. *Journal of the Optical Society of America A*, 1989, 6(11): 1715–1726. doi: [10.1364/JOSAA.6.001715](https://doi.org/10.1364/JOSAA.6.001715).
- [13] PATANAVIJIT V and JITAPUNKUL S. An iterative super-resolution reconstruction of image sequences using fast affine block-based registration with BTV regularization[C]. Proceedings of 2006 IEEE Asia Pacific Conference on Circuits and Systems, Singapore, 2006: 1717–1720. doi: [10.1109/APCCAS.2006.342128](https://doi.org/10.1109/APCCAS.2006.342128).
- [14] ZHOU Fei, YANG Wenming, and LIAO Qingmin. Interpolation-based image super-resolution using multisurface fitting[J]. *IEEE Transactions on Image Processing*, 2012, 21(7): 3312–3318. doi: [10.1109/TIP.2012.2189576](https://doi.org/10.1109/TIP.2012.2189576).
- [15] LIN Zhouchen and SHUM H Y. Fundamental limits of reconstruction-based superresolution algorithms under local translation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2004, 26(1): 83–97. doi: [10.1109/TPAMI.2004.1261081](https://doi.org/10.1109/TPAMI.2004.1261081).
- [16] YOUNG T, HAZARIKA D, PORIA S, *et al.* Recent trends in deep learning based natural language processing[J]. *IEEE Computational Intelligence Magazine*, 2018, 13(3): 55–75. doi: [10.1109/MCI.2018.2840738](https://doi.org/10.1109/MCI.2018.2840738).
- [17] KERMAN Y D S, GOLDBAUM M, CAI Wenjia, *et al.* Identifying medical diagnoses and treatable diseases by image-based deep learning[J]. *Cell*, 2018, 172(5): 1122–1131.e9. doi: [10.1016/j.cell.2018.02.010](https://doi.org/10.1016/j.cell.2018.02.010).
- [18] DONG Chao, LOY C C, HE Kaiming, *et al.* Image super-resolution using deep convolutional networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 38(2): 295–307. doi: [10.1109/TPAMI.2015.2439281](https://doi.org/10.1109/TPAMI.2015.2439281).
- [19] DONG Chao, LOY C C, and TANG Xiaoou. Accelerating the super-resolution convolutional neural network[C]. The 14th European Conference on Computer Vision, Amsterdam, The Netherlands, 2016: 391–407. doi: [10.1007/978-3-319-46475-6_25](https://doi.org/10.1007/978-3-319-46475-6_25).
- [20] KIM J, LEE J K, and LEE K M. Deeply-recursive convolutional network for image super-resolution[C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, USA, 2016: 1637–1645. doi: [10.1109/CVPR.2016.181](https://doi.org/10.1109/CVPR.2016.181).
- [21] SHI Wenzhe, CABALLERO J, HUSZÁR F, *et al.* Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network[C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, USA, 2016: 1874–1883. doi: [10.1109/CVPR.2016.207](https://doi.org/10.1109/CVPR.2016.207).
- [22] LEDIG C, THEIS L, HUSZÁR F, *et al.* Photo-realistic single image super-resolution using a generative adversarial network[C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, USA, 2017: 4681–4690. doi: [10.1109/CVPR.2017.19](https://doi.org/10.1109/CVPR.2017.19).
- [23] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, *et al.* Deep residual learning for image recognition[C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, USA, 2016: 770–778. doi: [10.1109/CVPR.2016.90](https://doi.org/10.1109/CVPR.2016.90).
- [24] KIM J, LEE J K, and LEE K M. Accurate image super-resolution using very deep convolutional networks[C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, USA, 2016: 1646–1654. doi: [10.1109/CVPR.2016.182](https://doi.org/10.1109/CVPR.2016.182).
- [25] YUAN Fei, HUANG Lianfen, and YAO Yan. An improved

- PSNR algorithm for objective video quality evaluation[C]. 2007 Chinese Control Conference, Hunan, China, 2007: 376–380. doi: [10.1109/CHICC.2006.4347144](https://doi.org/10.1109/CHICC.2006.4347144).
- [26] WANG Zhou, 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. doi: [10.1109/TIP.2003.819861](https://doi.org/10.1109/TIP.2003.819861).
- [27] GAO Shengkui and GRUEV V. Bilinear and bicubic interpolation methods for division of focal plane polarimeters[J]. *Optics Express*, 2011, 19(27): 26161–26173. doi: [10.1364/OE.19.026161](https://doi.org/10.1364/OE.19.026161).
- [28] TIMOFTE R, DE SMET V, and VAN GOOL L. A+: Adjusted anchored neighborhood regression for fast super-resolution[C]. The 12th Asian Conference on Computer Vision, Singapore, 2014: 111–126. doi: [10.1007/978-3-319-16817-3_8](https://doi.org/10.1007/978-3-319-16817-3_8).
- [29] ZEYDE R, ELAD M, and PROTTER M. On single image scale-up using sparse-representations[C]. The 7th International Conference on Curves and Surfaces, Avignon, France, 2010: 711–730. doi: [10.1007/978-3-642-27413-8_47](https://doi.org/10.1007/978-3-642-27413-8_47).
- 赵小强: 男, 1969年生, 博士生导师, 教授, 主要研究方向为故障诊断, 图像处理, 生产调度等.
- 宋昭漾: 男, 1995年生, 硕士生, 研究方向为图像处理.