

# 基于优化卷积神经网络的图像超分辨率重建

王 民, 刘可心\*, 刘 利, 杨润玲

西安建筑科技大学信息与控制工程学院, 陕西 西安 710055

**摘要** 与以往两类单帧图像的超分辨率重建方法相比,卷积神经网络超分辨率(SRCNN)技术以其端到端的映射架构大幅提高了运行效率与复原精度,然而网络的层数限制以及收敛性能使得部分图像的恢复效果不及基于样例的重建方法。针对网络优化问题,提出了一种将粒子群优化(PSO)算法与SRCNN相结合的方法,利用PSO算法对网络权重进行初始化,同时结合梯度下降(GD)算法对权值进行修正,使得PSO算法的全局搜索能力与GD算法的局部寻优能力相融合。分别对set5、set14数据集和雾霾天气下模糊图片进行对比实验,结果表明,所提算法不仅能以较少参数来获得较高性能的网络,其重建效果优于已有的4种算法,而且对边缘的锐化能力更强。

**关键词** 图像处理; 图像重建技术; 卷积神经网络; 粒子群优化; 梯度下降法

**中图分类号** TP183; TP389.1 **文献标识码** A

**doi:** 10.3788/LOP54.111005

## Super-Resolution Reconstruction of Image Based on Optimized Convolution Neural Network

Wang Min, Liu Kexin, Liu Li, Yang Runling

*College of Communication and Information Engineering, Xi'an University of Architecture and Technology, Xi'an, Shaanxi 710055, China*

**Abstract** Compared with the previous two types of single-frame image super-resolution reconstruction algorithm, the super-resolution with convolution neural network (SRCNN) has greatly improved the operational efficiency and recovery accuracy with its end-to-end mapping structure. However, the number of hidden layers and the convergence performance of the network make the recovery effects of some images worse than the example-based reconstruction algorithms. In view of the problem of network optimization, the algorithm of combining particle swarm optimization (PSO) with SRCNN is proposed. PSO is used to initialize the network weight and the gradient descent (GD) algorithm is used to correct the weight which can combine the global search capability of PSO and the local search ability of GD. The experimental results of set5, set14 datasets and the blurred images under haze weather respectively show that the proposed algorithm can not only use less parameters to obtain higher performance network, but also has better reconstruction effect than the existing four algorithms, and the ability to sharpen edges is stronger.

**Key words** image processing; image reconstruction techniques; convolution neural network; particle swarm optimization; gradient descent algorithm

**OCIS codes** 100.3010; 200.4260; 060.4256; 100.3008

## 1 引 言

图像是一种可供人眼读取的直观信息,其质量的优劣决定了后续识别和检测等操作的难易。但硬件采集设备通常受到固有分辨率的限制<sup>[1]</sup>,致使图像的分辨率在传输过程中大幅下降,尤其在雾天能见度较低<sup>[2]</sup>

**收稿日期:** 2017-05-25; **收到修改稿日期:** 2017-06-20

**基金项目:** 国家自然科学基金(61373112)、住房和城乡建设部科学技术项目(2016-R2-045)、陕西省自然科学基金基础研究计划(2014JM8348)

**作者简介:** 王 民(1959—),男,本科,教授,主要从事智能信息处理方面的研究。E-mail: wangmin1329@163.com

\* **通信联系人.** E-mail: m18602907837@163.com

的情况下,内容变得更加模糊。如何提高图像分辨率是近年来的研究重点。

与传统的图像复原和增强技术不同,超分辨率(SR)重建技术通过提高分辨率来改善图像质量,并广泛应用于监控视频取证、城建图集检索、医学影像分析等领域。单帧图像的SR重建方法主要分为<sup>[3]</sup>:基于无样本的SR技术以及基于样例的SR技术。基于无样本的SR技术通过系列低分辨率图像中的互补信息来重建高分辨率图像,最早利用插值放大方法来提高图像质量,随后依据空间频率<sup>[4]</sup>提取图像特征进而实现重建<sup>[5]</sup>;或结合先验知识来细化边缘信息,通常使用最大后验概率(MAP)估计法,但计算量过大。基于样例的SR技术根据信号相关性<sup>[6]</sup>,通过提取训练样本集的高频信息来预测高分辨率图像,是当前最先进的算法<sup>[7]</sup>。代表性算法如稀疏编码(SC)<sup>[8]</sup>以及锚定邻域回归(ANR)<sup>[9]</sup>,都具有更佳的重建效果。但以上方法均存在模型框架局限性大,无法进行省时计算等问题。

卷积神经网络(CNN)<sup>[10]</sup>因其模型结构简单,可用于解决图像分割、物体识别等计算机视觉领域的难题<sup>[11]</sup>。2014年,学者们类比于稀疏编码,巧妙地建立起低分辨率与高分辨率图像之间的CNN端对端映射,提出了超分辨率卷积神经网络(SRCNN)<sup>[7]</sup>模型,以隐含层的自动学习代替字典建模操作,大幅提升了重建精度与运行速度。为进一步加深对低质量图像的复原研究,隐含层的结构改造<sup>[12]</sup>成为了近年来改善网络性能的主要策略。但与图像分类不同,随着网络深度的加深,SRCNN会出现收敛过快和精度下降<sup>[13]</sup>等问题,如何优化网络参数成为了主要难题。

本文基于CNN的超分辨率技术,利用粒子群优化(PSO)算法对网络权值进行初始化,同时结合梯度下降(GD)法对权重进行优化,最终实现一种超分辨率重建算法。通过对通用测试图库<sup>[7-9]</sup>的重建实验,验证了该算法的可行性;通过对雾霾天气下设备所拍摄模糊图片的重建实验,验证了该算法的实用性。

## 2 基于CNN的超分辨率技术

深度学习的崛起使得机器能够以人的思维来感受身边事物。作为深度学习在人工神经网络方面的深入,CNN是一种有监督的模型架构,尤其适合处理二维数组问题<sup>[14]</sup>。其基本框架如图1所示,对卷积层的处理能够准确提取边缘信息以及更为丰富的细节特征;对下采样层(池化层)的处理节省了储存空间,提高了运行效率;通过全连接层的特征融合后,由输出层显示结果。




图1 CNN基本框架

Fig. 1 Basic framework of CNN

引入修正线性单元(ReLU)激励函数,使得网络具备稀疏性<sup>[15]</sup>。仿照SC重建技术,将性能卓越的CNN应用在图像的超分辨率技术中,便生成了SRCNN模型。

### 2.1 SRCNN模型及其原理

以单帧图像为例,重建网络结构如图2所示,主要包含:1)作为输入的低分辨率块的提取;2)建立非线性映射结构;3)重建高分辨率图像。

为了保持输入与输出图像大小一致,采用双三次插值法作为网络框架外唯一执行<sup>[7]</sup>的预处理操作进行图像的预调整。处理完的低分辨率图像 $Y_i$ 作为输入通过如下网络:

1) 图像块的提取与特征表示。类似于采用训练过的一组基(如haar,离散余弦变化等)来表示输入提取的图像块,使用优化后与基相关的一组滤波器来卷积图像,此卷积层表示为

$$F_1(Y_i) = h(W_1 * Y_i + b_1) = \max(0, W_1 * Y_i + b_1), \quad (1)$$

式中 $h(x)$ 选用ReLU激励函数, $W_1$ 对应一组包含权重的滤波器,规模为 $n_1 \times c \times f_1 \times f_1$ ,数量 $n_1$ 与特征图个数一致, $c$ 为图片通道数,实验中选择1,仅使用亮度通道以便后续算法对比实验, $f_1 \times f_1$ 相当于局部感受




图2 SRCNN 模型结构

Fig. 2 Model structure of SRCNN

野,即卷积核大小。经过第一层处理后,从低分辨率图像中提取的每个图像块被表示为一组包含多个特征图的高维向量。

2) 非线性映射。将首层处理后被表示为  $n_1$  维的向量,以非线性映射转化为  $n_2$  维向量,因此第二层卷积表示为

$$F_2(Y_i) = \max[0, W_2 * F_1(Y_i) + b_2], \quad (2)$$

式中  $W_2$  的规模为  $n_2 \times n_1 \times f_2 \times f_2$ 。根据 SC 算法中图像变换尺寸一致原则,滤波器大小选为  $1 \times 1$  来进行非线性映射操作。

3) 图像重建。将卷积提取的高分辨率特征块进行聚合,以传统求平均的方式对特征图进行滤波操作,最后的卷积层表示为

$$F(Y_i) = W_3 * F_2(Y_i) + b_3. \quad (3)$$

通过 3 次不同形式的卷积操作,权重和偏置项得以优化,不但简化了网络,而且克服了 SC 算法无前馈过程的缺点。非线性算子的全前馈性可以帮助网络进行有效计算,同时非线性运算符可以认为是全连接层。

## 2.2 SRCNN 训练

损失函数决定了 CNN 网络模型的优劣,通常选用均方误差(MSE)函数来描述。对于 SRCNN,定义损失函数为

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

式中  $W$  和  $b$  为网络结构中的权重与偏置项,  $n$  为训练样本数,  $X$  为真实图像,  $F(Y)$  为映射图像。重建图像与真实图像间对应的 MSE 函数最小时,不仅有利于获得较高的峰值信噪比(PSNR)<sup>[16]</sup>,而且便于得到最优参数。为了使其最小化,往往利用基于反向传播(BP)神经网络的梯度下降法<sup>[17]</sup>来修正网络参数  $W$  与  $b$ 。SRCNN 反向传播网络需要根据 BP 规则来计算权值关于 MSE 函数的偏导数<sup>[18]</sup>,残差  $\delta$  计算过程表示为

$$\delta_j^l = \beta_j^{l+1} [\max'(0, Y_j^l) \circ u_p(\delta_j^{l+1})], \quad (5)$$

式中  $u_p(Y) = Y \otimes 1_{n \times n}$  表示上采样操作,通常利用克罗内克积来实现。 $\delta_j^l$  为  $l$  层第  $j$  个特征图,  $\beta_j^{l+1}$  为可训练参数,“ $\circ$ ”表示逐元素相乘。

由于  $p_i^{l-1}$  为  $x_i^{l-1}$  在卷积时与权重逐元素相乘后的样板,  $\eta$  为学习率,那么通过链式法则计算参数更新可表示为

$$\frac{\partial L}{\partial W_{ij}^l} = \sum_{u,v} (\delta_j^l)_{u,v} (P_j^{l-1})_{u,v}, \quad \frac{\partial L}{\partial b_j} = \sum_{u,v} (\delta_j^l)_{u,v}, \quad (6)$$

$$W_j = W_j - \eta \frac{\partial L}{\partial W_{ij}^l}, \quad b_j = b_j - \eta \frac{\partial L}{\partial b_j}. \quad (7)$$

## 3 粒子群优化算法

目前大多采用高斯分布<sup>[7]</sup>或编码器赋值<sup>[19]</sup>等方法来进行权值初始化操作,但这些方法的不定性会影响重建精度。而粒子群优化算法因其收敛性与寻优能力<sup>[20]</sup>可设置良好的网络初始参数,因此采用 PSO 算法

优化 BP 神经网络来初始化 SRCNN 权值。

PSO 算法作为模拟鸟类觅食的启发式全局优化算法<sup>[21]</sup>,同遗传算法(GA)相比具有更快的收敛性,而且寻优参数使用较少,目前已广泛应用于神经网络训练领域。该算法将每个待优化的解即权值看作种群中的粒子,在迭代过程中计算个体适应度并择优更新位置。假设  $M$  维空间内有  $S$  个微粒,那么第  $k$  个粒子的空间位置表示为  $x_k = (x_{k1}, x_{k2}, \dots, x_{kM})$ ,  $k=1, 2, 3, \dots, S$ , 飞行速度表示为  $V_k = (V_{k1}, V_{k2}, \dots, V_{kM})$ , 飞行路线历史最佳位置表示为  $P_k = (P_{k1}, P_{k2}, \dots, P_{kM})$ , 群体最佳位置表示为  $P_g = (P_{g1}, P_{g2}, \dots, P_{gM})$ , 对于每代第  $m$  维( $1 \leq m \leq M$ )粒子的速度和位置进行更新:

$$V_{km}(t+1) = \omega V_{km}(t) + a_1 r_1 [p_{km} - x_{km}(t)] + a_2 r_2 [p_{gm} - x_{km}(t)], \quad (8)$$

$$x_{km}(m+1) = x_{km}(t) + V_{km}(t+1), \quad (9)$$

式中  $t$  为迭代次数,  $\omega$  为惯性权重,  $a_1$  和  $a_2$  为常数,称为加速因子,  $r_1$  和  $r_2$  为  $[0, 1]$  间的常数。

## 4 基于 PSO-SRCNN 的图像超分辨率重建

根据上述分析,发现经由 SRCNN 重建后的低分辨率图像  $Y_i$  具有较好的实时性与稳健性;利用 GD 算法修正权值后,损失函数趋于最小,但训练网络却易陷入局部最优。为了克服上述缺陷并提升重建性能,急需引入 PSO 算法来寻找不同权重的初始集合。

将 GD 算法的局部寻优能力与 PSO 算法的全局搜索能力相结合,主要分为 SRCNN 网络的优化阶段与重建阶段 2 个模块。3 层卷积模版的权值更新与初始值选取决定了重建性能,因此在第一次优化过程中,以图 2 所示的网络模型为基础,选取部分训练集图片作为对象。类比于 PSO 空间维度数,将输入图像划分为  $M$  小块,并将划分后的块视作 SRCNN 重建网络中的  $M$  个输入。对于 SRCNN 网络,每层由多个特征图组成,每张特征图所包含的多个神经元共享同一权值。滤波器决定了网络特征图个数,根据滤波器的个数便可以确定相应隐含层的权值阈值数目。输入层和输出层的维度相当于其本身的神经元个数,分别代表着输入层、输出层与隐含层之间的连接权值数。3 层间的权值总数构成初始种群规模。

以当前最优适应度个体  $P_g$ 、 $P_k$  来初始化原始网络,低分辨率块经过提取与映射后,被转化为包含丰富特征图的高维向量。为防止出现过拟合现象,使用(5)式计算网络残差  $\delta$ ;同时根据(6)、(7)式来实时更新参数。由此得到每一个 SRCNN 在图像块上的 MSE,并以此作为适应度函数,寻找当前个体的最佳适应度,进而实现 PSO 算法执行周期内的一次图像重建。

依据以上初始化方法,逐步按照(8)、(9)式进行权值迭代寻优。多次训练 SRCNN 并不断修正权值,直至选出性能最优时的参数,并以此构建最佳重建网络。在重建阶段,将所有图集经过训练后的网络进行重建,由此实现混合算法。具体流程如图 3 所示。

1) 预训练阶段将每幅真值图像  $\{X_i\}$  裁剪为  $32 \times 32$  大小的子块,并视其为多幅小图像输入。之后应用高斯模糊并对图像进行下采样处理,结合双三次插值法选择合适因子  $U_{\text{upscale}}$  进行放大,据此得到低分辨率图像样本  $\{Y_i\}$ 。

2) 建立如图 2 训练网络,将多个子图像块作为多个输入。网络权值以及阈值被视为粒子并构成初始种群,以 PSO 算法挑选出的最优适应度个体进行网络初始化。

3) 基于 BP 算法,以梯度下降法优化训练图集参数,利用残差作为检验历史,找出最佳权重后执行 PSO 框架进行迭代寻优。计算每个粒子的最佳适应度,并挑出本次种群的最佳解。

4) 重复执行 PSO-SRCNN 框架,直至找到全局最优解,并以此得到最优权值以及阈值。

5) 在优化后的最佳网络中对测试图像进行重建操作。

## 5 分析与讨论

研究基础:为验证本文算法的可行性,实验环境为 Intel core i7、NVIDIA Geforce 840M,操作系统为 64 位的 Windows 8.1。SRCNN 依赖的配置基础是 Anaconda Python 2.7.10, CUDA 6.5, Theano 0.7, VS 2013 ultimate, Matlab 2014a 以及深度学习函数库和 Sheffield 大学开发的遗传算法工具箱。

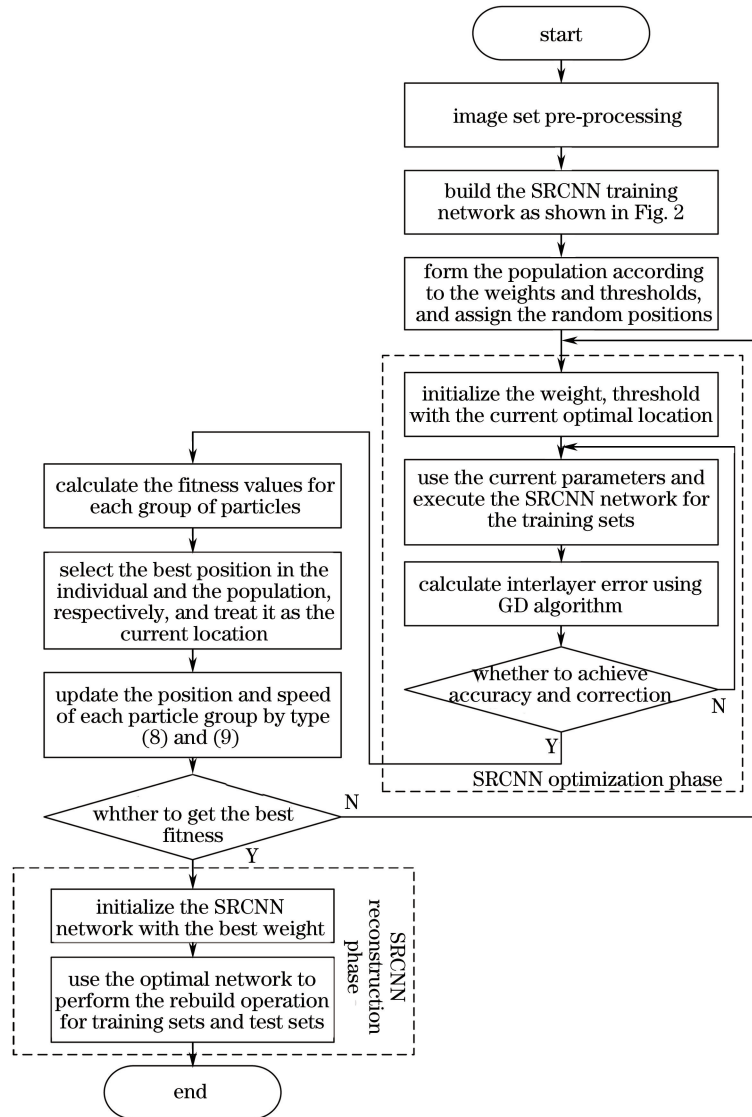


图3 基于 PSO-SRCNN 的图像重建算法流程图

Fig. 3 Flowchart of image reconstruction algorithm based on PSO-SRCNN

研究对象:1) 为保证对比实验的参数统一,使用与文献[7-9]相同的图集进行测试,训练图集包含 91 张图片共 24800 块子图像,测试图像部分示例如图 4(a)所示;2) 对雾霾天气下手机所拍摄的 253 张有关建筑物的图像进行测试,根据能见度分为较好与较差两类,统一规格为  $428 \times 505$ 。每一类别采取 5 折交叉验证方式,将数据集分组为  $E_1, E_2, \dots, E_5$ ,依次将  $E_q, q=1, 2, \dots, 5$  作为测试集,其余  $q-1$  组作为训练集进行验证,部分测试图像如图 4(b)所示。

评估方式:由于全参考单帧图像有原图作为对比,而无参考图像只能进行直接评估的差异性,利用 PSNR 对 set5 和 set14 数据集中全参考单帧图像的性能进行评价;利用 PSNR 和空间光谱熵(SSEQ)<sup>[22-23]</sup>相结合的形式对无参考图像的重建性能进行评价。SSEQ 算法于 2014 年提出,结合了空间域与频域熵值,通过图像特征结合支持向量机来计算失真概率,其框架如图 5 所示,实验中 SSEQ 范围选取  $[0, 100]$ 。

参数选择:考虑到运行时间,三层滤波器  $f_1 \times f_1, f_2 \times f_2, f_3 \times f_3$  的初始值分别为  $9 \times 9, 1 \times 1, 5 \times 5$ ,  $n_1$  选择 64,  $n_2$  选择 32。由于末尾卷积层的学习率对收敛性的影响,仿照文献[6]网络前两层学习率  $\eta_1 = \eta_2 = 10^{-4}$ ,最后一层学习率  $\eta_3 = 10^{-5}$ ,图片通道  $c=1$ ,种群规模为 40,  $a_1 = a_2 = 2$ ,空间维数与图像划分块一致。首先针对 set5 和 set14 对  $U_{\text{upscale}}$  的取值进行研究,并得到多次实验的平均结果记录,如表 1 所示。

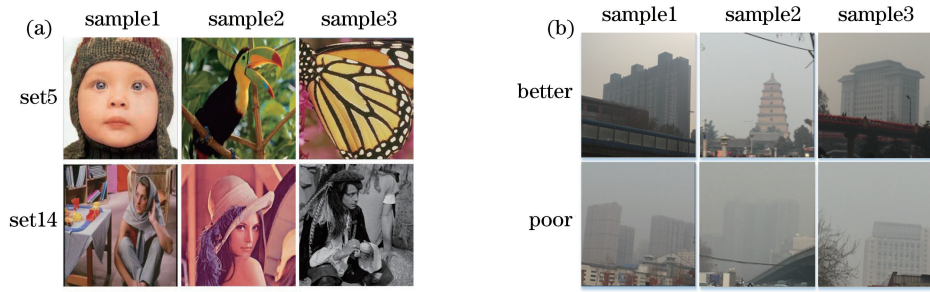


图4 测试样本集。(a)小型图库；(b)模糊照片

Fig. 4 Test sample sets. (a) Small image library; (b) blurred photos




图5 SSEQ 图像质量评估框架图

Fig. 5 Frame diagram of SSEQ image quality assessment

表1  $U_{\text{upscale}}$  的选择对网络最佳适应度的影响Table 1 Effect of  $U_{\text{upscale}}$  selection on the optimal fitness of the network

Iteration	$U_{\text{upscale}} = 2$		$U_{\text{upscale}} = 3$		$U_{\text{upscale}} = 4$	
	Set5 /dB	Set14 /dB	Set5 /dB	Set14 /dB	Set5 /dB	Set14 /dB
1	11.97	10.82	15.94	16.46	19.77	16.40
2	22.83	20.97	25.71	23.08	26.04	25.99
3	31.66	30.03	30.55	28.11	29.13	26.03
4	34.98	31.79	32.09	29.21	30.57	27.58
5	36.61	32.45	32.54	29.17	30.58	27.61
6	36.62	32.53	32.54	29.19	30.52	27.61

由表1可知,利用 PSO 算法对 SRCNN 网络的权值初始化后,可以在较少的迭代次数内使 PSNR 值趋于稳定。当  $U_{\text{upscale}} = 2$  时,其 PSNR 值最高,但是收敛稳定性和测试能力不如  $U_{\text{upscale}} = 3$  时高;当  $U_{\text{upscale}} = 4$  时,收敛稳定性较高但 PSNR 值较低,而且每一帧图像的重建时间较长。综上所述,以下讨论中  $U_{\text{upscale}}$  的取值为 3。

### 5.1 全参考单帧图像的重建

将本文算法分别与双三次算法、SC 算法、ANR 算法、SRCNN 算法等超分辨率重建的代表性方法进行对比实验,并把 bird 图像重建后的视觉对比效果记录于图 6。

SC 重建算法的运行时间比其他算法长,而基于 SRCNN 架构的算法执行时间较短。由图 6 可知,基于 CNN 的重建图像可读度更高。将局部鸟喙区域放大后,发现经由 PSO-SRCNN 算法重建后的图像边缘更加尖锐,质量相对较优。对重建效果进行量化评估,将 set5 图集的 PSNR 值记录于表 2。

表2 set5 图像重建性能对比

Table 2 Comparison of reconstruction performance of set5 image

Set5	PSNR of reconstruction algorithm /dB				
	Bicubic	SC	ANR	SRCNN	PSO-SRCNN
Baby	33.91	34.29	35.13	35.01	35.13
Bird	32.58	34.11	34.60	34.91	35.34
Butterfly	24.04	25.58	25.90	27.58	27.69
Head	32.88	33.17	33.63	33.55	33.65
Woman	28.56	29.94	30.33	30.92	30.90
Average	30.39	31.42	31.92	32.39	32.54




图 6 5 种算法对 bird 图像重建的视觉效果对比

Fig. 6 Comparison of visual effects for bird image reconstruction by five algorithms

对比实验中,本文算法的 PSNR 平均值最高,比 SC 算法高出 1.12 dB,比 ANR 算法高出 0.62 dB,比基本 SRCNN 算法高出 0.15 dB。尽管本文算法对 Woman 图片的重建效果比 SRCNN 算法低 0.02 dB,但其余图像的重建效果均得到提升,更接近于真实分辨率。对 set14 的性能测试结果以折线图形式呈现,如图 7 所示。

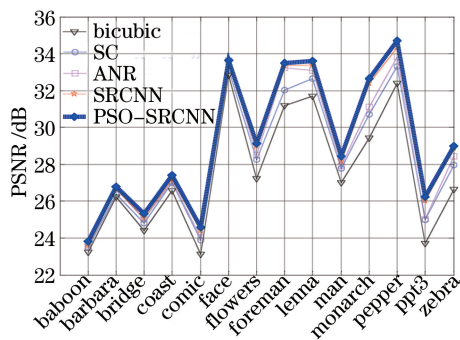


图 7 不同算法对 set14 图像的重建性能对比

Fig. 7 Comparison of reconstruction performance of set14 image by different algorithms

由图 7 可知,使用本文算法学习图像特征后,其重建性能更高。在 face 图像的重建中, SRCNN 算法的性能不如 ANR 算法,但使用本文算法重建后,其图像质量得到明显改善, PSNR 值提高了 0.04 dB。 PSO-SRCNN 算法对 lena 以及 pepper 两幅图像的重建效果较为突出,比 SRCNN 算法分别高出 0.22 dB 和 0.34 dB。 14 幅图像的重建 PSNR 平均值如表 3 所示,应用 PSO-SRCNN 算法比 SC 算法高出 0.88 dB,比 ANR 算法高出 0.54 dB,比基本 SRCNN 算法高出 0.19 dB。

表 3 Set14 图片重建方法 PSNR 均值

Table 3 PSNR mean of Set14 image reconstruction method

dB

Method	Bicubic	SC	ANR	SRCNN	PSO-SRCNN
PSNR	27.54	28.31	28.65	29.00	29.19

## 5.2 雾霾天气下无参考模糊图像的重建

为进一步测试本文算法对于无参考且固有分辨率较低图像的重建性能,进而检验其复原程度以及去雾能力,将雾霾天气下拍摄的建筑物图片作为研究对象,继续选用双三次算法、SC 算法、ANR 算法和 SRCNN 算法作为对比,重建后的视觉效果如图 8 所示。

与图像增强去雾技术相比,利用图像超分辨率技术重建的性能量化指标更高,抑制振铃效应的能力更强。图 8(a)是在雾霾天能见度相对较好时拍摄的大雁塔图像通过不同算法重建后的效果对比图,通过塔尖放大图可以看出,本文算法更能细化建筑物边缘,PSNR 值也最高;图 8(b)是在能见度较差情况下对建筑物应用不同算法重建后的对比图,通过局部放大图可以发现,本文算法不仅将建筑顶层的窗内边缘结构描绘清晰,而且 PSNR 值也明显高于其他算法。最后,对 2 类图像的重建性能进行量化,如表 4 所示。

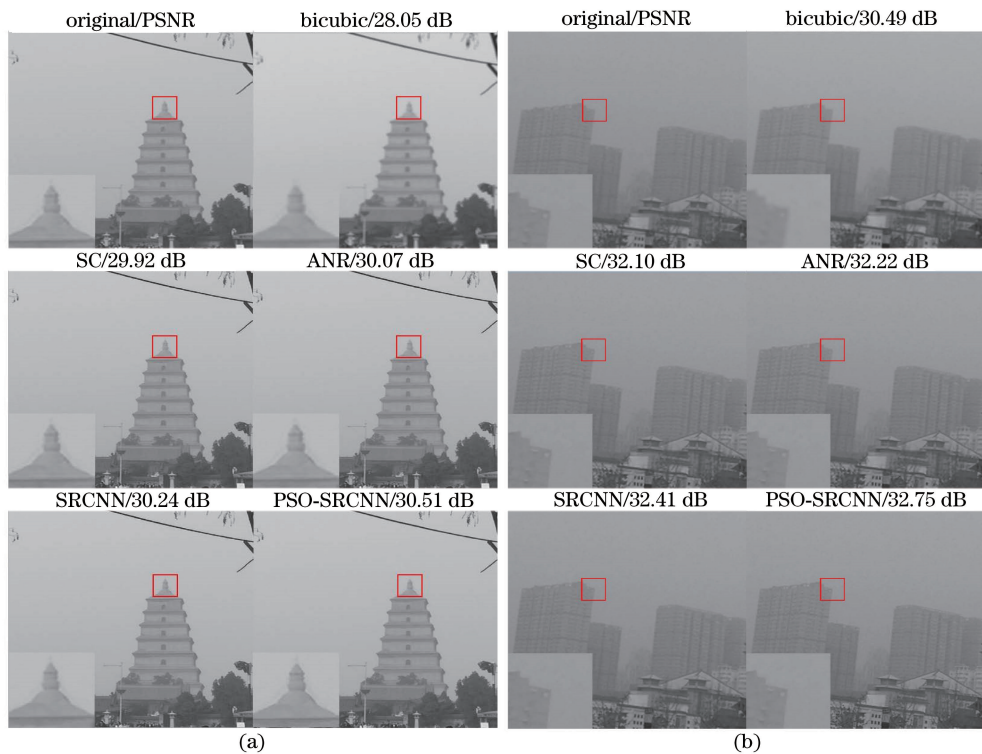


图 8 雾霾天气下 5 种重建算法的视觉效果。(a)能见度较好;(b)能见度较差

Fig. 8 Visual effects of five reconstruction algorithms in haze. (a) Better visibility; (b) poor visibility

表 4 不同算法对模糊图像的重建性能分析

Table 4 Reconstruction performance analysis of blurred images by different algorithms

Algorithm	PSNR /dB			SSEQ		
	Better	Poor	Average	Better	Poor	Average
Bicubic	28.02	30.25	29.14	49.07	40.69	44.88
SC	29.34	32.52	30.93	43.73	38.84	41.29
ANR	29.66	32.58	31.12	42.92	38.03	40.48
SRCNN	29.83	32.7	31.27	41.17	37.42	39.30
PSO-SRCNN	30.01	32.89	31.45	39.09	36.27	37.68

由表 4 可知,PSO-SRCNN 算法相较于其他算法更具重建优势,在较差情况下的重建效果普遍优于较好情况下的效果,PSNR 值比 SRCNN 算法平均高出 0.18 dB,SSEQ 值比 SRCNN 算法减少 1.62。本文算法不仅



对 SRCNN 网络性能进行了改善,同时也表现出了在雾霾天气下进行图像去雾的能力。

## 6 结 论

提出了一种将粒子群优化算法与基于 CNN 的超分辨率技术相结合的重建算法。利用粒子群优化算法对 SRCNN 的权重进行初始化,并基于 BP 神经网络,结合梯度下降法来修正权值,既弥补了 SRCNN 层数限制所导致的个别图像复原保真度较低的问题,也避免了数据训练陷入局部最优。实验结果表明,本文算法不仅重建稳健性高于其他算法,而且满足实时性要求,对边缘的锐化效果最强;且相比于其他重建算法,本文算法更能有效抑制振铃效应,在去雾重建以及恶劣环境下物体检测等棘手问题中具有应用潜力。

研究主要侧重于新算法的性能测试,未考虑去雾后的图像虽然边缘清晰,但对对比度无法满足人眼判断准则的问题。下一步将基于大气退化物理模型,结合 PSO-SRCNN 算法优势,对图片进行精准的重建处理,同时将针对模糊视频进行重建研究。

## 参 考 文 献

- [1] Fan Chao, Sun Ningning, Xia Xu. Super-resolution reconstruction based on image sequences[J]. Infrared Technology, 2010, 32(5): 279-282.  
樊超, 孙宁宁, 夏旭. 基于序列图像的超分辨率重建[J]. 红外技术, 2010, 32(5): 279-282.
- [2] Yang Aiping, Bai Huanghuang. Nighttime image defogging based on the theory of Retinex and dark channel prior[J]. Laser & Optoelectronics Progress, 2017, 54(4): 041002.  
杨爱萍, 白煌煌. 基于 Retinex 理论和暗通道先验的夜间图像去雾算法[J]. 激光与光电子学进展, 2017, 54(4): 041002.
- [3] Su Heng, Zhou Jie, Zhang Zhihao. Survey of super-resolution image reconstruction methods[J]. Acta Automatica Sinica, 2013, 39(8): 1202-1213.  
苏衡, 周杰, 张志浩. 超分辨率图像重建方法综述[J]. 自动化学报, 2013, 39(8): 1202-1213.
- [4] Chen Jian, Gao Huibin, Wang Weiguo, *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.
- [5] 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, 周璀, 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.
- [6] Tang Chaoying, Chen Yueting, Li Qi, *et al.* Adaptive temporal compressive sensing for video based on signal correlation[J]. Acta Optica Sinica, 2016, 36(10): 1010001.  
唐超影, 陈跃庭, 李奇, 等. 基于信号相关性的自适应时域视频压缩感知重建方法[J]. 光学学报, 2016, 36(10): 1010001.
- [7] Dong C, Loy C G, He K, *et al.* Learning a deep convolutional network for image super-resolution[C]. European Conference on Computer Vision, 2014: 184-199.
- [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] Timofte R, de Smet V, van Gool L. A+: adjusted anchored neighborhood regression for fast super-resolution[C]. Asian Conference on Computer Vision, 2014: 111-126.
- [10] Yu D, Deng L. Deep learning and its applications to signal and information processing [exploratory dsp][J]. IEEE Signal Processing Magazine, 2011, 28(1): 145-154.
- [11] Gan C, Wang N, Yang Y, *et al.* DevNet: a deep event network for multimedia event detection and evidence recounting [C]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, 2015: 2568-2577.
- [12] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [EB/OL]. [2017-01-16]. <https://arxiv.org/abs/1409.1556>.
- [13] He K, Sun J. Convolutional neural networks at constrained time cost [C]. Proceedings of IEEE Conference on

Computer Vision and Pattern Recognition, 2015: 5353-5360.

- [14] Zhang Baochang, Yang Wankou, Lin Nana. Machine learning and visual perception[M]. Beijing: Tsinghua University Press, 2016.  
张宝昌, 杨万扣, 林娜娜. 机器学习与视觉感知[M]. 北京: 清华大学出版社, 2016.
- [15] Nair V, Hinton G E. Rectified linear units improve restricted Boltzmann machines [C]. Proceedings of 27th International Conference on Machine Learning, 2010: 807-814.
- [16] 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.
- [17] Li Yandong, Hao Zongbo, Lei Hang. Survey of convolutional neural network[J]. Journal of Computer Applications, 2016, 36(9): 2508-2514.  
李彦冬, 郝宗波, 雷航. 卷积神经网络研究综述[J]. 计算机应用, 2016, 36(9): 2508-2514.
- [18] Bouvrie J. Note on convolutional neural networks[EB/OL]. [2016-11-27]. [http://cogprints.org/5869/1/c-nn\\_tutorial.pdf](http://cogprints.org/5869/1/c-nn_tutorial.pdf).
- [19] Fu X L, Cai L H, Liu Y, *et al.* A computational cognition model of perception, memory, and judgment[J]. Science China-Information Sciences, 2014, 57(3): 032114.
- [20] Wang Min, Song Zhengfu, Wang Zhihui. Remote sensing image segmentation based on fractal net evolution approach and improved fuzzy c-means[J]. Laser & Optoelectronics Progress, 2016, 53(11): 112801.  
王民, 宋正付, 王稚慧. 基于分形网络演化方法和改进模糊聚类遥感影像分割[J]. 激光与光电子学进展, 2016, 53(11): 112801.
- [21] Zhao Zhigang, Lin Yujiao, Yin Zhaoyuan. A mean particle swarm optimization algorithm based on adaptive inertia weight[J]. Computer Engineering & Science, 2016, 38(3): 501-506.  
赵志刚, 林玉娇, 尹兆远. 基于自适应惯性权重的均值粒子群优化算法[J]. 计算机工程与科学, 2016, 38(3): 501-506.
- [22] Lu Yuxuan. Image super-resolution using convolutional networks and its visual improvement [D]. Hefei: Anhui University, 2016: 5-27.  
卢昱璇. 基于卷积神经网络的图像超分辨率重建及视觉改进[D]. 合肥: 安徽大学, 2016: 5-27.
- [23] Liu L X, Liu B, Huang H, *et al.* No-reference image quality assessment based on spatial and spectral entropies[J]. Signal Processing Image Communication, 2014, 29(8): 856-863.