

改进的基于卷积神经网络的图像超分辨率算法

肖进胜^{1,2}, 刘恩雨¹, 朱 力¹, 雷俊锋¹

¹武汉大学电子信息学院, 湖北 武汉 430072;

²地球空间信息技术协同创新中心, 湖北 武汉 430079

摘要 针对现有的基于卷积神经网络的图像超分辨率算法参数较多、计算量较大、训练时间较长、图像纹理模糊等问题, 结合现有的图像分类网络模型和视觉识别算法对其提出了改进。在原有的三层卷积神经网络中, 调整卷积核大小, 减少参数; 加入池化层, 降低维度, 减少计算复杂度; 提高学习率和输入子块的尺寸, 减少训练消耗的时间; 扩大图像训练库, 使训练库提供的特征更加广泛和全面。实验结果表明, 改进算法生成的网络模型取得了更佳的超分辨率结果, 主观视觉效果和客观评价指标明显改善, 图像清晰度和边缘锐度明显提高。

关键词 显微; 图像超分辨率; 深度学习; 卷积神经网络; 卷积核参数

中图分类号 TN911.73 文献标识码 A

doi: 10.3788/AOS201737.0318011

Improved Image Super-Resolution Algorithm Based on Convolutional Neural Network

Xiao Jinsheng^{1,2}, Liu Enyu¹, Zhu Li¹, Lei Junfeng¹

¹Electronic Information School, Wuhan University, Wuhan, Hubei 430072, China;

²Collaborative Innovation Center of Geospatial Technology, Wuhan, Hubei 430079, China

Abstract An improved image super-resolution algorithm based on the convolutional neural network is proposed to overcome many problems such as more parameters, a large amount of calculation, longer training time and fuzzy texture combined with the present image classification network model and visual recognition algorithms. The proposed algorithm adjusts the convolution kernel size to reduce parameters in the original three layers of convolutional neural network. Pool layers are added to reduce the dimension and decrease the computational complexity. The learning rate and size of input sub-blocks are improved to reduce the training time. The training database is expanded to provide extensive and comprehensive characteristics. Experimental results show that the proposed algorithm achieves good super-resolution results, and the subjective visual effect and objective evaluation indices are both improved obviously. The image resolution and edge sharpness are enhanced significantly.

Key words microscopy; image super-resolution; deep learning; convolutional neural network; parameters of convolution kernels

OCIS codes 180.5810; 100.6640; 100.3010; 200.4260

1 引 言

图像超分辨率(SR)是从一幅或者多幅成像质量较差的低分辨率(LR)图像中获取高分辨率(HR)图像的技术, 该技术能够提供视觉效果更好的图像, 提供更多的图像信息^[1-4], 主要分为 4 种类型, 即基于插值^[5]、重建^[6]、增强^[7]和学习^[8]的方法。其中, 基于学习的图像超分辨率方法近些年来发展比较火热, 该方法利用图像数据库或图像本身, 通过学习获得高、低分辨率图像之间的关联, 并将其作为先验约束条件生成高分辨率图像。基于学习的方法可分为基于自学习和基外部数据库的方法。

在基于自学习方面, Yang 等^[9]的方法利用了图像的自相似性学习, 只使用单一输入的图像, 而不依赖于

收稿日期: 2016-09-27; 收到修改稿日期: 2016-11-07

基金项目: 国家自然科学基金(61471272)、湖北省自然科学基金(2016CFB499)

作者简介: 肖进胜(1975—), 男, 博士, 副教授, 主要从事视频图像处理、计算机视觉等方面的研究。

E-mail: xiaojis@whu.edu.cn

一个外在的训练图像,该方法计算简单高效。Zhang 等^[10]结合框架结构调制和稀疏表示,解决了相同和不同尺寸的图像结构特点的问题。Huang 等^[11]扩大了内部块的搜索空间,引入仿射变换适应图像中几何形状的变化,但在自然风景图像处理中,效果与其他方法相比并无明显优势。Choi 等^[12]将低分辨率的图像中提取的块再分成多个子块,提取低分辨率与高分辨率图像中的对应关系,获得了更好的边缘处理效果。

在基于外部数据库方面,2002年,Freeman 等^[13]提出基于样本学习的图像超分辨率方法,通过在外部图像数据库中使用最近邻域搜索的方式获得向量集。Timofte 等^[14]结合稀疏学习字典和邻域嵌入的方法,提出固定邻域回归的方法,在保持图像质量的同时,提高了算法的处理速度。Yang 等^[15]利用稀疏表示,使计算的复杂度大幅降低,并且对有噪声的输入图像处理效果比较好。同时,机器学习以及神经网络的应用日趋广泛,尤其是在视觉识别、图像分类以及图像超分辨率等方面。Dong 等^[16]将卷积神经网络用于图像超分辨率中,将整个过程视为三层卷积层的超分辨卷积神经网络(SRCNN),将图像特征从低分辨率空间非线性映射至高分辨率空间内,重建图像质量更优。

本文将深度学习理论应用于图像超分辨率,研究卷积神经网络用于图像超分辨率重建方法的优化。受文献[16]的启发,借鉴深度卷积网络的大规模视觉识别算法的网络模型,修改神经网络结构,加深卷积网络;加入池化层,同时调整卷积核大小,并减少参数,对训练速度进行改善。理论分析和实验结果表明,改进算法取得了更优的超分辨率效果。

2 基于深度学习的图像超分辨率算法

基于深度学习^[17]的图像超分辨率方法依靠外部库,通过深度学习神经网络获得相应的先验信息,以实现图像的超分辨率,主要分为以下几个步骤:

- 1) 建立训练所需的外部图像库;
- 2) 构建网络模型;
- 3) 对训练集数据进行训练,估计与优化网络参数,得到输入数据的特征表达及先验知识;
- 4) 将低分辨率图像输入重建模型,输出高分辨率图像。

卷积神经网络不仅能有效减少网络的训练参数,简单化神经网络,而且具有很强的适应性。其中,最具代表性的是超分辨率卷积神经网络^[16],其由三层卷积层构成,分别为特征提取、非线性映射和高分辨率图像重构。该算法框架如图 1 所示。




图 1 SRCNN 算法框架

Fig. 1 Structure of SRCNN algorithm

特征提取是从初始图像中提取块,得到输入图像的特征图 $F_1(\mathbf{Y})$,可表示为

$$F_1(\mathbf{Y}) = \max(0, \mathbf{W}_1 * \mathbf{Y} + \mathbf{B}_1), \quad (1)$$

式中 \mathbf{Y} 表示初始高分辨率图像, $*$ 表示卷积运算, \mathbf{W}_1 为卷积核, \mathbf{B}_1 为神经元偏置向量。卷积得到的特征图再经过 ReLU 激活函数 $\max(0, x)$ 进行处理^[18]。设 f_1 为单个滤波器的尺寸, c 是输入图像的通道数(只对 \mathbf{Y} 通道进行处理,因此 $c=1$),如果有 n_1 个卷积核,那么 \mathbf{W}_1 的尺寸为 $c \times f_1 \times f_1 \times n_1$ 。

非线性映射将特征向量从低分辨率空间变换至高分辨空间,过程可表示为

$$F_2(\mathbf{Y}) = \max [0, \mathbf{W}_2 * F_1(\mathbf{Y}) + \mathbf{B}_2], \quad (2)$$

式中 \mathbf{W}_2 为卷积核, \mathbf{B}_2 为神经元偏置向量。若有 n_2 个卷积核, 卷积后生成 n_2 维的特征图, 即 \mathbf{W}_2 的尺寸为 $n_1 \times f_2 \times f_2 \times n_2$ 。

高分辨率图像重构利用之前得到的基于块的输出特征图来生成最终的高分辨率图像, 过程可表示为

$$F(\mathbf{Y}) = \mathbf{W}_3 * F_2(\mathbf{Y}) + \mathbf{B}_3, \quad (3)$$

式中 \mathbf{W}_3 包含 c 个卷积核, 则其尺寸大小为 $n_2 \times f_3 \times f_3 \times c$, \mathbf{B}_3 为一个维数为 c 的偏置向量。 \mathbf{W}_3 可视为一个均值滤波器, 整个重构过程是一个线性操作过程。

SRCNN 的参数可以表示为 $\Theta = \{\mathbf{W}_1, \mathbf{W}_2, \mathbf{W}_3, \mathbf{B}_1, \mathbf{B}_2, \mathbf{B}_3\}$, 整个网络的训练过程就是对参数的估计和优化。通过最小化 $F(\mathbf{Y}; \Theta)$ 与 \mathbf{X} 之间的误差得到参数最优解。给定高分辨率图像集合 $\{\mathbf{X}_i\}$ 与其相应低分辨率图像集合 $\{\mathbf{Y}_i\}$, 均方误差 $L(\Theta)$ 为

$$L(\Theta) = \frac{1}{n} \sum_{i=1}^n \| F(\mathbf{Y}_i; \Theta) - \mathbf{X}_i \|^2, \quad (4)$$

式中 n 为训练集数目, $\{\mathbf{X}_i\}$ 通过裁剪生成随机排列的子块作为训练阶段的输入数据。为了得到 $\{\mathbf{Y}_i\}$, 对得到的子图像经过高斯滤波模糊之后进行下采样, 然后采用双三次插值(BI)放大至与原子图像尺寸大小一致。

与其他算法相比较, SRCNN 算法在主观评价以及峰值信噪比(PSNR)和结构相似性(SSIM)等客观指标上具有明显优势, 其对图像超分辨率处理的运行速度较快。对于 14 幅大小为 $492 \text{ pixel} \times 446 \text{ pixel}$ 的图像, SRCNN 算法处理一幅图像的平均时间为 $0.39 \text{ s}^{[16]}$, 而其他对比算法的平均时间为 $1 \sim 100 \text{ s}$ 。然而, SRCNN 算法在以下几个方面可以进一步改进: 1) 调整卷积核大小和参数, 降低计算复杂度; 2) 不增加计算量的基础上, 适当增加卷积层数, 使提取的特征更准确细致, 提升超分辨率图像质量; 3) 迭代次数过大会使训练过程耗时较长, 尝试修改网络, 使得网络在尽可能小的迭代次数时就能达到好的训练效果, 减少训练时间。

3 改进的基于卷积神经网络的图像超分辨率算法

牛津大学 VGG 小组将卷积神经网络运用在图像分类与视觉识别中, 获得了令人满意的成效, 在 ImageNet 大赛中名列前茅。在该卷积神经网络的基础之上, 借鉴 VGG 小组提出的基于深度卷积网络的大规模视觉识别算法 VGG_ILSVRC_16_layers 模型、ImageNet 图像分类大赛的优秀网络模型 GoogLeNet, 对基于卷积神经网络的图像超分辨率算法进行改进, 网络结构框图如 2 所示。

改进后的训练过程为: 1) 训练集图像经过卷积层后得到的特征图经过激活函数; 2) 经过池化层; 3) 对特

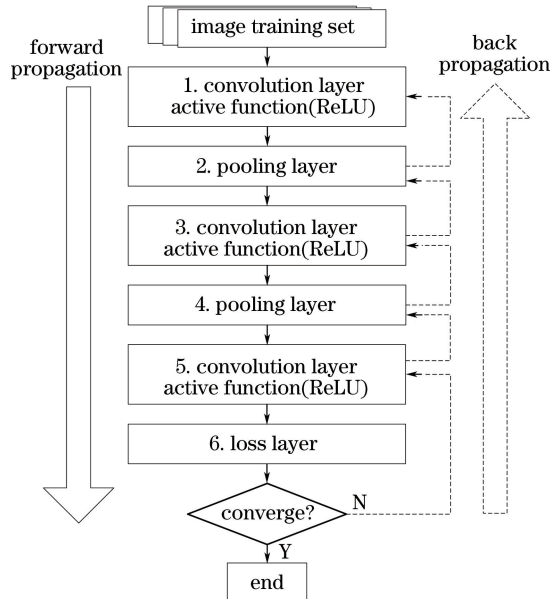


图 2 基于卷积神经网络的图像超分辨率算法框架

Fig. 2 Structure of image super-resolution algorithm based on convolutional neural network

征进行卷积和激活函数运算;4)再次经过池化层;5)通过卷积层和激活函数运算,计算损失层,训练至结果收敛时结束。

3.1 卷积层

卷积层主要考虑卷积核尺寸、卷积核数目以及学习率对模型效果和速度的影响。

3.1.1 卷积核尺寸

SRCNN 中提出的三层卷积为 9-1-5 模型,改进算法为 3-3-3 模型。为了与 SRCNN 算法性能进行比较,同样采用三层卷积层,但是与 SRCNN 不同在于改进后每一层卷积层的卷积核大小都是 3×3 。

SRCNN 算法在第一层卷积核尺寸选择 9×9 ,实际上, 3×3 已经能够足够覆盖图像的特征。根据 VGG 小组对深度卷积网络的实验结果和经验,对于 VCC_ILSVRC_16_layers 模型,第一层使用 3×3 大小卷积核,能够有效减少参数数目。因此,改进算法将第一层的卷积核尺寸设为 3×3 。

SRCNN 算法中,第二层卷积核尺寸越大,超分辨率效果越好,但同时会增大运算量。因此,改进算法中将第二层卷积核尺寸选择为 3×3 ,既能提高分辨率效果,又能保证计算量不会大幅增加。

由于第二层增大卷积核尺寸使参数增加,同样出于对计算量的考虑,将第三层卷积核尺寸选择为 3×3 (SRCNN 算法为 5×5)。而缩小第三层卷积核尺寸可能会影响超分辨率图像的质量,所以分别对 3-3-3 模型和 3-3-5 模型的卷积网络进行训练和测试。迭代次数为 5×10^5 ,实验结果表明,在训练阶段,3-3-5 模型每迭代 1000 次比 3-3-3 模型仅平均多耗时 7 s;而测试阶段输出超分辨率图像的平均 PSNR 仅比 3-3-3 模型高 0.13 dB。

基于上述经验,权衡处理结果和运算速率,选择 3-3-3 模型,这样既增大了卷积核尺寸以提升处理效果,同时在该基础上减小第一、三层卷积核尺寸,以控制参数数目,降低运算的复杂度。

3.1.2 卷积核数目

第一层和第二层卷积核个数 n_1, n_2 与卷积核尺寸共同影响超分辨率效果。在 SRCNN 算法中 9-1-5 模型中 $n_1 = 64, n_2 = 32$ 。改进算法在 3-3-3 模型下,对不同大小 n_1 和 n_2 进行测试,最终选取 $n_1 = 64, n_2 = 64$ 。

针对改进算法 3-3-3 模型在相同迭代次数、相同学习率和不同卷积核个数 n_1, n_2 对图 3 测试图像进行超分辨率处理,得到超分辨率图像的 PSNR 值,以测试图像 Bird 为例,均采用迭代次数为 5×10^4 、学习率为 10^{-3} ,得到对比数据如表 1 所示。

表 1 不同卷积核个数测试 PSNR 值

Table 1 PSNR values of different convolution kernels numbers

| Convolution kernels number | $n_1 = 64, n_2 = 32$ | $n_1 = 64, n_2 = 64$ | $n_1 = 128, n_2 = 64$ |
|----------------------------|----------------------|----------------------|-----------------------|
| PSNR | 33.59 | 33.66 | 30.14 |

同时,出于对图像超分辨率过程中信息量和计算量的考虑,SRCNN 选取的子图像尺寸为 33×33 ,适当地增大了输入子块的尺寸,经过测试实验表明,输入子块尺寸适度加大,训练速度提升,时间减少。

3.1.3 学习率

训练时对权重不断的更新优化,在梯度项前所乘系数,即为学习率。学习率太小,则收敛过慢;学习速率太大,代价函数会振荡。SRCNN 给出的学习率比较低,第一、二层为 10^{-4} ,第三层为 10^{-5} ,因此,实验中将学习率提高至 10^{-3} 。

对学习率进行进一步的测试。利用所设计算法在相同迭代次数、不同学习率下得到的网络学习模型对测试图像进行超分辨率处理,得到各超分辨率图像的 PSNR 值。以 Bird 图为例,采用 5×10^4 次迭代,对不同学习率得到的网络模型进行测试和记录,结果如表 2 所示。可见,学习率为 10^{-3} 时效果最好。

表 2 不同学习率测试 PSNR 值

Table 2 PSNR values of different learning rates

| Learning rate | 0.00001 | 0.00005 | 0.0001 | 0.0005 | 0.001 | 0.0015 | 0.002 |
|---------------|---------|---------|--------|--------|--------------|--------|-------|
| PSNR | 30.99 | 33.15 | 33.18 | 33.35 | 33.66 | 13.97 | 13.78 |

3.2 池化层

SRCNN 没有使用池化层,在第一层和第二层卷积层之后加入池化层。引用池化层之后能够减少卷积层输出的特征向量,降低维度,提高训练速度,并且不容易出现过拟合现象,改善了结果^[19]。引入池化层后,

网络达到了 5 层的深度,深层次的网络结构更有利于学习图像数据更本质的表达。同时,池化层可以减少参数数目,有利于简化网络,并提高参数训练效率。

如果选择图像中的连续范围作为池化区域,并且只是池化相同的隐藏单元产生的特征,那么,这些池化单元就具有平移不变性,即图像经历了一个小的平移之后,依然会产生相同的特征。对于池化层,输入特征图的数目不会发生变化,但是每个输出特征图的尺寸会减小,该过程的本质就是下采样,可表示为

$$\mathbf{x}_j^l = f [\beta_j^l \text{down}(\mathbf{x}_j^{l-1}) + b_j^l], \quad (5)$$

式中 \mathbf{x}_j^l 和 \mathbf{x}_j^{l-1} 分别为当前层和前一层的第 j 个特征图, $\text{down}(\cdot)$ 表示下采样, $f(\cdot)$ 为激活函数, β_j^l 为乘性偏置项, b_j^l 为加性偏置项,实验中令 $\beta_j^l = 1, b_j^l = 0$ 。由于输入图像中临近 $n \times n$ 大小的图像块求和产生的影响,所以输出特征图会整体缩小。

采用最大池化^[20]可以将输入图像分割为一系列不重叠的矩阵,然后对每个子区域输出最大值。

4 实验结果及分析

实验环境包括硬件设备和软件配置,测试所用计算机配置为 Intel Core i7-5820K CPU @ 3.30 GHz x12, GPU 为 NVIDIA GeForce TITAN X, 内存为 16 GB。实验平台搭载的操作系统为 64 位 ubuntu 14.04 LTS、Matlab R2014a、CUDA Toolkit 7.0 和 OpenCV 3.0。

选择典型的传统双三次插值(BI)方法、稀疏编码(ScSR)算法^[15]、基于样本学习的固定邻域回归的图像超分辨率算法(SR_NE_ANR)算法^[14]以及 SRCNN 算法^[16]进行对比测试。采用的图像训练库来源于 ImageNet 数据库,数据库增大到 800 幅。为了保证实验结果的合理客观,选择 6 幅具有代表性,且纹理细节丰富的图像进行测试和对比。测试图像如图 3 所示,其中,图 3 (a)~(e)来源于网络数据库,图 3 (f)为手机拍摄的图像。每幅图像的分辨率如表 3 所示,所有测试的低分辨率图像放大 9 倍。



图 3 测试图像。(a) 蝴蝶; (b) 海星; (c) 女性; (d) 荷花; (e) 鸟; (f) 小黄人

Fig. 3 Test images. (a) Butterfly; (b) starfish; (c) woman; (d) lotus; (e) bird; (f) minion

表 3 测试图像分辨率

Table 3 Resolution of the test images

| | Butterfly | Starfish | Woman | Lotus | Bird | Minion |
|------------------------------|-----------|-----------|-----------|-----------|-----------|-----------|
| Resolution / (pixel × pixel) | 256 × 256 | 256 × 256 | 228 × 344 | 413 × 309 | 288 × 288 | 330 × 330 |

为了便于对比和测试,采用的图像退化数学模型为对原始高分辨率图像高斯模糊后实行下采样,生成低分辨率图像。经由插值法放大的初始高分辨率图像输入到离线训练后的卷积神经网络模型之中,经过网络学习和优化后的模型参数的处理生成最终的高分辨率图像。实验过程中每种算法选取的缩放因子均为 3,为了进行客观合理的比较,选取相同迭代次数的网络模型的学习结果进行对比测试。由于设备平台等的限制, SRCNN 与本文算法选取的最大迭代次数均为 5×10^5 。

4.1 主观效果

图 4~7 给出了 5 种算法对 4 幅测试图像分别处理的结果。

从图 4~7 给出的处理结果可见, ScSR 算法、SR_NE_ANR 算法、SRCNN 算法和改进算法(均为基于学习的图像超分辨率算法)处理结果要明显优于传统的 BI 算法。主观上来看, ScSR 算法、SR_NE_ANR 算法和 SRCNN 算法都得到了较好的超分辨率图像,但是对于某些测试图像,改进算法的图像锐度相比其他几种算法在边缘保持方面结果更好。

图 4~6 分别对蝴蝶翅膀颜色变化的部分、海星的花纹和人眼进行局部放大, BI 算法、ScSR 算法得到的




图 4 不同算法对蝴蝶图的处理结果。(a) 输入图像；(b) BI；(c) ScSR；(d) SR_NE_ANR；(e) SRCNN 算法；(f) 本文算法

Fig. 4 Results comparison of butterfly image with different algorithms. (a) Input image; (b) BI; (c) ScSR; (d) SR_NE_ANR; (e) SRCNN; (f) proposed algorithm




图 5 不同算法对海星图的处理结果。(a) 输入图像；(b) BI；(c) ScSR；(d) SR_NE_ANR；(e) SRCNN；(f) 本文算法

Fig. 5 Results of starfish image with different algorithms. (a) Input image; (b) BI; (c) ScSR; (d) SR_NE_ANR; (e) SRCNN; (f) proposed algorithm




图 6 不同算法对女性图的处理结果。(a) 输入图像；(b) BI；(c) ScSR；(d) SR_NE_ANR；(e) SRCNN；(f) 本文算法

Fig. 6 Results of women image with different algorithms. (a) Input image; (b) BI; (c) ScSR; (d) SR_NE_ANR; (e) SRCNN; (f) proposed algorithm



图 7 不同算法对荷花图的处理结果。(a) 输入图像；(b) BI；(c) ScSR；(d) SR_NE_ANR；(e) SRCNN；(f) 本文算法

Fig. 7 Results of lotus image with different algorithms. (a) Input image; (b) BI; (c) ScSR; (d) SR_NE_ANR; (e) SRCNN; (f) proposed algorithm

结果十分模糊，边缘不清晰，尤其在图 4 的蝴蝶翅膀黄黑色的边缘、图 5 中海星的白色和棕色的边缘以及图 6 中人眼和皮肤的边缘；SR_NE_ANR 算法、SRCNN 算法的实验结果略微能看清边缘，但是仍与原图差距较大；改进算法边缘处理比用以上 4 种算法处理的结果更加清晰，边缘更加完整，边缘保持方面更好，锐度更强，与原图效果最接近。图 7 中对莲花的花和叶的边缘进行部分放大，可以看出，在 BI 算法、ScSR 算法、SR_NE_ANR 算法放大后效果十分模糊，而 SRCNN 算法和本文算法处理后边缘较清晰。

4.2 客观效果

客观评价指标主要是 PSNR 和图像 SSIM^[7]。前者对处理后的结果跟原图相比的误差进行定量计算, PSNR 愈高,说明失真愈小;SSIM 越逼近 1,说明处理后的结构与原图结构极为近似,即生成的结果图更好。

采用以上两个指标对 5 种算法的处理结果进行客观评价,表 4 给出了客观测试的结果。除了 SR_NE_ANR 算法对 Bird 测试图像的客观指标略高于本文算法之外,其余测试结果均表明,本文算法获取的 PSNR 和 SSIM 均高于 BI 算法、ScSR 算法和 SRCNN 算法,充分说明该算法产生的结果与原图特别接近,处理效果更好。

表 4 客观指标对比
Table 4 Comparison of objective index

| Image | Index | BI | ScSR | SR_NE_ANR | SRCNN | Proposed |
|-----------|-------|--------|--------|---------------|--------|---------------|
| Butterfly | PSNR | 24.04 | 25.44 | 25.90 | 26.52 | 27.80 |
| | SSIM | 0.8216 | 0.8557 | 0.8717 | 0.8726 | 0.9034 |
| Starfish | PSNR | 27.00 | 28.04 | 28.05 | 28.42 | 28.77 |
| | SSIM | 0.8121 | 0.8485 | 0.8475 | 0.8519 | 0.8641 |
| Woman | PSNR | 28.56 | 29.82 | 30.33 | 30.44 | 30.46 |
| | SSIM | 0.8896 | 0.9095 | 0.9169 | 0.9144 | 0.9171 |
| Lotus | PSNR | 27.11 | 28.34 | 28.74 | 28.72 | 29.30 |
| | SSIM | 0.8421 | 0.8750 | 0.8839 | 0.8774 | 0.8895 |
| Bird | PSNR | 32.58 | 33.89 | 34.60 | 34.19 | 34.49 |
| | SSIM | 0.9256 | 0.9424 | 0.9488 | 0.9426 | 0.9462 |
| Minion | PSNR | 28.32 | 29.26 | 29.80 | 29.93 | 30.59 |
| | SSIM | 0.8656 | 0.8819 | 0.8921 | 0.8859 | 0.8952 |

为了突出改进算法相对 SRCNN 算法的有效提高,还进行了一系列的训练和学习过程,得到了多种网络学习模型的结果。针对 SRCNN 算法和改进算法在相同迭代次数下得到的两种不同的网络学习模型对上述测试图像进行超分辨率处理,得到相应的 PSNR 和 SSIM 值,以测试图像蝴蝶图为例,采用不同迭代次数得到的网络模型对其进行测试和记录,最终得到其 PSNR 和 SSIM 的变化趋势,分别如图 8 和 9 所示。为了便于对比,图中加入 BI 算法、ScSR、SR_NE_ANR 算法的测试结果,此处需要说明的是,BI 算法测试结果与迭代次数无关;ScSR、SR_NE_ANR 算法仅在 10~100 次迭代下对测试结果有影响,在 5×10^4 次迭代以上时对测试结果没有影响。




图 8 不同算法得到的 PSNR

Fig. 8 PSNR of different algorithms




图 9 不同算法得到的 SSIM

Fig. 9 SSIM of different algorithms

由图 8 和 9 可以得到,无论是 PSNR 还是 SSIM,改进算法得到的结果整体优于 SRCNN 算法和 BI 算法;相较于 SRCNN 算法,在训练过程中,改进算法达到最优效果的收敛速度比较快,如图 9 所示, SRCNN 算法需要 5×10^5 次迭代才能达到的效果,改进算法只需要大约 6×10^4 次迭代,提升幅度达到 88%。以上测试结果从客观方面说明本文算法的超分辨率效果更好。

4.3 效率对比

该卷积网络的复杂度为 $O\{f_1^2 n_1 + n_1 f_2^2 n_2 + n_2 f_3^2\}$ 。对于 SRCNN 网络,其一次迭代的计算复杂度为 8032。对于改进的卷积神经网络结构,一次迭代的计算复杂度为 38016。因此其每次迭代训练时参数计算

量比 SRCNN 大,即单次迭代训练消耗更多时间。但值得注意的是, SRCNN 算法需要 5×10^5 次迭代才能达到到的效果,所提算法仅需 6×10^4 次迭代就能达到同样训练效果。平均耗时和总耗时情况如表 5 所示。

表 5 训练总耗时对比

Table 5 Comparison of total training time

| Method | 1000 times iteration / s | 6×10^4 times iteration /s | 5×10^5 times iteration /s |
|----------|--------------------------|------------------------------------|------------------------------------|
| SRCNN | 62.98 | 3778.8 | 31490 |
| Proposed | 88.78 | 5326.8 | |

所以,虽然改进算法计算量比 SRCNN 算法略大,但从训练过程的整体来看,改进算法在低于 SRCNN 迭代次数的一个数量级的条件下,既保证了比 SRCNN 更好的超分辨率效果,同时训练总耗时大幅减少,效率高于 SRCNN 算法。

5 结 论

通过理论剖析卷积神经网络的学习过程,对基于卷积神经网络的图像超分辨率算法提出了一系列的改进。针对改进算法进行了一系列的实验测试工作,并和传统的 BI 算法以及 SRCNN 算法进行了对比。结果表明,改进算法的超分辨率结果较好,图像边缘保持的比较好,边缘锐度更高,整体看起来更清晰。

采用 PSNR 和 SSIM 对各种算法进行定量测试,结果表明,改进算法能够产生更佳的超分辨率效果;与 SRCNN 算法相比,在迭代次数较少的情况下能达到更优的结果,其能够大幅减少训练时间;在相同的迭代次数下,改进算法的计算复杂度比 SRCNN 略高。因此,下一步研究内容,应该考虑进一步降低计算复杂度以提高运行速度。

参 考 文 献

- [1] Juefei-Xu F, Savvides M. Single face image super-resolution via solo dictionary learning [C]. IEEE International Conference on Image Processing (ICIP), 2015: 2239-2243.
- [2] Xiao J, Pang G, Zhang Y, *et al.* Adaptive shock filter for image super-resolution and enhancement [J]. Journal of Visual Communication and Image Representation, 2016, 40: 168-177.
- [3] Li Min, Cheng Jian, Le Xiang, *et al.* Super-resolution based on sparse dictionary coding [J]. Journal of Software, 2012, 23(5): 1315-1324.
李 民, 程 建, 乐 翔, 等. 稀疏字典编码的超分辨率重建 [J]. 软件学报, 2012, 23(5): 1315-1324.
- [4] Zhang K, Tao D, Gao X, *et al.* Learning multiple linear mappings for efficient single image super-resolution [J]. IEEE Transactions on Image Processing, 2015, 24(3): 846-861.
- [5] Bätz M, Eichenseer A, Seiler J, *et al.* Hybrid super-resolution combining example-based single-image and interpolation-based multi-image reconstruction approaches [C]. 2015 IEEE International Conference on Image Processing (ICIP), 2015: 58-62.
- [6] Zhou Jinghong, Zhou Cui, Zhu Jianjun, *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 隼, 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.
- [7] Xiao Jinsheng, Gao Wei, Peng Hong, *et al.* Detail enhancement for image super-resolution algorithm based on SVD and local self-similarity [J]. Chinese Journal of Computers, 2016, 39(7): 1393-1406.
肖进胜, 高 威, 彭 红, 等. 基于局部自相似性和奇异值分解的超采样图像细节增强 [J]. 计算机学报, 2016, 39(7): 1393-1406.
- [8] Lian Qiusheng, Zhang Wei. 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.
- [9] Yang C Y, Huang J B, Yang M H. Exploiting self-similarities for single frame super-resolution [C]. Asian Conference on Computer Vision, 2010: 497-510.
- [10] Zhang Y, Liu J, Yang W, *et al.* Image super-resolution based on structure-modulated sparse representation [J]. IEEE Transactions on Image Processing, 2015, 24(9): 2797-2810.

- [11] Huang J B, Singh A, Ahuja N. Single image super-resolution from transformed self-exemplars [C]. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015: 5197-5206.
- [12] Choi J S, Bae S H, Kim M. Single image super-resolution based on self-examples using context-dependent subpatches [C]. 2015 IEEE International Conference on Image Processing (ICIP), 2015: 2835-2839.
- [13] Freeman W T, Jones T R, Pasztor E C. Example-based super-resolution [J]. IEEE Computer Graphics and Applications, 2002, 22(2): 56-65.
- [14] Timofte R, de Smet V, van Gool L. Anchored neighborhood regression for fast example-based super-resolution [C]. Proceedings of the IEEE International Conference on Computer Vision, 2013: 1920-1927.
- [15] Yang J, Wright J, Huang T S, *et al.* Image super-resolution via sparse representation [J]. IEEE Transactions on Image Processing, 2010, 19(11): 2861-2873.
- [16] 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.
- [17] Le Cun Y, Bengio Y, Hinton G. Deep learning [J]. Nature, 2015, 521(7553): 436-444.
- [18] Nair V, Hinton G E. Rectified linear units improve restricted Boltzmann machines [C]. Proceedings of the 27th International Conference on Machine Learning (ICML-10), 2010: 807-814.
- [19] He K, Zhang X, Ren S, *et al.* Spatial pyramid pooling in deep convolutional networks for visual recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1904-1916.
- [20] Scherer D, Müller A, Behnke S. Evaluation of pooling operations in convolutional architectures for object recognition [C]. International Conference on Artificial Neural Networks, 2010: 92-101.