

基于卷积神经网络的单幅图像超分辨

史紫腾, 王知人, 王瑞, 任福全*

燕山大学理学院, 河北 秦皇岛 066004

摘要 与传统的超分辨算法相比, 基于卷积神经网络的超分辨算法具有较大优势, 但仍存在训练时间较长、重建图像纹理不够清晰等问题。基于此, 在原有的卷积神经网络超分辨重建算法基础上进行了以下优化: 放弃原有的修正线性单元函数, 改用新的激活函数; 改变网络结构, 图像重建由最后的反卷积上采样来实现; 采用自适应矩估计优化算法替换原本的随机梯度下降优化算法。分别在 Set5 和 Set14 测试集上进行对比实验, 实验结果表明, 改进算法在较少的训练时间下, 峰值信噪比最大提高了 2.33 dB, 纹理更加清晰, 边缘更加完整, 重建效果更好。

关键词 图像处理; 深度学习; 卷积神经网络; 超分辨率; 反卷积

中图分类号 TP391

文献标识码 A

doi: 10.3788/LOP55.121001

Single Image Super-Resolution Based on Convolutional Neural Network

Shi Ziteng, Wang Zhiren, Wang Rui, Ren Fuquan*

College of Science, Yanshan University, Qinhuangdao, Hebei 066004, China

Abstract The super-resolution algorithm based on the convolutional neural network has great advantages compared with the traditional super-resolution algorithms. But there are still some problems to be improved, such as long training time, lacking of image texture reconstruction and so on. Owing to this, on the basis of the original convolutional neural network super-resolution reconstruction algorithm, the following optimizations are carried out. The original rectified linear unit function is discarded and the new activation function is used instead. The network structure is changed and image reconstruction is achieved by the final deconvolution upsampling. The original stochastic gradient descent optimization algorithm is replaced by adaptive moment estimation algorithm whose optimizes performance is faster and better. Comparative experiments are carried out on Set5 and Set14 test sets, respectively. The experimental results show that the reconstruction effects of the improved method with less training time are greatly improved on the objective evaluation index, for example, the power signal-to-noise ratio increases up to 2.33 dB, and the texture is clearer, the edges are more complete and the reconstruction effect is better on the subjective visual effects.

Key words image processing; deep learning; convolutional neural networks; super-resolution; deconvolution

OCIS codes 100.3010; 060.4256; 100.3008

1 引言

分辨率是判定图像质量的重要指标, 高分辨率(HR)的图像能够提供更多的图像细节信息, 这些细节信息可以在监控设备、医学影像和卫星图像等实际应用中起到重要的作用。图像超分辨率(SR)是一种由低分辨率(LR)图像重建出 HR 图像的重建技术^[1], 分为基于模型的超分辨算法^[2-4]和基于学习的超分辨算法^[5-15]两种类型。其中, 基于学习的

超分辨算法比前者具有很大的优势, 相关研究也更加具有实用意义, 该方法直接学习 LR-HR 之间的映射关系, 当向网络中输入 LR 图像时, 可以直接预测出对应的 HR 图像。

基于学习的超分辨算法最早由 Freeman 等^[5]提出, 他们首先发现了 LR 和 HR 图像之间的关系可以通过学习来获得, 正是这种通过学习获得的关系可以用来完成图像的重建。因此, 通过构建马尔可夫(MRF)网络^[6]成功学习到 LR 与 HR 图像块

收稿日期: 2018-05-07; 修回日期: 2018-06-05; 录用日期: 2018-06-08

基金项目: 燕山大学基础研究专项课题青年课题(理工 A 类 15LGA016)

* E-mail: renfu_quan@ysu.edu.cn

之间的映射关系,但是这种学习消耗了大量的样本时间和测试搜索时间。随后 Chang 等^[7]提出将局部线性嵌入(LLE)加入到 SR 的研究中,这样需要的样本数量较少,但是容易产生拟合使重建图像不清晰。Yang 等^[8]认为图像具有稀疏性,因此将稀疏表示应用到 SR 中,为了保证 LR 和 HR 图像稀疏系数的一致性,他们联合训练 LR 和 HR 图像块字典,先计算出 LR 图像块的稀疏表示矩阵,再利用 LR 图像块的稀疏系数来完成 HR 图像的重构。该算法可以自适应地选取邻域,避免发生欠拟合或者过拟合,但是训练库完成稀疏编码的过程会消耗大量时间。Dong 等^[9]提出了卷积神经网络超分辨率(SRCNN)算法,通过构建 3 层卷积神经网络来学习 LR 到 HR 图像块之间的非线性映射关系,然后直接由 LR 图像预测出对应的 HR 图像,完成图像重建。SRCNN 构造简单、易于收敛、计算复杂度较低,相较之前算法速度更快且重建图像质量更好,但是其本身存在一些问题,例如训练所需时间较长、重建图像纹理不清晰等,本文旨在对这两个问题进行改善。

本文在原有的 SRCNN 基础上,对网络进行了




图 1 SRCNN 算法框架

Fig. 1 SRCNN algorithm framework

第一层卷积网络的作用为图像块的特征提取和表示,可表示为

$$F_1(Y) = \max(0, W_1^* Y + B_1), \quad (1)$$

式中 W_1 为卷积核, B_1 为 n_1 维的偏差, $*$ 表示卷积运算, W_1 表达式为 $c \times f_1 \times f_1 \times n_1$, 代表 n_1 个 $c \times f_1 \times f_1$ 的卷积核, 其中 c 为图像的通道数(本文只研究单通道, 即 Y 通道重建, 因此 $c=1$)。以 ReLU 函数 $\max(0, x)$ 作为激活函数。

第一层通过卷积操作得到了图像块的 n_1 维特征。在第二层中, 将 n_1 维特征向量映射到 n_2 维特征向量, 可表示为

$$F_2(Y) = \max[0, W_2^* F_1(Y) + B_2], \quad (2)$$

式中 B_2 为 n_2 维的偏差, W_2 表达式为 $n_1 \times f_2 \times f_2 \times n_2$, 代表 n_2 个 $n_1 \times f_2 \times f_2$ 的卷积核。

通过前面两层学习获得了 LR-HR 图像的非线

性映射关系,在客观指标和主观视觉上均优于其他算法。实验过程中,通过加深网络来更好地实现重建,但是在 4 层网络时优化速度和效果下降,在 5 层网络时难以收敛,因此采用简单高效的 3 层网络。本文研究了带参数的线性修正单元(PReLU)和线性修正单元(ReLU)函数的优点并加以改进,构造了一种新的激活函数^[16], 称其为 e-ReLU 函数,用来提高重建质量,并且不再将双三次插值上采样后的图像当作输入图像,而是直接输入 LR 图像,然后通过反卷积^[10]放大来加快训练速度。另外本文选择自适应矩估计优化(Adam)算法^[17]代替随机梯度下降优化(SGD)算法,可以同时提高重建质量和加快训练速度。实验结果表明,本文算法的重建效果不仅在客观指标上优于其他算法,而且在直接视觉效果上图像纹理更加清晰,重建效果更好,训练时间更短。

2 SRCNN

SRCNN 算法由图像块特征提取和表示、非线性映射和重构高分辨率图像的三层卷积神经网络组成。该算法的结构如图 1 所示。

性映射关系,最后一层卷积网络需要利用前面所学习到的非线性映射关系来完成高分辨率图像的重构,可表示为

$$F(Y) = W_3^* F_2(Y) + B_3, \quad (3)$$

式中 B_3 为 c 维的偏差, W_3 表达式为 $n_2 \times f_3 \times f_3 \times c$, 代表 c 个 $n_2 \times f_3 \times f_3$ 的卷积核。

均方误差(MSE)作为 SRCNN 的损失函数来学习获得卷积网络的参数 $\theta = (W_1, W_2, W_3, B_1, B_2, B_3)$, 训练的本质就是对这些参数进行优化。均方误差 $L(\theta)$ 可以表示为

$$L(\theta) = \frac{1}{n} \sum_{i=1}^n \| F(Y_i; \theta) - X_i \|^2, \quad (4)$$

式中 $F(Y_i; \theta)$ 为重建图像, X_i 为原始高分辨率图像,通过最小化 $L(\theta)$ 然后经过反向传播优化每一层参数 $\theta = (W_1, W_2, W_3, B_1, B_2, B_3)$, 得到参数的最

优解, n 为训练样本的数量。

值得注意的是, SRCNN 中没有引入池化层。池化层通常应用于图像分类中, 通过下采样卷积, 在保留主要特征的同时减少参数(降维), 达到平移、旋转等不变性。但是 SR 算法的目的是提高图像分辨率, 获取更多的图像细节信息, 与池化层的作用相反, 因此, 本文算法和 SRCNN 算法中都没有引入池化层。




图 2 本文算法框架图

Fig. 2 Proposed algorithm framework

本文算法的具体步骤可以表示如下:

1) 直接输入 LR 图像 Y , 通过滤波器对 LR 图像进行卷积操作(Conv1 层), 得到 LR 图像的特征向量, 该层输出的特征向量经过 e-ReLU 激活函数处理输出得到 $F_1(Y)$ 。

2) 输入 $F_1(Y)$, 通过滤波器对其进行卷积操作(Conv2 层), 得到 LR-HR 图像之间的映射关系, 并经过 e-ReLU 激活函数处理得到 $F_2(Y)$ 。

3) 输入 $F_2(Y)$, 并对其进行反卷积操作, 反卷积操作与卷积操作是相反的, 它可以看作是卷积的逆过程。在运算过程中, 先将核转置后再进行卷积运算, 最后进行整合得到了输出的 HR 图像。

每层需要设置的参数有卷积核的大小、卷积核的数目、卷积时的步长以及零填充大小, 详细数据记录如表 1 所示。

表 1 各个层的参数设置

Table 1 Parameter settings for each layer

Name	Size	Number	Stride	Padding
Conv1	5×5	64	1	0
Conv2	3×3	32	1	0
Deconv	9×9	1	3	4

3.1 卷积层

SRCNN 中引用的是 ReLU 函数。ReLU 函数虽然在反向传播求误差梯度时收敛速度快, 具有较大优势, 但存在一个缺点, 即“Dead ReLU Problem”, 因此, 在训练过程中可能出现神经元死亡, 导致权重无法进行正常更新。为此, 本文在

3 本文算法

考虑到原卷积神经网络迭代速度慢、训练所需时间长、图像不够清晰等问题, 本文在 SRCNN 上对激活函数、上采样方法和优化方法加以改进, 对卷积核的尺寸加以调整, 并对训练数据进行增强。在保证迭代速度快、训练时间短的同时, 达到更好的超分辨效果。本文算法的结构如图 2 所示。

ReLU 函数的基础上加以改进, 根据 PReLU 函数的优点, 构造了一个新的函数(即 e-ReLU 函数), 可表示为

$$f(x) = \begin{cases} x, & x \geq 0 \\ \exp(ax) - 1, & x < 0 \end{cases} \quad (5)$$

e-ReLU 函数图像如图 3 所示。由图 2 和图 3 可知, 在 $x > 0$ 的区域, e-ReLU 与 ReLU 相同, e-ReLU 函数继承了 ReLU 函数的优点。而在 $x < 0$ 的区域, e-ReLU 函数采用较平滑的指数函数来克服 ReLU 函数的缺点, 即选取合理的初始值 a (本文取值 $a = 1$), 有选择地对负值进行激活, 使得在此区域内保留有用的信息而忽略冗余信息从而达到提高超分辨质量的目的。

因此, 特征提取操作(第一层)可以表示为

$$F_1(Y) = \max(0, W_1^* Y + B_1) + \min(0, W_1^* Y + B_1). \quad (6)$$

非线性映射操作(第二层)可以表示为

$$F_2(Y) = \max[0, W_2^* F_1(Y) + B_2] + \min[0, W_2^* F_1(Y) + B_2]. \quad (7)$$

由于 SRCNN 中输入的是三次插值上采样后的图像, 所以第一层卷积核的尺寸为 9×9 。如果直接输入 LR 图像, 则卷积核的尺寸有所减小, 本文中第一层的卷积核由 9×9 减小为 5×5 , 既可以加快训练速度, 也不影响重建效果。由文献[18]可知, 第二层卷积核越大, 超分辨重建效果则越好, 但是第二卷积核尺寸增加会大幅度增加训练时间。因此,




图3 函数示意图。(a) ReLU;(b) e-ReLU

Fig. 3 Function schematic. (a) ReLU; (b) e-ReLU

从训练速度和重建质量两方面考虑,卷积核的尺寸由 1×1 增大为 3×3 ,滤波器的数量与文献[9]保持一致,即 $n_1=64, n_2=32$ 。

3.2 反卷积层

反卷积操作可以看作是卷积的逆操作,其作用是对图像进行上采样操作。当步长 $s=k$ 时,卷积操作会将输入图像缩小 $1/k$,而 $s=k$ 的反卷积操作则会将输入图像放大 k 倍,并且当 $k>1$ 时,整个网络的复杂度会降为 $1/k^2$,从而缩短训练时间。本文采用反卷积操作来完成重建,通过调整步长来调整采样因子,文献[18]提出适当增加反卷积核的大小可以取得更好的重建质量,因此本文采用相对较大的卷积核来提升重建质量(卷积核由 5×5 增加为 9×9)。该过程可以表示为

$$F(Y) = \sigma[W * F_2(Y) + B], \quad (8)$$

式中 W 表示的是反卷积层的权重参数, $F_2(Y)$ 为第二个卷积层的输出, $F(Y)$ 是反卷积层的输出。步长可以根据网络采样因子的大小调整(步长必须大于1)。另外最后一层的输出图像块的大小可以表示为

$$a = s(I - 1) + R - 2p, \quad (9)$$

式中 I 为输入的反卷积层图像的大小, R 为反卷积核的大小, s 为步长, p 为零填充大小。

3.3 训练与优化

同样使用MSE作为损失函数, SRCNN中采用SGD算法来最小化损失函数,以及更新权重,但是SGD算法优化速度低,并且对超参数的变化非常敏感,导致SRCNN很难训练出最优结果。而Adam优化算法会根据梯度的一阶矩估计和二阶矩估计来动态调整每个参数的学习率,从而保证每一次迭代的学习率都在确定范围内,优化速度和质量均得到提高,因此采用Adam算法来替代SGD算法。

本文中Adam的参数配置为控制权重更新速度的学习率 μ (本文取值为0.001)。学习率的选取非常重要,较大的学习率能够获得更快的学习速度,

而较小的学习率可以获得更好的收敛结果,因此选取合适的学习率可以保证学习速度和收敛结果。一阶和二阶矩估计的指数衰减率 β_1 取值为0.9, β_2 取值为0.999。为了防止出现分母为零的情况,引入一个非常小的参数 ϵ (本文为 10^{-8})。图4为采用Adam优化器的rainLos训练误差值变化图,可以看出,本文算法不仅优化速度快,优化质量也较好。




图4 训练过程中本文算法训练误差值随着迭代次数增加的变化图

Fig. 4 Graph of train loss in the proposed method with the increase of iterations in the training process

4 实验结果和分析

4.1 网络初始化

本文算法的实验环境为Inter Core i5-3230M CPU @2.6 GHz,内存为8 GB,操作系统为64位Win7系统、Matlab R2016a以及深度学习框架Caffe^[19]。

为了提高超分辨的效果,在标准的91幅图像^[8]训练集上进行了扩充。对原始的91幅训练样本进行了旋转(90° 、 180° 和 270°)和缩小(0.5~0.9)处理,经过多角度转换增强了样本的多样性。实验结果表明,本文算法不仅可以加快网络的收敛速度,还可以获取更多的特征信息,使得最终的重建质量更好。

选择双三次插值超分辨(BI)算法、基于稀疏表示的超分辨(ScSR)算法^[8]、SRCNN算法^[9](9-1-5)和

SRCNN-Ex 算法^[10](9-5-5)作为实验对比。实验过程中涉及的缩放因子都取为 3。为了使对比合理有效,选取相同的迭代次数 10^5 的重建结果进行比较。

4.2 综合量化评价

本文选用峰值信噪比 (PSNR) 和结构相似度 (SSIM)^[20] 作为衡量图像质量的重要指标。重建后

的图像和原图之间会存在误差,PSNR 对其误差进行定量计算,PSNR 值越高,两者之间失真越小,即重建质量越好;SSIM 表示重建后的图像和原图的结构相似程度,SSIM 越接近 1,两者结构越相似,即重建结果越好。在 Set 5^[21] 和 Set 14^[22] 测试集上分别进行了测试,结果如表 2 和 3 所示。

表 2 在 Set 5 测试集上的 PSNR 和 SSIM 值

Table 2 PSNR and SSIM values on Set 5 test set

Image	BI		ScSR		SRCNN		SRCNN-Ex		Proposed method	
	PSNR /dB	SSIM	PSNR /dB	SSIM	PSNR /dB	SSIM	PSNR /dB	SSIM	PSNR /dB	SSIM
Baby	33.91	0.90	34.29	0.92	34.83	0.92	34.91	0.92	35.04	0.92
Bird	32.57	0.93	34.11	0.92	33.77	0.94	34.03	0.94	35.46	0.95
Butterfly	24.04	0.82	25.58	0.82	25.00	0.83	25.58	0.84	27.91	0.91
Head	32.88	0.80	33.17	0.80	33.42	0.82	33.42	0.82	33.67	0.83
Women	28.56	0.89	29.94	0.91	29.60	0.91	29.91	0.91	31.22	0.93
Average	30.39	0.87	31.42	0.87	31.32	0.88	31.57	0.89	32.66	0.91

表 3 在 Set 14 测试集上的 PSNR 和 SSIM 值

Table 3 PSNR and SSIM values on Set 14 test set

Image	BI		ScSR		SRCNN		SRCNN-Ex		Proposed method	
	PSNR /dB	SSIM	PSNR /dB	SSIM	PSNR /dB	SSIM	PSNR /dB	SSIM	PSNR /dB	SSIM
Baboon	23.21	0.54	23.50	0.59	23.52	0.60	23.54	0.60	23.62	0.61
Barbara	26.25	0.75	26.39	0.75	26.76	0.78	26.84	0.78	26.57	0.78
Bridge	24.40	0.65	24.80	0.70	24.89	0.70	24.95	0.70	25.14	0.71
Coastguard	26.55	0.61	27.00	0.65	27.00	0.66	27.08	0.66	27.12	0.66
Comic	23.12	0.70	23.90	0.76	23.77	0.75	23.87	0.75	24.53	0.79
Face	32.82	0.80	33.10	0.81	33.38	0.82	33.40	0.82	33.71	0.83
Flowers	27.23	0.80	28.25	0.83	28.06	0.83	28.27	0.83	29.22	0.85
Foreman	31.16	0.91	32.04	0.91	32.09	0.91	32.01	0.91	33.65	0.94
Lenna	31.68	0.86	32.64	0.87	32.53	0.87	32.78	0.88	33.57	0.88
Man	27.01	0.75	27.76	0.78	27.56	0.78	27.72	0.78	28.33	0.80
Monarch	29.43	0.92	30.71	0.93	30.40	0.93	30.87	0.93	32.78	0.95
Pepper	32.38	0.87	33.32	0.87	32.08	0.88	33.30	0.88	34.57	0.89
Ppt3	23.71	0.87	24.98	0.87	24.34	0.88	25.02	0.89	26.24	0.92
Zebra	26.63	0.80	27.95	0.82	27.74	0.84	28.37	0.84	29.11	0.85

由表 2 和表 3 可知,改进算法无论在 PSNR 还是 SSIM 指标上,整体结果都优于 BI、ScSR、SRCNN 和 SRCNN-Ex 算法。在 Set 5 测试集上,平均 PSNR 值比双三次插值、ScSR、SRCNN 和 SRCNN-Ex 算法的结果分别提高了 2.27、1.24、1.34 和 1.09,最少提升了 1.09,最多达到了 2.27,尤其在 Butterfly 上更是提高了 2.33,提升效果非常明显。在 Set 14 测试集上,Monarch 超分辨效果也提高了 1.91。因此,本文算法可以明显提高图像的超分辨重建效果。

4.3 主观效果

图 4~7 所示为部分测试图像的结果图。由主观效果来看,本文方法产生的图像更清晰。由图 5

的局部放大图可以看到,本文算法的重建图眼部更清晰,噪声更少,更接近原图。由图 6 和图 7 的局部放大图可以看到,本文算法的重建图纹理更清晰,边缘更完整,锐度更强,细节更完善。由图 7 的局部放大图可以看到,本文算法的重建图更清晰,细节重建更好,放大效果更好。由图 5~8 可知,本文算法的重建图细节更完善,纹理更清晰,更逼近原图。

4.4 效率对比

由于硬件设备的限制,上述测试时本文算法采取的迭代次数为 10^5 ,此时在 Set 5 测试集上的 PSNR 为 32.66 dB,但是值得注意的是,由文献[10]可知,SRCNN 算法和 SRCNN-Ex 算法在 8×10^8 次迭代时在 Set 5 测试集上的 PSNR 分别为 32.39 dB




图 5 Set 5 中的 baby_GT 重建结果比较。(a)原图;(b) BI/33.91 dB;(c) ScSR/34.29 dB;
(d) SRCNN/34.83 dB;(e) SRCNN-Ex/34.91 dB;(f)本文方法/35.04 dB

Fig. 5 Comparison of the reconstruction of the baby_GT in Set 5. (a) Original image; (b) BI/33.91 dB;
(c) ScSR/34.29 dB; (d) SRCNN/34.83 dB; (e) SRCNN-Ex/34.91dB; (f) proposed method/35.04 dB




图 6 Set 5 中的 butterfly_GT 重建结果比较。(a)原图;(b) BI/24.04 dB;(c) ScSR/25.58 dB;
(d) SRCNN/25.00 dB;(e) SRCNN-Ex/25.58 dB;(f)本文方法/27.91 dB

Fig. 6 Comparison of the reconstruction of the butterfly_GT in Set 5. (a) Original image; (b) BI/24.04 dB;
(c) ScSR/25.58 dB; (d) SRCNN/25.00 dB; (e) SRCNN-Ex/25.58 dB; (f) proposed method/27.91 dB




图 7 Set 14 中的 lenna 重建结果比较。(a)原图;(b) BI/31.68 dB;(c) ScSR/32.64 dB;
(d) SRCNN/32.53 dB;(e) SRCNN-Ex/32.78 dB;(f)本文方法/33.57 dB

Fig. 7 Comparison of the reconstruction of the lenna in Set 14. (a) Original image; (b) BI/31.68 dB; (c) ScSR/32.64 dB;
(d) SRCNN/32.53 dB; (e) SRCNN-Ex/32.78 dB; (f) proposed method/33.57 dB



图 8 Set 14 中的 pepper 重建结果比较。(a)原图;(b) BI/32.38 dB;(c) ScSR/33.32 dB;
(d) SRCNN/32.08 dB;(e) SRCNN-Ex/33.30 dB;(f)本文方法/34.57 dB

Fig. 8 Comparison of the reconstruction of the pepper in Set 14. (a) Original image; (b) BI/32.38 dB; (c) ScSR/33.32 dB;
(d) SRCNN/32.08 dB; (e) SRCNN-Ex/33.30 dB; (f) proposed method/34.57 dB

和 32.75 dB,此时本文算法在 PSNR 值上已经高于 SRCNN 算法 0.27 dB,仅比 SRCNN-Ex 算法低 0.09 dB。为了使本文算法更加具有信服力,将迭代次数增加到 2×10^5 ,此时在 Set 5 测试集上的

PSNR 为 32.77 dB,PSNR 值已经超过 SRCNN-Ex 算法在 8×10^8 次迭代时候的结果(SRCNN 算法的最佳结果),但是在训练时间上却小了几个数量级,各个算法具体的消耗时间如表 4 所示。

表 4 训练时间对比
Table 4 Comparison of training time

Method	1000 times iteration	10^5 times iteration	2×10^5 times iteration	8×10^8 times iteration
SRCNN	477			381600000
SRCNN-Ex	1392			1113600000
Proposed method	141	14100	28200	

由表 4 可知,当本文算法迭代 10^5 时,其重建效果已经超 SRCNN 的最佳结果,训练时间缩短了 $1/27064$,本文算法迭代 2×10^5 时,其重建效果已经超过 SRCNN-Ex 算法的最佳结果,即超过 SRCNN 算法各种模型的最佳结果,此时训练时间缩短了 $1/39489$ 。并且由图 9 可以看到,本文算法在迭代次数达到 2×10^5 时,PSNR 值的上升趋势仍然明显,可以预测随着迭代次数的继续增加,本文算法可以取得更好的重建质量。由此可知,本文算法不仅在重建质量上优于 SRCNN 和 SRCNN-Ex 算法,而且在训练时间上具有较大优势。




图 9 随着迭代次数的增加,本文算法在 Set 5 测试集上平均 PSNR 值变化图

Fig. 9 Change graph of the average PSNR value for proposed algorithm in the Set 5 test set, with the number of iterations

5 结 论

对原有的卷积神经网络超分辨算法存在的重建纹理不清晰、训练时间过长等问题进行了改进,提出了一种重建效果更好、训练时间更短的超分辨算法,并将重建结果与传统的 BI、ScSR、SRCNN 和 SRCNN-Ex 算法进行比较。实验结果表明,本文算法的超分辨重建效果更好,不仅在客观指标上具有很大的提高,而且在视觉上具有更加清晰的边缘和纹理,整体重建效果更好。

对本文算法与 SRCNN 和 SRCNN-Ex 算法进行效率对比,可以看出本文算法大幅度减少了训练时间,更加适合于实际应用。今后的研究方向应该重点考虑在保证训练时间的前提下加深网络的深度,使特征提取更加精确,或者采取其他更有效的网

络模型,以获得更好的重建效果。

参 考 文 献

- [1] Chen J, Gao H B, Wang W G, *et al.* Methods and applications of image super-resolution restoration[J]. *Laser & Optoelectronics Progress*, 2015, 52(2): 020004.
陈健, 高慧斌, 王伟国, 等. 图像超分辨率复原方法及应用[J]. *激光与光电子学进展*, 2015, 52(2): 020004.
- [2] Schultz R R, Stevenson R L. Extraction of high-resolution frames from video sequences [J]. *IEEE Transactions on Image Processing*, 1996, 5(6): 996-1011.
- [3] Hardie R C, Barnard K J, Armstrong E E. Joint MAP registration and high-resolution image estimation using a sequence of undersampled images [J]. *IEEE Transactions on Image Processing*, 1997, 6(12): 1621-1633.
- [4] Patti A J, Altunbasak Y. Artifact reduction for set theoretic super resolution image reconstruction with edge adaptive constraints and higher-order interpolants [J]. *IEEE Transactions on Image Processing*, 2001, 10(1): 179-186.
- [5] Freeman W T, Jones T R, Pasztor E C. Example-based super-resolution[J]. *IEEE Computer Graphics and Applications*, 2002, 22(2): 56-65.
- [6] Zheng L X, He X H, Wu W, *et al.* Learning-based super-resolution technique [J]. *Computer Engineering*, 2008, 34(5): 193-195.
郑丽贤, 何小海, 吴炜, 等. 基于学习的超分辨率技术[J]. *计算机工程*, 2008, 34(5): 193-195.
- [7] Chang S G, Cvetkovic Z, Vetterli M. Locally adaptive wavelet-based image interpolation[J]. *IEEE Transactions on Image Processing*, 2006, 15(6): 1471-1485.
- [8] 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.
- [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, Loy C C, Tang X O. Accelerating the super-resolution convolutional neural network [C] // European Conference on Computer Vision, 2016: 391-407.
- [11] Li S M, Lei G Q, Fan R. Depth map super-resolution reconstruction based on convolutional neural networks [J]. Acta Optica Sinica, 2017, 37(12): 1210002.
李素梅, 雷国庆, 范如. 基于卷积神经网络的深度图超分辨率重建 [J]. 光学学报, 2017, 37(12): 1210002.
- [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] Lai W S, Huang J B, Ahuja N, *et al.* Deep Laplacian pyramid networks for fast and accurate super-resolution [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2017: 5835-5843.
- [14] Ledig C, Theis L, Huszár F, *et al.* Photo-realistic single image super-resolution using a generative adversarial network [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2017: 105-114.
- [15] Lim B, Son S, Kim H, *et al.* Enhanced deep residual networks for single image super-resolution [C] // IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2017: 1132-1140.
- [16] He K M, Zhang X Y, Ren S Q, *et al.* Delving deep into rectifiers: surpassing human-level performance on ImageNet classification [C] // IEEE International Conference on Computer Vision, 2015: 1026-1034.
- [17] Kingma D P, Ba J. Adam: a method for stochastic optimization [C] // International Conference for Learning Representations, 2015.
- [18] Dong C, Deng Y B, Loy C C, *et al.* Compression artifacts reduction by a deep convolutional network [C] // IEEE International Conference on Computer Vision, 2015: 576-584.
- [19] Jia Y Q, Shelhamer E, Donahue J, *et al.* Caffe: Convolutional architecture for fast feature embedding [C] // ACM International Conference on Multimedia, 2014: 675-678.
- [20] 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.
- [21] Bevilacqua M, Roumy A, Guillemot C, *et al.* Low-complexity single-image super-resolution based on nonnegative neighbor embedding [C] // British Machine Vision Conference, 2012: 1-10.
- [22] Zeyde R, Elad M, Protter M. On single image scale-up using sparse-representations [C] // International Conference on Curves and Surfaces, 2010: 711-730.