

边缘修正的多尺度卷积神经网络重建算法

程德强**, 蔡迎春*, 陈亮亮, 宋玉龙

中国矿业大学信息与控制工程学院, 江苏 徐州 221008

摘要 目前,基于卷积神经网络的超分辨率重建方法具有参数数量大,时效性偏低,边缘细节信息丢失的缺陷。针对该问题,提出基于边缘修正的多尺度卷积神经网络超分辨率重建算法。首先在训练阶段,利用低频信息的冗余性设置参数共享层,将同一组滤波器应用到不同放大倍数的训练网络中,构建多任务学习框架;然后在重建阶段,从样本训练库中学习可以高分辨率图像边缘修正系数,采用邻域像素差值线性运算将边缘系数与重建的高分辨率图像进行融合,矫正边缘信息的偏差,弥补丢失细节;最后根据随机梯度下降法和反向传播法,利用梯度不断更新权重参数使网络达到最优化。实验结果表明,该算法的重建效果较为显著,边缘锐度较高,消除了模糊和锯齿现象,并且通过参数共享大幅减少参数数量,满足实时性的要求。

关键词 图像处理; 超分辨率重建; 边缘修正; 多尺度; 梯度信息

中图分类号 TP391.4

文献标识码 A

doi: 10.3788/LOP55.091003

Multi-Scale Convolutional Neural Network Reconstruction Algorithm Based on Edge Correction

Cheng Deqiang**, Cai Yingchun*, Chen Liangliang, Song Yulong

School of Information and Control Engineering, China University of Mining and Technology, Xuzhou, Jiangsu 221008, China

Abstract At present, the super-resolution reconstruction methods based on convolutional neural network have the defects of large amount of parameters, low timeliness and loss of edge detail information. In order to solve these problems, we propose a super-resolution reconstruction algorithm of multiscale convolution neural network based on edge correction. Firstly, in the training phase, we set the parameter sharing layer by using the redundancy of low frequency information. In other words, the same set of filters applied to different magnification training networks to build the multi-task learning framework. In the reconstruction phase, the edge correction coefficient of high-resolution image is learned from the sample training library. The neighborhood pixel difference is used to fuse the edge coefficient and the reconstructed high resolution image, and to correct the deviation of the edge information and make up for the missing details. Finally, according to the stochastic gradient descent and back-propagation, we use the gradient to continuously update the weight parameters to make the network reach the maximum optimization. Experimental results show that the proposed algorithm has the significant reconstruction effect, high edge sharpness, elimination of blurring and aliasing, and greatly reduces the amount of parameters through parameter sharing to meet real-time requirements.

Key words image processing; super-resolution reconstruction; edge correction; multi-scale; gradient information

OCIS codes 100.3010; 100.2960

1 引言

图像超分辨率重建是一种将低分辨率(LR)图像恢复为高分辨率(HR)图像的方法^[1]。目前,该

方法主要分为三类:插值法^[2]、基于重建的方法^[3]、基于学习的方法^[4]。插值法十分简单,容易实现,但所重建的图像不够清晰。基于重建的方法以退化模型为基础,利用图像的先验知识进行重建,但需要精

收稿日期: 2018-02-05; 修回日期: 2018-03-21; 录用日期: 2018-03-28

基金项目: 国家自然科学基金(51774281)、江苏省“六大人才高峰”高层次人才培养项目(2015-ZBZZ-009)

* E-mail: cyccumt@126.com; ** E-mail: 879301252@qq.com

度极高的亚像素配准,不易实现。近年来的研究热点是基于学习的方法, Yang 等^[5-6]研究了稀疏编码(ScSR)方法,通过训练高低分辨率字典,学习 LR 与 HR 图像之间的映射关系。Timofte 等^[7-8]将稀疏编码字典与邻域嵌入的方法相结合,提出锚定邻域回归(ANR)和调整的锚定邻域回归(A+)等方法。

后来,随着深度学习方法的兴起,基于深度学习的超分辨率重建方法也取得显著的效果。Dong 等^[9]最先提出基于卷积神经网络的超分辨率(SRCNN)重建方法,该方法直接学习一种 LR 与 HR 图像之间端到端的映射关系,在隐藏层中进行字典学习和空间模型建立,在卷积层中进行图像块的提取和放大,从而避免很多前/后期处理,但网络结构单一并不支持多种放大倍数下的图像超分辨率重建。后来, Dong 等^[10]在 SRCNN 方法的基础上进行改进,提出快速的卷积神经网络超分辨率(FSRCNN)重建方法,将未经预处理的 LR 图像直接作为网络输入,在网络末端采用反卷积层进行上采样,并且调整卷积核尺寸大小。Kim 等^[11]提出深度递归卷积网络(DRCN),通过增加网络的深度扩展图像的感受野,提出递归监督和跳过连接以降低网络模型的训练难度。

Dong 等的方法未考虑训练网络参数的共享性,不支持多种放大倍数下的图像超分辨率重建,忽略了图像块边缘纹理细节的差异性。Kim 等^[11]的方法虽然效果不错,但是网络层数增多,计算量较大。因此,为了在快速重建图像的同时提高重建后图像边缘细节的清晰度,本文在 Dong 等的基础上提出基于边缘修正的多尺度卷积神经网络超分辨率重建算法。首先,该方法在训练阶段利用图像局部结构的重复性设置参数共享卷积层,能够让同一种训练网络适用于不同放大倍数的网络,在不增加参数量的情况下,拓展网络的适用范围;然后在重建阶段从图像样本库中学习高分辨率图像边缘修正系数,对于重建后的高分辨率图像进行边缘修正,弥补重建过程产生的边缘误差。实验结果表明,基于边缘修正的多尺度卷积神经网络超分辨率重建算法能够通过参数共享同时进行多任务学习,增强了边缘信息特征,取得了较好的视觉效果,且具有良好的辨识度。

2 基于卷积神经网络的超分辨率重建模型

基于卷积神经网络的超分辨率重建算法是一种

经典的深度学习算法,主要包括图像训练和重建两部分,其基本步骤为:1) 构建训练样本库。2) 建立端到端的超分辨率学习框架。3) 对 LR 图像进行双三次插值,得到与 HR 图像 X 尺寸大小相同的插值图 Y^B 。4) 将插值图 Y^B 作为卷积神经网络的输入图像,依次经过特征提取、非线性映射、重建三个卷积层,如图 1 所示,用公式分别表示为

$$\begin{cases} F_1(Y^B) = \varphi(0, W_1 * Y^B + B_1) \\ F_2(Y^B) = \varphi[0, W_2 * F_1(Y^B) + B_2] \\ F_3(Y^B) = W_3 * F_2(Y^B) + B_3 \end{cases} \quad (1)$$

式中 $\{W_1, W_2, W_3\}$ 分别为每层滤波权重,其尺寸大小为 $n_k \times c \times f_k \times f_k$ ($k=1, 2, 3$), n_k 为特征图数量, c 为输入图像的通道数, f_k 为卷积核的大小。 $\{B_1, B_2, B_3\}$ 分别为每层偏置向量, $*$ 为卷积, $F_i(Y^B)$ 为每层输出结果, φ 为带参数的修正线性单元(PRELU),与修正线性单元(RELU)相比,PRELU 具有较好的正则化效果,有效加速网络的收敛速度。整个网络的关键点在于对参数 $\Theta = \{W_1, W_2, W_3, B_1, B_2, B_3\}$ 的训练和优化,低分辨率输入图像经过特征提取、非线性映射、重建过程之后,通过最小化重建图像 $F(Y^B, \Theta)$ 和真实图像 X 之间的损失误差得到参数的最优解,表示为

$$\min_{\Theta} \frac{1}{n} \sum_{i=1}^n \|F_3(Y_i^B; \Theta) - X_i\|_2^2, \quad (2)$$

式中 X_i 为 HR 图像, n 为高/低分辨率样本对数。可采用随机梯度下降(SGD)^[12]法和反向传播(BP)法对(2)式进行求解。

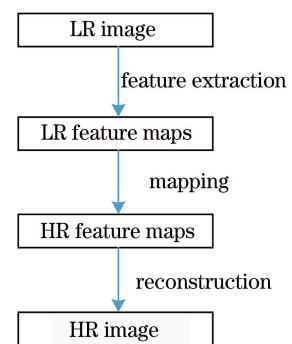


图 1 卷积神经网络框架图

Fig. 1 Structure of convolutional neural network

3 边缘修正的多尺度卷积神经网络重建算法

3.1 算法模型

针对卷积网络尺度单一、计算量大、边缘细节丢失等问题,提出基于边缘修正的多尺度卷积神经网络

络超分辨率重建方法。其主旨思想为:预处理,对低分辨率输入图像进行双三次插值放大;然后依次经过特征提取层、非线性映射层、重建层、边缘信息融合层、损失函数层,计算修正图像与原图误差;再利用反向过程计算梯度并不断更新参数,使网络最优化。

由于多尺度情况下大部分低频信息具有重复

性,所以在非线性映射过程中设置共享卷积层,使网络参数跨尺度传播交流,从而同时达到对 2、3、4 倍网络的监督和指导。完成超分辨率重建后,为了提高图像边缘细节的精确度,将学习的边缘先验信息与重建的高分辨率图像进行融合,以修正和补偿丢失的细节信息。算法模型如图 2 所示。

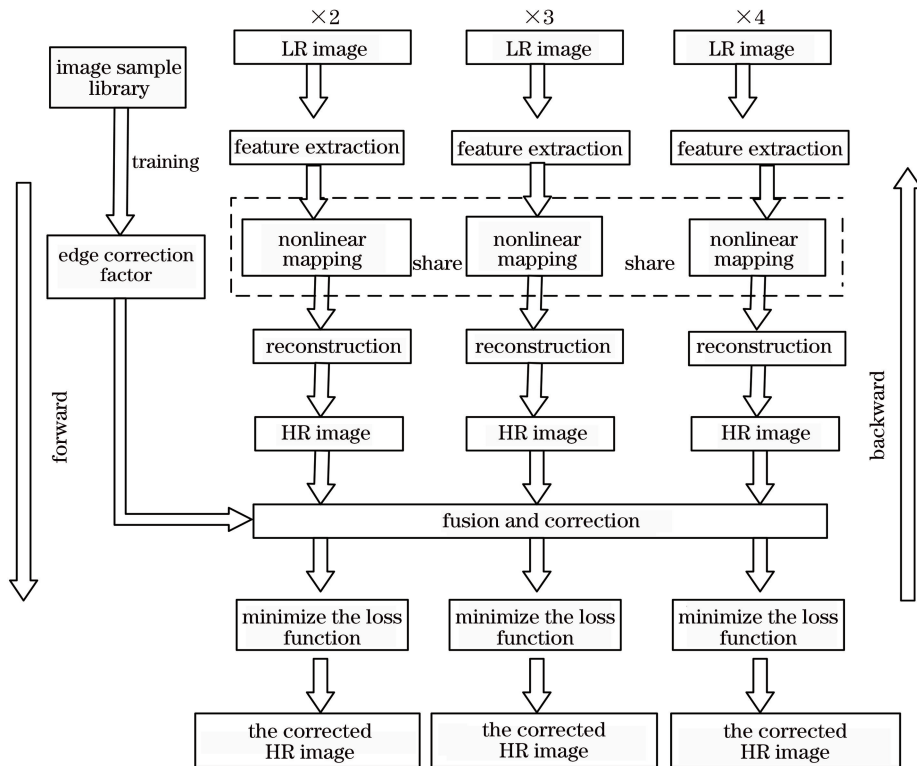


图 2 本文算法模型

Fig. 2 Model of proposed algorithm

3.2 多尺度共享

自然图像的局部结构在多尺度情况下通常具有重复性,很多丢失的细节可以通过不同尺度下的其他相似块估计得到。清晰的边缘和复杂的纹理细节通常需要不同尺度下的结构共同实现,展示出最优的视觉效果。由此可见,图像块的冗余性对于学习 LR、HR 图像之间端到端的映射十分有利。受此启发,采用共享层策略构建了多尺度学习框架。如图 2 所示,使 $\times 2$ 、 $\times 3$ 、 $\times 4$ 倍放大网络共享映射层,通过共享参数,同一组滤波器可被用于各条路径,并且通过跨尺度可进行信息传递和交流,互相提供正则化指导,大幅简化网络的复杂度,减少参数量,提高训练效率。

根据近邻相似关系可知,图像的空间相关性只是局部的像素联系较为紧密,而距离较远的像素相关性则较弱。因而,每个神经元没有必要对全局图像进行感知,只需要对局部进行感知,然后在更高层

将局部的信息综合起来即可得到全局的信息,如图 3 所示,图 3(a)为全连接,图 3(b)为局部连接。输入一幅 1000×1000 的图像,那么输入层的神经元数目就是像素点数目 1000×1000 ,若采用图 3(a)全连接,参数数量为 $1000000 \times 1000 \times 1000$ 个。如果采用图 3(b)局部连接,让隐藏层的 1000×1000 个神经元仅和输入层 10×10 个神经元相连接,则参数数量为 $1000000 \times 10 \times 10$ 个,显而易见,后者是前者的




图 3 感受野。(a)全连接;(b)局部连接

Fig. 3 Receptive field.

(a) Full connection; (b) local connection

万分之一。所以对 2、3、4 倍放大网络均采用局部连接,大幅减少了整体网络的参数数量。

权值共享是将学习的低频特征应用于不同尺度的网络训练中。因为图像的局部结构具有重复性,在映射过程中每个神经元均对应 100 个参数,而隐藏层的每个神经元与输入层不同区域的 10×10 个




图 4 权值共享

Fig. 4 Weight sharing

利用网络的局部感知和权值共享的性质,将训练网络进行改进,形成共享层。当网络的尺度变换时,不必每次从头开始训练,只需要微调卷积步长就能实现多种放大倍数下的网络训练,进而获得一定程度上的尺度不变性,提升训练效率。

3.3 边缘信息融合

由文献[13]可知,一幅图像中的某个图像块可以通过邻域图像块的线性运算表示,而本文仅需要获得图像的边缘信息来对重建后的图像进行融合和边缘修正,且邻域像素值和该像素值的差分能很好的表示图像的边缘信息,因此采用邻域像素差分值的线性运算修正重建的高分辨率图像。考虑到图像的梯度方向不同所获得的图像边缘信息也会不同,利用不同方向的边缘信息与重建后的图像进行融合,从而可以使图像的边缘信息更加丰富,视觉效果更佳。分别求取 $x+$ 、 $x-$ 、 $y+$ 和 $y-$ 这 4 个方向的梯度信息,各方向梯度公式定义为

$$\frac{\partial f}{\partial x_+} = \frac{\Delta f}{\Delta x_+} = f(x+1, y) - f(x, y), \quad (3)$$

$$\frac{\partial f}{\partial x_-} = \frac{\Delta f}{\Delta x_-} = f(x-1, y) - f(x, y), \quad (4)$$

$$\frac{\partial f}{\partial y_+} = \frac{\Delta f}{\Delta y_+} = f(x, y+1) - f(x, y), \quad (5)$$

$$\frac{\partial f}{\partial y_-} = \frac{\Delta f}{\Delta y_-} = f(x, y-1) - f(x, y), \quad (6)$$

式中 $f(x, y)$ 为图像中坐标为 (x, y) 的像素灰度值,根据梯度公式计算 $x+$ 、 $x-$ 、 $y+$ 和 $y-$ 这 4 个方向的梯度信息图像 s_{x+} 、 s_{x-} 、 s_{y+} 、 s_{y-} 。边缘信息 g_i 定义为

$$g_i = \mathbf{k}_i \cdot \mathbf{s}_i (i = 1, 2, 3, \dots, n \times n), \quad (7)$$

式中 $\mathbf{k}_i = [a \ b \ c \ d]$ 为系数矩阵, $\mathbf{s}_i = [s_{x+} \ s_{x-} \ s_{y+} \ s_{y-}]^T$ 。则可通过求解下式来获得系

神经元的连接均相同,即这 1000000 个神经元的 100 个参数均相等。这 100 个滤波参数也是特征提取的方式,该方式与位置无关,只提取符合条件的图像特征。本文采用共享的 3×3 卷积核在 5×5 的图像上做卷积,如图 4 所示,就像一个筛子,将图像中符合条件(激活值越大越符合条件)的特征筛选出来。

数矩阵 $\mathbf{K} = \{\mathbf{k}_1, \mathbf{k}_2, \dots, \mathbf{k}_{n \times n}\}$ 。

$$\min \|G + H_{HR} - I\|, \quad (8)$$

式中 $G = \{g_1, g_2, \dots, g_{n \times n}\} = \{\mathbf{k}_1 \cdot \mathbf{s}_1, \mathbf{k}_2 \cdot \mathbf{s}_2, \dots, \mathbf{k}_{n \times n} \cdot \mathbf{s}_{n \times n}\} = \mathbf{K}\mathbf{S}$ 是边缘信息的集合, $\mathbf{S} = \{\mathbf{s}_1, \mathbf{s}_2, \dots, \mathbf{s}_{n \times n}\}$ 是梯度信息的集合, H_{HR} 为卷积层重建的高分辨率图像, I 为样本图像。(8)式采用改进的正交匹配追踪(OMP)算法进行求解[14],从而获得系数矩阵 \mathbf{K} 。在融合过程中,采用欧氏距离最小方法选择匹配的边缘融合系数矩阵。

4 实验结果

实验的计算机配置为 Intel(R) Core(TM) i5-7500 CPU @3.40 GHz, 16 GB 运行内存,平台为深度学习平台 Caffe[15] 及其 Matlab2013a 环境。进行了大量对比实验以验证该算法的超分辨率性能,在重建质量和速度的权衡之下,选用 5 层卷积网络,选取最大迭代次数为 8×10^5 ,并且在不同放大倍数下,共享映射层低频参数。

实验中采用训练集 General-100[10] 和 91 幅[6] 图像, General-100 训练集包含 100 幅 bmp 格式的图像,其大小范围为 $710 \times 704 \sim 131 \times 112$,而且边缘锐度较高,平滑的区域较少,所以非常适合学习边缘信息。为了扩大训练集,使样本更具有代表性,将训练集中所有样本图像分别进行 90° 、 180° 、 270° 旋转并进行 0.6、0.7、0.8、0.9 倍缩放后,训练样本数量变为原来的 19 倍,完全满足卷积神经网络需要大量数据集的要求。

采用文献[12]中的学习策略,即根据 SGD 方法,利用负梯度 $\nabla L(W)$ 、上一次的更新值 V_t 和当前权重 W_t 来计算当前的更新值 V_{t+1} 和权重 W_{t+1} :

$$V_{t+1} = \alpha V_t - \beta \nabla L(W_t), \quad W_{t+1} = W_t + V_{t+1}, \quad (9)$$

式中动量 $\alpha=0.9$, 学习率 $\beta=10^{-3}$, 随着迭代次数的增加, 当损失函数层的损失达到最小时, 学习率降低为 10^{-4} 。

4.1 主观效果

选用标准测试集 set5^[16] 和 set14^[17], 并与 Bicubic、ScSR^[6]、A+^[8]、SRCNN^[9]、FSRCNN^[10]、DRCN^[11] 6 种现有经典算法进行对比。图 5~9 是在 3 倍放大比例下, 7 种不同算法的重建效果以及局部细节放大图对比, 由于篇幅限制, 仅选取 baby、butterfly、ppt3、lenna、zebra 等 5 幅边缘细节丰富且具有代表性的图像作为展示。

图 5~9 分别对 baby 的右眼、蝴蝶翅膀纹理、lenna 帽檐、ppt3 字母、斑马条纹等 5 处局部区域进

行 3 倍放大。从放大图中可以看出, Bicubic 算法的整体重建质量不高, 较为模糊; ScSR 算法视觉效果略好, 但是 baby 眼睛周围和瞳孔部分、ppt3 字母重影严重, 辨识度太差, 蝴蝶翅膀纹理以及斑马背部条纹处不清晰, lenna 帽檐处锯齿现象严重。A+、SRCNN 和 FSRCNN 算法比前两种方法视觉效果好, 但细微的高频部分仍然不清晰, 边缘不够完整。虽然 DRCN 算法的效果与本文算法很接近, 但是 DRCN 算法网络结构复杂, 计算量大。总体来说, 本文算法重建效果最好, 如 baby 睫毛和瞳孔部分锐度增强, 蝴蝶纹理边缘以及斑马背部条纹信息保持完好, 较为清晰, lenna 帽檐和 ppt3 字母辨识度较高, 与原图效果更接近。

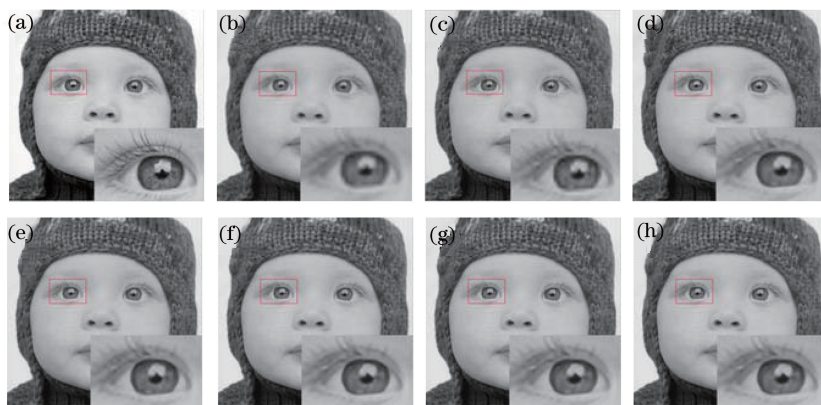


图 5 不同算法重建结果对比(baby)。(a)原始图像;(b) Bicubic 算法;(c) ScSR 算法;(d) A+算法;(e) SRCNN 算法;(f) FSRCNN 算法;(g) DRCN 算法;(h)本文算法

Fig. 5 Comparison of reconstruction results with different algorithms (baby).

(a) Original image; (b) Bicubic algorithm; (c) ScSR algorithm; (d) A+ algorithm; (e) SRCNN algorithm; (f) FSRCNN algorithm; (g) DRCN algorithm; (h) proposed algorithm




图 6 不同算法重建结果对比(butterfly)。(a)原始图像;(b) Bicubic 算法;(c) ScSR 算法;(d) A+算法;(e) SRCNN 算法;(f) FSRCNN 算法;(g) DRCN 算法;(h)本文算法

Fig. 6 Comparison of reconstruction results with different algorithms (butterfly). (a) Original image; (b) Bicubic algorithm; (c) ScSR algorithm; (d) A+ algorithm; (e) SRCNN algorithm; (f) FSRCNN algorithm; (g) DRCN algorithm; (h) proposed algorithm

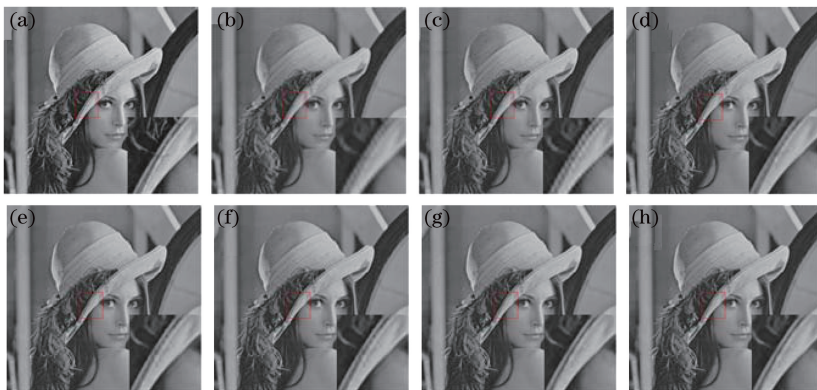


图 7 不同算法重建结果对比(lenna)。(a)原始图像;(b) Bicubic 算法;(c) ScSR 算法;(d) A+算法;
(e) SRCNN 算法;(f) FSRCNN 算法;(g) DRCN 算法;(h)本文算法

Fig. 7 Comparison of reconstruction results with different algorithms (lenna). (a) Original image;
(b) Bicubic algorithm; (c) ScSR algorithm; (d) A+ algorithm; (e) SRCNN algorithm; (f) FSRCNN algorithm;
(g) DRCN algorithm; (h) proposed algorithm



图 8 不同算法重建结果对比(ppt3)。(a)原始图像;(b) Bicubic 算法;(c) ScSR 算法;(d) A+算法;
(e) SRCNN 算法;(f) FSRCNN 算法;(g) DRCN 算法;(h)本文算法

Fig. 8 Comparison of reconstruction results with different algorithms (ppt3). (a) Original image;
(b) Bicubic algorithm; (c) ScSR algorithm; (d) A+ algorithm; (e) SRCNN algorithm; (f) FSRCNN algorithm;
(g) DRCN algorithm; (h) proposed algorithm

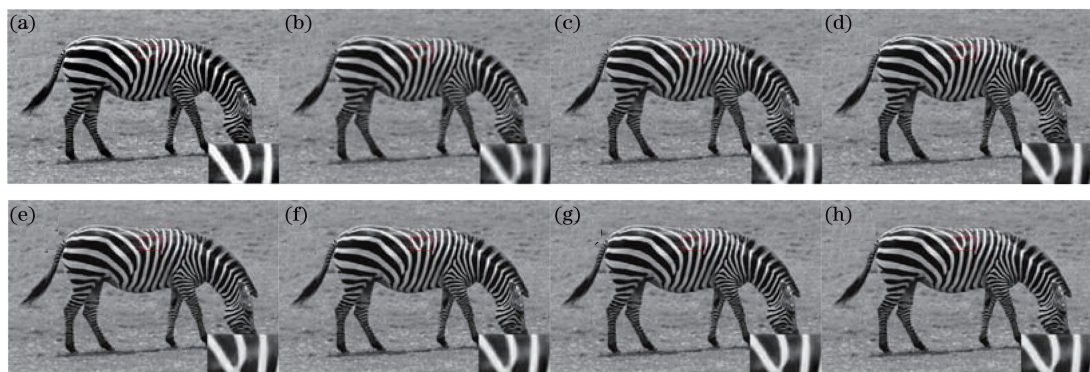


图 9 不同算法重建结果对比(zebra)。(a)原始图像;(b) Bicubic 算法;(c) ScSR 算法;(d) A+算法;
(e) SRCNN 算法;(f) FSRCNN 算法;(g) DRCN 算法;(h)本文算法

Fig. 9 Comparison of reconstruction results with different algorithms (zebra). (a) Original image;
(b) Bicubic algorithm; (c) ScSR algorithm; (d) A+ algorithm; (e) SRCNN algorithm; (f) FSRCNN algorithm;
(g) DRCN algorithm; (h) proposed algorithm

4.2 客观效果

为了进一步客观的评价重建图像的质量,表 1、表 2 所示分别为测试集 set5 和 set14 部分图像在放大倍数为 2、3、4 时的峰值信噪比值(PSNR)和结构相似度(SSIM)。从表中统计数据来看,本文算法

的 PSNR 值比 FSRCNN 平均高出 1.12 dB 左右,比 SRCNN 平均高出 1.85 dB 左右,比 DRCN 高出 0.1 dB 左右,并且 SSIM 值均高于其他 6 种算法,充分证明了该算法的有效性,重建效果与原图更接近。

表 1 在不同放大倍数下测试集 set5 中各图像的指标对比

Table 1 Comparison of indexes of test set5 with different up-scale factors

Image	Scale	PSNR/SSIM						
		Bicubic algorithm	ScSR algorithm	A+ algorithm	SRCNN algorithm	FSRCNN algorithm	DRCN algorithm	Proposed algorithm
Baby	2	37.07/0.9297	—	38.51/0.9538	38.54/0.9545	38.62/0.9551	39.71/0.9557	39.82/0.9567
	3	33.91/0.8680	34.47/0.8826	35.20/0.9088	35.25/0.9090	35.29/0.9140	36.28/0.9186	36.34/0.9379
	4	31.78/0.8106	—	33.03/0.8603	33.17/0.8629	33.29/0.8655	34.35/0.8711	34.47/0.8929
Bird	2	36.81/0.9295	—	37.72/0.9301	37.21/0.9388	38.53/0.9408	39.67/0.9418	39.68/0.9583
	3	32.46/0.8675	33.86/0.8752	35.39/0.8891	35.48/0.8897	36.01/0.8927	37.35/0.9025	37.47/0.9207
	4	30.18/0.8011	—	32.50/0.8509	32.52/0.8510	32.74/0.8534	33.94/0.8579	33.97/0.8697
Butterfly	2	27.43/0.9017	—	32.08/0.9086	32.75/0.9108	32.82/0.9119	33.81/0.9124	33.99/0.9397
	3	23.76/0.8506	25.10/0.8693	27.25/0.8704	27.95/0.8779	28.68/0.8807	29.70/0.8805	29.83/0.8927
	4	22.10/0.7994	—	24.49/0.8125	25.46/0.8177	25.69/0.8246	26.75/0.8229	26.96/0.8408
Head	2	34.85/0.9289	—	35.48/0.9291	35.72/0.9306	35.87/0.9358	36.97/0.9384	36.99/0.9399
	3	32.88/0.8765	32.95/0.8779	33.38/0.8890	33.71/0.8897	33.81/0.8904	34.85/0.9109	34.94/0.9218
	4	31.59/0.8109	—	32.25/0.8113	32.44/0.8225	32.49/0.8287	33.54/0.8279	33.62/0.8345
Woman	2	32.14/0.9201	—	35.31/0.9354	35.37/0.9379	35.61/0.9402	36.72/0.9405	36.95/0.9493
	3	27.43/0.8497	28.51/0.8574	31.28/0.8659	31.37/0.8695	32.01/0.8727	33.18/0.8903	33.39/0.8919
	4	26.46/0.8099	—	28.60/0.8117	28.69/0.8186	28.98/0.8207	29.09/0.8217	29.28/0.8397

表 2 在不同放大倍数下测试集 set14 中部分图像的指标对比

Table 2 Comparison of indexes of test set14 with different up-scale factors

Image	Scale	PSNR/SSIM						
		Bicubic algorithm	ScSR algorithm	A+ algorithm	SRCNN algorithm	FSRCNN algorithm	DRCN algorithm	Proposed algorithm
Baboon	2	24.86/0.8387	—	25.66/0.9055	25.74/0.9064	26.01/0.9088	26.85/0.9107	26.98/0.9215
	3	23.21/0.7736	23.46/0.7785	23.60/0.8187	23.67/0.8197	23.71/0.8244	24.87/0.8273	24.94/0.8287
	4	22.43/0.7019	—	22.71/0.7031	22.73/0.7039	22.85/0.7145	23.91/0.7144	23.91/0.7228
Flowers	2	30.37/0.8541	—	33.09/0.9012	33.32/0.9126	33.49/0.9223	34.55/0.9238	34.71/0.9358
	3	27.23/0.7951	28.22/0.8004	29.08/0.8143	29.26/0.8257	29.45/0.8277	30.45/0.8285	30.59/0.8319
	4	25.52/0.7801	—	26.92/0.7956	27.14/0.7988	27.41/0.8094	28.42/0.8117	28.74/0.8289
Foreman	2	34.14/0.9295	—	36.33/0.9357	36.42/0.9366	36.58/0.9379	37.69/0.9352	37.81/0.9508
	3	31.18/0.8842	32.04/0.8855	33.69/0.8906	33.89/0.8997	34.12/0.9124	35.19/0.9224	35.35/0.9397
	4	29.41/0.8152	—	32.20/0.8801	32.14/0.8874	32.67/0.8963	33.77/0.9174	33.83/0.9202
Lenna	2	34.70/0.9127	—	36.61/0.9315	36.64/0.9328	36.80/0.9411	37.89/0.9486	37.99/0.9593
	3	31.68/0.8775	32.57/0.8892	33.58/0.8916	33.67/0.8995	33.85/0.9007	34.89/0.9053	34.89/0.9124
	4	29.84/0.8079	—	31.40/0.8125	31.41/0.8126	31.59/0.8204	32.68/0.8287	32.87/0.8311
Pepper	2	34.97/0.9175	—	36.80/0.9354	36.57/0.9357	36.93/0.9399	37.84/0.9408	37.93/0.9546
	3	32.39/0.8957	33.40/0.8965	34.49/0.9217	34.71/0.9288	34.89/0.9305	35.87/0.9374	35.99/0.9413
	4	30.60/0.8129	—	32.93/0.8948	32.98/0.8962	33.19/0.9189	34.25/0.9198	34.46/0.9273
Ppt3	2	26.87/0.7992	—	29.69/0.7840	31.52/0.8117	32.07/0.8175	33.14/0.8271	33.19/0.8294
	3	23.71/0.6857	25.13/0.7099	26.15/0.7144	27.04/0.7452	27.31/0.7696	28.26/0.7965	28.37/0.8046
	4	21.98/0.6241	—	23.6/0.6984	24.80/0.6995	24.69/0.7108	25.77/0.7259	25.89/0.7260
Zebra	2	30.63/0.8059	—	33.62/0.9157	33.49/0.9122	34.01/0.9186	35.31/0.9278	35.44/0.9284
	3	24.08/0.7351	28.29/0.7769	29.04/0.7782	26.09/0.7145	29.42/0.7954	30.75/0.8214	30.87/0.8216
	4	23.52/0.7259	—	25.91/0.7367	25.78/0.7345	26.97/0.7446	28.09/0.7851	28.17/0.7855

与 DRCN 方法相比,该算法的 PSNR 值平均提升 0.10 dB 左右,虽然效果未明显提高,但是 DRCN 方法采用的是深度递归网络,需要多层卷积多次循环递归,计算量较大,整个网络的训练过程大约需要 6 天的时间。而本文网络的训练过程仅需 13 h。为了充分展现该算法计算量小的优势,以上述测试图像 ppt3 为例,放大因子为 3 时,采用不同迭代次数下的网络训练模型对其进行测试,分析其不同迭代次数下的 PSNR 值和 SSIM 值的变化,如图 10

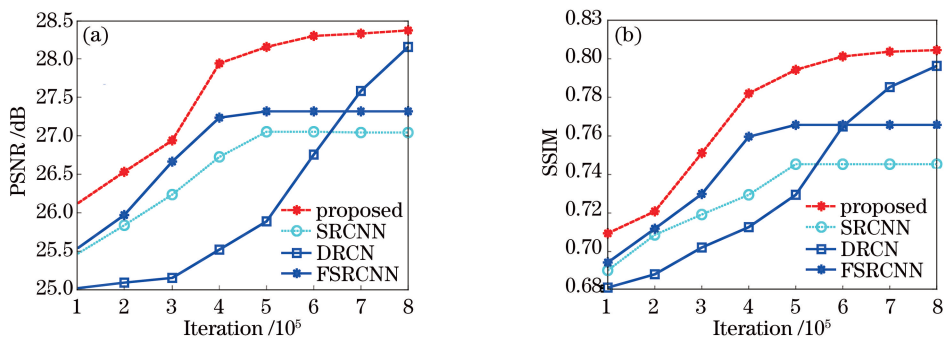


图 10 不同算法的评价指标变化。(a) PSNR; (b) SSIM

Fig. 10 Changes in evaluation indicators of different algorithms. (a) PSNR; (b) SSIM

5 结 论

针对现有卷积网络重建算法存在的参数数量大、纹理边缘不清晰的问题,提出基于边缘修正的多尺度卷积神经网络超分辨率重建算法。设计一种新型的多尺度低频信息共享网络,然后将学习的边缘先验知识与重建好的高分辨率图像进行融合以弥补边缘偏差,最后根据随机梯度下降法,利用反向过程计算梯度,不断更新权重参数使网络达到最优化。对 set5 和 set14 两个数据集进行测试,并在通用测试集上,与现有的 6 种经典算法进行了多组对比实验。结果表明,本文算法重建的图像视觉效果较好,能够消除边缘重影和锯齿现象,增强锐度和对比度,在不同放大倍数下,采用参数共享策略可以大幅缩减网络的参数数量和计算复杂度。

参 考 文 献

- [1] Xiao J S, Liu E Y, Zhu L, *et al.* Improved image super-resolution algorithm based on convolutional neural network [J]. *Acta Optica Sinica*, 2017, 37 (3): 0318011.
肖进胜, 刘恩雨, 朱力, 等. 改进的基于卷积神经网络的图像超分辨率算法 [J]. *光学学报*, 2017, 37 (3): 0318011.
- [2] Bätz M, Eichenseer A, Seiler J, *et al.* Hybrid super-

(a)、(b)所示,由于 Bicubic 算法的测试结果与迭代次数无关,而 A+ 和 ScSR 算法的测试结果仅在迭代次数为 10~100 时才会受到影响,所以表中仅给出 SRCNN、FSRCNN、DRCN 以及本文算法的测试结果。从折线的变化趋势来看,本文算法达到最优效果的收敛速度最快。值得说明的是,DRCN 算法需要迭代 8×10^5 次才能达到的效果,该算法仅需要迭代 5×10^5 次就能达到,充分说明在重建质量和收敛速度权衡下,该算法计算量大幅减少。

resolution combining example-based single-image and interpolation-based multi-image reconstruction approaches [C] // *Proceedings of IEEE International Conference on Image Processing*, 2015: 58-62.

- [3] Zhou J H, Zhou C, Zhu J J, *et al.* A method of super-resolution reconstruction for remote sensing image based on non-subsampled contourlet transform [J]. *Acta Optica Sinica*, 2015, 35(1): 0110001.
周靖鸿, 周瑾, 朱建军, 等. 基于非下采样轮廓波变换遥感影像超分辨重建方法 [J]. *光学学报*, 2015, 35(1): 0110001.
- [4] Lian Q S, Zhang W. Image super-resolution algorithms based on sparse representation of classified image patches [J]. *Acta Electronica Sinica*, 2012, 40 (5): 920-925.
练秋生, 张伟. 基于图像块分类稀疏表示的超分辨率重构算法 [J]. *电子学报*, 2012, 40(5): 920-925.
- [5] Yang J C, Wright J, Huang T, *et al.* Image super-resolution as sparse representation of raw image patches [C] // *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, 2008: 1-8.
- [6] Yang J C, Wright J, Huang T S, *et al.* Image super-resolution via sparse representation [J]. *IEEE Transactions on Image Processing*, 2010, 19(11): 2861-2873.
- [7] Timofte R, De V, van Gool L. Anchored

- neighborhood regression for fast example-based super-resolution [C] // Proceedings of IEEE International Conference on Computer Vision, 2013: 1920-1927.
- [8] Timofte R, de Smet V, van Gool L. A+: Adjusted anchored neighborhood regression for fast super-resolution[C] // Proceedings of Asian Conference on Computer Vision, 2014: 111-126.
- [9] Dong C, Loy C C, He K M, *et al.* Image super-resolution using deep convolutional networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(2): 295-307.
- [10] Dong C, Chen C L, Tang X. Accelerating the super-resolution convolutional neural network [C] // Proceedings of European Conference on Computer Vision, 2016: 391-407.
- [11] Kim J, Lee J K, Lee K M. Deeply-recursive convolutional network for image super-resolution[C] // Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, 2016: 1637-1645.
- [12] 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.
- [13] Chang H, Yeung D Y, Xiong Y M. Super-resolution through neighbor embedding [C] // Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2004, 1: I.
- [14] Aharon M, Elad M, Bruckstein A. *rmK*-SVD: An algorithm for designing overcomplete dictionaries for sparse representation [J]. IEEE Transactions on Signal Processing, 2006, 54(11): 4311-4322.
- [15] Jia Y Q, Shelhamer E, Donahue J, *et al.* Caffe: Convolutional architecture for fast feature embedding [C] // Proceedings of the 22nd ACM International Conference on Multimedia, 2014: 675-678.
- [16] Bevilacqua M, Roumy A, Guillemot C, *et al.* Low-complexity single image super-resolution based on nonnegative neighbor embedding [EB/OL]. [2018-02-05] http://eprints.imtlucca.it/2412/1/Bevilacqua_2012.pdf.
- [17] Zeyde R, Elad M, Protter M. On single image scale-up using sparse-representations[C] // Proceedings of International Conference on Curves and Surfaces, 2010: 711-730.