

改进的超分辨率图像重建算法

曲海成^{*}, 唐博文^{**}, 袁贵森^{***}

辽宁工程技术大学软件学院, 辽宁 葫芦岛 125105

摘要 针对超分辨率卷积神经网络(SRCNN)卷积层较少、训练时间长、不易收敛且表达和泛化能力受限等问题,提出了一种残差反卷积 SRCNN(RD-SRCNN)算法。首先利用不同大小的卷积核进行卷积操作,以更好地提取低分辨率图像中的细节特征;然后将获取的图像特征输入由不同大小卷积核构成的卷积层和指数线性单元激活层组成的残差网络,并通过短路径连接各个特征提取单元,以解决梯度消失、实现特征重用、减少网络冗余;最后,通过加入反卷积层增大感受野,得到清晰的高分辨率图像。实验结果表明,RD-SRCNN 算法在视觉和客观评价标准上均取得了较好的效果。

关键词 图像处理;反卷积;残差网络;激活函数;卷积神经网络

中图分类号 TP391

文献标志码 A

doi: 10.3788/LOP202158.0210018

Improved Super-Resolution Image Reconstruction Algorithm

Qu Haicheng^{*}, Tang Bowen^{**}, Yuan Guisen^{***}

School of Software, Liaoning Technical University, Huludao, Liaoning 125105, China

Abstract Aiming at the problems of super-resolution convolutional neural network (SRCNN) with fewer convolutional layers, long training time, difficulty in convergence, and limited expression and generalization capabilities, a residual deconvolution SRCNN (RD-SRCNN) algorithm is proposed in this work. First, different size convolution kernels are used for convolution operation to better extract the detailed features in low resolution images. Then, the acquired image features are input into the residual network composed of convolution layer composed of convolution kernels of different sizes and activation layer of exponential linear unit, and each feature extraction unit is connected by short path to solve the problem of gradient disappearance and realize the feature reuse, and reduce the network redundancy. Finally, a clear high-resolution image is obtained by adding a deconvolution layer to increase the receptive field. Experimental results show that the RD-SRCNN algorithm achieves good results in both visual and objective evaluation criteria.

Key words image processing; deconvolution; residual network; activation function; convolutional neural network

OCIS codes 100.3010; 100.6640; 110.3010

1 引言

超分辨率(SR)技术^[1]是指根据低分辨率图像重建出相应的高分辨率图像,SR 技术广泛应用于银行安全监控系统、证券交易、图像压缩以及医学图像分析^[2]等领域。图像 SR 技术是图像处理领域的研究热点,图像 SR 算法可大致分为传统方法和基于学习的方法。传统方法包括基于插值^[3]和基于重

建^[4]的方法。经典插值方法包括最近邻法、双线性法和双三次法。这些方法都可以有效增强图像分辨率,但会造成边缘模糊;基于重建的方法利用从低分辨率图像中提取的信息,结合先验信息生成高分辨率图像,包括凸集投影法和迭代反投影法。凸集投影法需要在向量空间中定义封闭的凸约束集,实际的高分辨率图像包含在约束集中,估计的高分辨率图像即为约束集的交点。这类方法简单且计算量

收稿日期: 2020-05-28; 修回日期: 2020-07-10; 录用日期: 2020-07-20

^{*} E-mail: quhaicheng@lntu.edu.cn; ^{**} E-mail: hyzcywx521@163.com; ^{***} E-mail: 48999481@qq.com

小,但无法处理复杂结构的图像。基于学习的方法通过训练大量图像数据,学习高分辨率和低分辨率图像之间的关系,然后在重建过程中训练输入的低分辨率图像,获得高分辨率图像。基于学习^[5]的方法有稀疏编码(SC)和深度学习^[6]两大类,通过提取高频信息的预测技术也被应用在高分辨率图像^[7]的SR重建中。Yang等^[8]提出了一种基于学习的SC算法,可从外部图像样本中选取高分辨率和低分辨率图像块,形成高分辨率和低分辨率的字典,然后利用字典对稀疏系数进行估计,恢复SR图像;Timofte等^[9]提出的锚定邻域回归(ANR)方法将稀疏字典和ANR相结合,用ANR方法降低分辨率图像块重构的复杂度,并结合K奇异值分解(SVD)训练和字典进行重建,获得了较好的重建效果。但该方法受到模型框架的约束,计算时间长、运算效率较低。

基于卷积神经网络(CNN)^[10]的深度学习方法广泛应用于图像超分辨重建领域。Dong等^[11]提出了超分辨率CNN(SRCNN)算法,采用SR算法和样本学习建立了CNN的端到端映射,将输入的低分辨率图像转换为高分辨率图像,将字典建模^[11]替换为隐层参数的自动调整,极大提高了重建精度,减少了计算时间。在快速SRCNN(FSRCNN)^[12]中,图像尺寸放大过程中的插值函数被隐含在前面的卷积层中,可自动学习到。由于卷积运算都是在低分辨率图像上进行,因此效率较高。Kim等^[13]的研究

表明,输入的低分辨率图像和输出的高分辨率图像在很大程度上是相似的,即低分辨率图像携带的低频信息与高分辨率图像中的低频信息相近,训练时会花费大量的时间,实际中只需学习高分辨率图像和低分辨率图像之间的高频部分残差即可。SRCNN存在的限制条件:1)用双三次插值对输入图像进行预处理,会导致图像产生边缘模糊^[14]和锯齿状;2)计算速度随网络复杂度的增加而降低,图像重构时可能不收敛;3)只有三个卷积层,无法完全提取图像细节特征;4)未在图像边界处进行零点填充,减少了输出图像的感受野。

针对上述问题,本文提出了一种残差反卷积SRCNN(RD-SRCNN)算法。首先,增加具有较小内核的深度卷积层,以提取图像的细节特征。其次,在训练过程中加入残差网络,以加快网络收敛速度、解决消失梯度问题;最后,用反卷积扩大感受野,改善重建图像的质量,建立端到端的自主学习过程。

2 图像超分辨相关理论

2.1 SRCNN 算法

SRCNN算法包括特征提取、非线性映射和图像重构,其网络结构如图1所示。主要有三层,包括卷积核大小分别为 9×9 、 1×1 和 5×5 的卷积层(Conv),分别对应第一层、第二层和第三层。 W 和 B 分别为过滤器和多维的偏差, f 和 n 分别为滤波器的空间大小和个数。SRCNN的具体步骤如下。




图1 SRCNN的整体结构

Fig. 1 Overall structure of the SRCNN

1) Patch的提取:从低分辨率图像 Y 中提取出重叠的局部图像,将每个局部图像用高维向量表示为

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

式中, $F_1(\cdot)$ 为SRCNN提取的一组特征图像, W_1 和 B_1 分别为网络第一层过滤器和多维的偏差,将校正后的指数线性单元(ELU) $\max(0, x)$ 用于过滤器响应。

2) 非线性映射:将所有高维向量都用非线性映

射到相反的高维向量上。理论上,这些映射向量的本质是图像不同部分的高分辨率图像,利用这些映射向量能构造出图像的特征,可表示为

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

式中, W_2 和 B_2 分别为网络第二层过滤器和多维的偏差, $F_2(\cdot)$ 输出的每个二维向量在概念上都是高分辨率块的表示。

3) 图像重建:定义卷积层后,生成最终的高分

分辨率图像,可表示为

$$F_3(Y) = W_3 * F_2(Y) + B_3, \quad (3)$$

式中, W_3 和 B_3 分别为网络第三层滤波器和多维的偏差, $F_3(\cdot)$ 结合内部预测的一个空间邻域得到最终的高分辨率图像。

2.2 激活函数

修正线性单元(ReLU)激活函数是一个分段线性函数,通过向神经网络中加入非线性因素以更好地挖掘相关特征。当输入为负时,该函数的输出为零;当输入为正时,该函数的本质是一个线性函数。ReLU 激活函数具有特殊的非线性结构,能更好地训练神经网络。当网络层数增加 M 时,ReLU 激活函数的神经元激活率会降低 $2M$,可表示为

$$X_{\text{ReLU}}(x) = \begin{cases} x, & \text{if } x > 0 \\ 0, & \text{if } x \leq 0 \end{cases} \quad (4)$$

激活函数可为 CNN 提供非线性建模能力,由于 ReLU 激活函数存在神经元死亡问题,即在变量为负的区间内,会丢失图像的细节特征,导致图像恢复错误。因此,用带参数的修正线性单元(PReLU)^[15]代替 ReLU 激活函数,以解决神经元死亡问题,同时可以加速网络的收敛,还可以解决梯度消失问题,但会增加少量 ELU 激活函数。与 ReLU 相比,ELU 激活函数提供了一个负值区间,不仅能进行归一化处理,还能降低计算复杂度。当平均输出趋近于零时,可减小偏移效应,梯度趋近于原始值。ELU 函数可表示为

$$f(x) = \begin{cases} x, & \text{if } x \geq 0 \\ \alpha [\exp(x) - 1], & \text{if } x < 0 \end{cases} \quad (5)$$

2.3 残差网络

已有研究表明,CNN 的层数在特征提取和非线性映射过程中起着重要作用。随着网络层数的增加,CNN 的结构也变得越来越复杂,从而导致梯度消失^[16]问题。直接利用卷积层拟合一个潜在的恒等映射函数 $H(x) = x$ 比较困难。如果将网络设计为 $H(x) = F(x) + x$,则可以转换为学习一个残差函数 $F(x) = H(x) - x$ 。只需使 $F(x) = 0$,就能构成一个恒等映射 $H(x) = x$,其中, $F(x)$ 为求和前的网络映射, $H(x)$ 为从输入到求和后的网络映射。此时,拟合残差相对容易,图像的特征信息也会得到很好的传递,从而减少信息丢失,得到分辨率更高的图像。此外,更深层次网络的训练会越来越难,且容易产生退化和网络冗余现象。

2.4 FSRCNN 算法

SRCNN 算法中限制运行速度的因素:1)低分辨

率图像需要上采样(通过双三次插值);2)非线性映射步骤,需要缩减参数、加快速度。对于第一个问题可用解卷积层代替双三次插值;对于第二个问题,可添加萎缩层和扩张层,并将一个大尺寸卷积层用一些小尺寸卷积层(卷积核大小为 3×3)代替。整个网络结构类似漏斗形状,中间细两端粗。该网络不仅速度快,且除了最后一个解卷积层外不需要更改参数。

2.5 反卷积操作

反卷积网络是图像特征空间中一种自学习的上采样操作,其结构如图 2 所示。由于反卷积优于其他上采样操作,因此,在整个 CNN 上进行反卷积操作,以增加感受野,改善图像重建的质量,建立端端的自主学习过程。反卷积操作输出的特征图尺寸可表示为

$$o' = s \times (i - 1) + k - 2p, \quad (6)$$

式中, k 为卷积核大小, s 为步长, p 为填充尺寸, i 输入特征图的尺寸。




图 2 反卷积的结构

Fig. 2 Structure of the deconvolution

如图 2 所示,若输入尺寸为 3×3 ,卷积核尺寸为 3×3 ,步长为 2,填充尺寸为 1,即 $i = 3, k = 3, s = 2, p = 1$,则输出特征图的尺寸为 5×5 ,其中, $5 = 2 \times (3 - 1) - 2 + 3$ 。

3 RD-SRCNN 算法

RD-SRCNN 算法的特点:利用线性滤波器的深度神经网络能更有效地提取图像特征;采用零填充可避免截断误差、恢复图像信息、实现特征重用,同时加速网络收敛、避免梯度分散;通过增加网络的深度提高网络性能,利用残差学习直接对残差图像进行建模,以解决网络的退化问题。残差网络中的批处理归一化(BN)层^[17]虽然可以降低训练速度,但不稳定、容易导致算法发散。从而破坏图像原有的对比度信息,影响网络输出的质量。因此,本网络删除 BN 层,使用 ELU 函数加速训练过程,可以克服 ReLU 函数负

区间内神经元死亡的问题;且该激活单元的平均输出趋近于零,从而加速参数的更新和神经网络的收敛。通过引入反卷积层,将重建过程转化为端到端的自主学习过程,可提高重建图像的质量。

3.1 网络结构设计

本算法的整体结构分为三个部分,如图 3 所示。

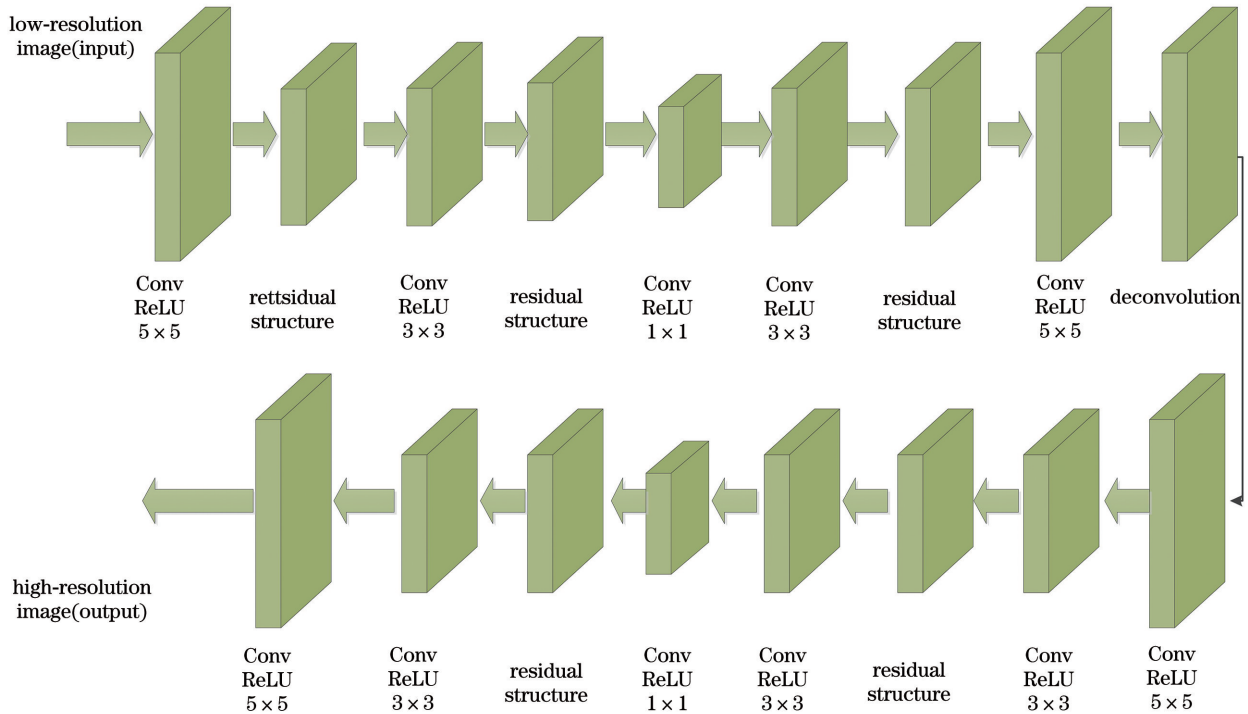


图 3 改进的 SRCNN 结构

Fig. 3 Improved SRCNN structure

使用更小尺寸的卷积核,如 3×3 和 5×5 ,以减少参数量和改善正则化。多个小卷积层比大卷积层有更好的非线性效果,使决策函数的稳定性更好,不仅能起到隐式正则化的作用^[18],还能提取更多的图像细节特征。但当使用的小卷积核过多时,会导致运行时间增加。可利用残差网络解决网络层数增加导致的收敛速度慢、梯度消失、数据冗余等问题。本网络采用的卷积核尺寸分别为 $128 \times 5 \times 5$ 、 $64 \times 3 \times 3$ 、 $64 \times 1 \times 1$ 、 $32 \times 3 \times 3$ 、 $64 \times 5 \times 5$ 、 $1 \times 3 \times 3$ 。

3.2 改进的残差网络

残差网络可以实现特征复用、减少网络冗余、加速参数更新和网络收敛。随着更深层次网络的加入,可能会产生梯度消失、网络停止训练。如果深层网络的最后一层具有相同的映射,则该模型会退化为浅层网络。因此,将采集的特征信息输入残差块中,每个残差块都包含了多个由卷积层和激活层构成的特征提取单元,如图 4 所示。其次,每个特征提取单元的输出都会通过短路径连接到下一个特征提取单

元。第一部分是对插值后的低分辨率图像进行特征提取;第二部分是利用隐层进行非线性映射;第三部分是进行图像重建。在卷积过程中,当图像的感受野减小时,可利用反卷积扩大感受野。相比现有 SRCNN 的层数有所增加,同时用改进的残差结构加速网络的收敛。




图 4 残差网络

Fig. 4 Residual network

元。短路径连接可以有效缓解梯度消失现象,加强特征传播,促进特征再利用。由于 BN 层降低了训练速度,导致网络不稳定和发散。因此,去除 BN 层,用 ELU 激活函数代替 ReLU 激活函数,改变残差网络的结构。将两个 3×3 的卷积层替换为 $1 \times 1 + 3 \times 3 + 1 \times 1$ 的配置,如图 5 所示。新结构中心的 3×3 卷积层在保持精度的前提下降低了另外两个 1×1 卷积层的计算复杂度。




图 5 改进的残差网络

Fig. 5 Improved residual network

4 实验设计与分析

4.1 实验数据及设置

实验采用三个公共数据集评估 RD-SRCNN 算法的性能,前两个数据集分别为 Set5 和 Set14 数据集,将原始数据集旋转 90° 、 180° 和 270° 以生成扩增数据集。训练数据包含 91 张 BMP (Bone morphogenetic protein) 图像,且每张图像的大小不同。将数据集中的图像进行分割后,训练集包含 28800 张子图像。网络输入和期望输出 (标签) 的大小分别为 $33 \text{ pixel} \times 33 \text{ pixel}$ 和 $21 \text{ pixel} \times 21 \text{ pixel}$ 。第三个数据集为 City100 数据集,包含两个不同成像设备 (iPhoneX 和 Nikon D5500 相机) 拍摄的高低分辨率图像对,拍摄的是贺卡上的景物建筑图像。成像设备通过变焦拍摄高低分辨率图像,拉近镜头,视野变大 (Zoom out),图像的分辨率降低;视野变小 (Zoom in),则分辨率增加。

实验环境:系统为 Windows10,软件平台为 Anaconda3 (Python3. 7. 6),深度学习框架为 Tensorflow,使用 CPU 进行运算。用于训练和测试的硬件配置:内存为 32 G,处理器为 Platinum8269CY 的 CPU,主频为 2.5 G、四核。

4.2 评估指标

用峰值信噪比 (PSNR)、结构相似度 (SSIM)^[19]

和均方误差 (MSE) 三个指标评价本算法的性能。PSNR 为信号的最大功率与噪声功率之比,在工程应用中常被用来评估图像压缩的质量。图像压缩会减少原始图像的大小,从而实现有效的存储和传输。PSNR 可表示为

$$X_{\text{PSNR}} = 10 \times \log_{10} \left(\frac{M_1^2}{X_{\text{MSE}}} \right) = 20 \times \log_{10} \left(\frac{M_1}{\sqrt{X_{\text{MSE}}}} \right), \quad (7)$$

式中, X_{MSE} 为原始图像与处理后图像的均方误差^[20], M_1 为图像颜色的最大值。采样的 8 位图像像素值范围为 0 到 255, X_{MSE} 可表示为

$$X_{\text{MSE}} = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} I(i, j) - K(i, j), \quad (8)$$

式中, m 和 n 分别为图像的长与宽, (i, j) 为像素值对应的坐标, $I(i, j)$ 、 $K(i, j)$ 分别为不同图像对应坐标的像素值。SSIM 可以评估原始图像和处理后图像之间的差异,即原始图像与处理后图像之间的相似性,可表示为

$$X_{\text{SSIM}} = L(X, Y)C(X, Y)S(X, Y), \quad (9)$$

$$L(X, Y) = \frac{2u_x u_y + C_1}{u_x^2 + u_y^2 + C_1}, \quad (10)$$

式中, $C(X, Y)$ 为亮度的估计, $K(X, Y)$ 为对比度的估计, $S(X, Y)$ 为结构相似程度的度量。 u_x 和 u_y 分别为图像在 X 维和 Y 维上的均值, σ_x 和 σ_y 分别为图像在 X 维和 Y 维上的标准差。沿 X 和 Y 方向的方差分别由 $u_x * u_x$ 和 $u_y * u_y$ 给出, C_1 为防止分母趋近于零的常数,由 $(K_1 \times L)^2$ 给出。根据文献^[21]可知, K_1 、 L 分别为 0.01、255。

不同算法在不同指标下的重建效果如表 1~表 3 所示,主要包括婴儿、鸟类、蝴蝶、头部、女人图像对应的 MSE、SSIM、PSNR。可以发现,相比 SRCNN 和 FSRCNN^[22] 算法,本算法的 PSNR 分别提高了 0.874 dB 和 1.068 dB, SSIM 分别增加了 0.018 和 0.024, MSE 分别减少了 12.364 和 14.326。

表 1 不同算法的 MSE

Table 1 MSE of different algorithms

Algorithm	Baby	Bird	Butterfly	Head	Woman
Bicubic	27.28	35.31	247.33	34.75	93.45
SRCNN	21.97	23.78	134.33	30.86	65.77
FSRCNN	22.41	23.60	127.43	30.53	62.93
RD-SRCNN	21.09	17.69	86.44	28.79	49.95

表 2 不同算法的 SSIM
Table 2 SSIM of different algorithms

Algorithm	Baby	Bird	Butterfly	Head	Woman
Bicubic	0.90	0.92	0.82	0.80	0.88
SRCNN	0.91	0.94	0.87	0.81	0.91
FSRCNN	0.91	0.95	0.88	0.82	0.91
RD-SRCNN	0.92	0.96	0.92	0.83	0.93

表 3 不同算法的重建效果
Table 3 Reconstruction effects of different algorithms unit: dB

Algorithm	Baby	Bird	Butterfly	Head	Woman
Bicubic	33.77	32.65	24.19	32.72	28.42
SRCNN	34.71	34.21	26.54	33.23	29.95
FSRCNN	34.72	34.40	27.07	33.28	30.14
RD-SRCNN	34.88	35.65	28.76	33.54	31.15

为了探究 ELU 激活函数的有效性和适当增加网络层数对图像恢复的影响,用 ELU 激活函数代替 ReLU 激活函数,并对比 5 层和 8 层网络中 5 张图像对应的 MSE、SSIM 和 PSNR,结果如表 4 和表 5 所示。可以发现,在其他条件不变的情况下,用 ELU 激活函数代替 ReLU 激活函数时,5 层网络结

构的平均 PSNR 增加了 0.156 dB,SSIM 均值提高 0.006,MSE 均值降低 1.97;8 层网络结构的平均 PSNR 增加了 0.104 dB,SSIM 均值提高 0.008,MSE 均值降低 1.782。这表明用 ELU 激活函数代替 ReLU 激活函数或适当增加网络的深度可以提高图像恢复的质量。

表 4 5 层网络结构中不同激活函数的对比
Table 4 Comparison of different activation functions in the 5-layer network structure

Evaluation indicator	Activation function	Baby	Bird	Butterfly	Head	Woman
MSE	ELU	21.31	23.12	123.51	30.29	58.82
	ReLU	22.41	23.60	127.43	30.53	62.93
SSIM	ELU	0.91	0.94	0.89	0.82	0.92
	ReLU	0.91	0.94	0.88	0.81	0.91
PSNR /dB	ELU	34.84	34.49	27.21	33.32	30.43
	ReLU	34.62	34.40	27.07	33.28	30.14

表 5 8 层网络结构中不同激活函数的对比
Table 5 Comparison of different activation functions in the 8-layer network structure

Evaluation indicator	Activation function	Baby	Bird	Butterfly	Head	Woman
MSE	ELU	21.23	21.18	106.74	29.27	56.26
	ReLU	22.33	21.86	113.67	29.80	56.43
SSIM	ELU	0.92	0.95	0.90	0.83	0.92
	ReLU	0.91	0.94	0.89	0.82	0.92
PSNR /dB	ELU	34.84	34.92	27.84	33.46	30.62
	ReLU	34.73	34.86	27.57	33.39	30.61

为了研究改进的残差网络对本算法的影响,设计了 5 层和 8 层网络并在 5 张图像上进行对比实验,结果如表 6 和表 7 所示。可以发现,在其他条件不变的情况下,加入残差网络后,5 层网络结构的平均 PSNR 增加了 0.686 dB,SSIM 均值增加了 0.014,MSE 均值减少了 10.24;8 层网络结构

的平均 PSNR 增加了 0.444 dB,SSIM 均值提高了 0.012,MSE 均值降低了 5.616。这表明改进的残差网络能增强图像细节的恢复,原因是每个残差网络都是由多个卷积层以及激活函数组成,同时使用的短路径连接可以有效缓解梯度消失问题,加强了图像的特征传播及再利用。

表 6 5 层网络结构中的 ELU 激活函数性能

Table 6 ELU activation function performance in 5-layer network structure

Evaluation indicator	Residual structure	Baby	Bird	Butterfly	Head	Woman
MSE	yes	21.16	18.18	87.05	29.35	50.17
	no	21.31	23.12	123.57	30.29	58.82
SSIM	yes	0.92	0.95	0.92	0.83	0.93
	no	0.91	0.94	0.89	0.82	0.92
PSNR /dB	yes	34.88	35.53	28.73	33.45	31.13
	no	34.84	34.49	27.21	33.32	30.43

表 7 8 层网络结构中的 ELU 激活函数性能

Table 7 ELU activation function performance in 8-layer network structure

Evaluation indicator	Residual structure	Baby	Bird	Butterfly	Head	Woman
MSE	yes	21.16	18.18	86.44	29.35	49.95
	no	21.53	20.38	105.43	29.55	56.27
SSIM	yes	0.92	0.96	0.92	0.83	0.93
	no	0.91	0.95	0.90	0.82	0.92
PSNR /dB	yes	34.88	35.65	28.76	33.54	31.15
	no	34.79	35.03	27.9	33.42	30.62

为了研究反卷积对本算法的影响,进行了反卷积和无反卷积的对比实验,前提是使用 ELU 激活函数及残差网络,结果如表 8 所示。可以发现,在使

用 ELU 激活函数和残差网络的情况下,加入反卷积后的平均 PSNR 增加了 0.052 dB,SSIM 均值增加 0.002,MSE 均值下降 0.346。

表 8 反卷积和非反卷积的性能指标

Table 8 Performance indicators of deconvolution and non-deconvolution

Evaluation indicator	Deconvolution	Baby	Bird	Butterfly	Head	Woman
MSE	yes	21.09	17.69	86.44	28.79	49.95
	no	21.16	18.18	87.05	29.35	50.17
SSIM	yes	0.92	0.96	0.92	0.83	0.93
	no	0.92	0.95	0.92	0.83	0.93
PSNR /dB	yes	34.88	35.65	28.76	33.54	31.15
	no	34.88	35.53	28.73	33.45	31.13

以 3 个 3×3 的级联卷积代替 1 个 7×7 的卷积后,可以减少 $22(7 \times 7 - 3 \times 3 \times 3)$ 个参数,以 2 个

3×3 的级联卷积代替 1 个 5×5 的卷积后,可以减少 $7(5 \times 5 - 2 \times 3 \times 3)$ 个参数。此外,残差网络通过

短路径连接,可以直接提取特征并传输给下一层网络。残差网络中存在恒等映射的特殊情况,不会引入额外的参数和计算复杂度,在给定软硬件环境下的实际运行时间如表 9 所示。

为了验证本算法与其他算法在主观视觉上的差异,选择表 1~表 3 中具有代表性的算法作为参考,不同算法的重建结果如图 6 所示。

表 9 训练时间的对比

Table 9 Comparison of training time

Method	Times /s	Method	Time /s
Eight layers with no residual	31.638	5-layer network	11.863
Eight layers with residual	30.071	8-layer network	8.152




图 6 不同算法的重建效果。(a)Bicubic;(b)SRCNN;(c) FSRCNN;(d)本算法

Fig. 6 Reconstruction effects of different algorithms. (a) Bicubic; (b) SRCNN; (c) FSRCNN; (d) our algorithm

为了提高本算法的实际参考价值,该实验数据的低分辨率和高分辨率数据均来自不同相机实际拍

摄并经过配准和校正形成的数据对。部分实验结果如图 7 所示。

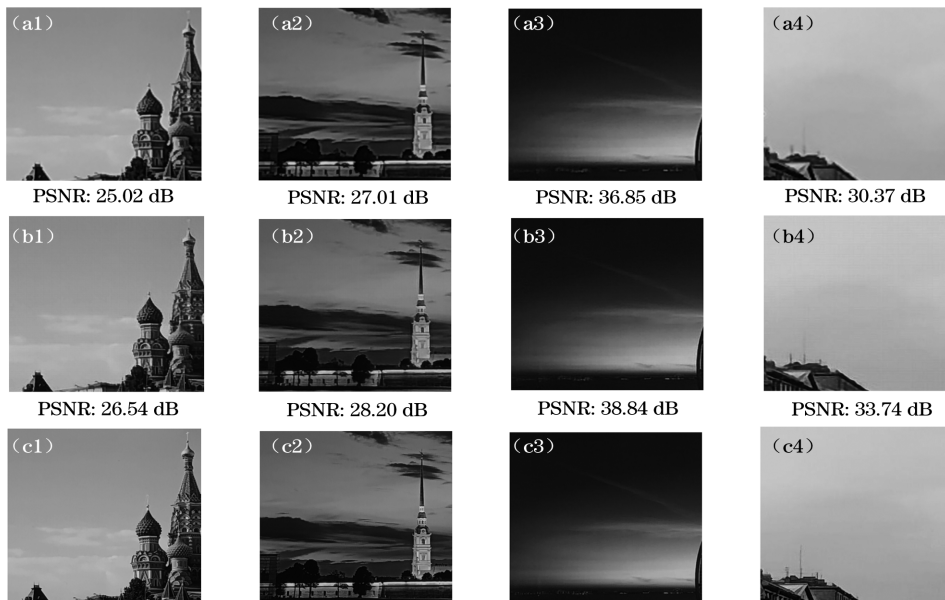


图 7 实际采集图像的重建效果。(a)低分辨率图像;(b)本算法;(c)高分辨率图像

Fig. 7 Reconstruction effect of the actual acquired image. (a) Low-resolution images; (b) our algorithm; (c) high-resolution images

5 结 论

提出了一种改进的 RD-SRCNN 算法,在经典 SRCNN 的基础上增加了更多的层数,同时改进了残差网络,目的是加强特征传播,促进特征的再利用,进而提高图像的重建效果。用 ELU 激活函数代替 ReLU 激活函数,解决了网络中渐变消失和神经元死亡的问题。提出了一种改进的残差网络和反卷积算法,解决了图像细节提取不完整、训练速度慢、网络收敛性差等问题。此外,卷积运算需要一个小的传感器字段,因此在网络模型中增加了补零操作,以消除边界效应。实验结果表明,本算法可以增强网络重建高分辨率图像的能力。未来研究还需在网络结构设计中结合局部信息和全局信息以及低阶和高阶信息提高 SR 图像的质量。

参 考 文 献

- [1] Yang X, Wang C Q, Fei S M. An adaptive method for simultaneous image super-resolution and motion estimation based on nonlinear least square [J]. *Journal of Image and Graphics*, 2010, 15(12): 1714-1719.
杨欣, 王从庆, 费树岷. 基于非线性最小二乘的图像自适应 SR 重建以及运动估计 [J]. *中国图象图形学报*, 2010, 15(12): 1714-1719.
- [2] Wang M, Liu K X, Liu L, et al. Super-resolution reconstruction of image based on optimized convolution neural network[J]. *Laser & Optoelectronics Progress*, 2017, 54(11): 111005.
- [3] Sun R H, Shi L F, Huang L Y, et al. Reversible data hiding based on image interpolation and reference matrix [J]. *Journal of Guangxi Normal University (Natural Science Edition)*, 2019, 37(2): 90-104.
孙容海, 施林甫, 黄丽艳, 等. 基于图像插值和参考矩阵的可逆信息隐藏算法 [J]. *广西师范大学学报 (自然科学版)*, 2019, 37(2): 90-104.
- [4] Xi Z H, Yuan K P. Super-resolution image reconstruction based on residual channel attention and multilevel feature fusion[J]. *Laser & Optoelectronics Progress*, 2020, 57(4): 041504.
- [5] 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), June 7-12, 2015, Boston, MA, USA. New York: IEEE, 2015: 5197-5206.
- [6] Zhao J T. Single-image defogging algorithm based on deep learning[J]. *Laser & Optoelectronics Progress*, 2019, 56(11): 111005.
赵建堂. 基于深度学习的单幅图像去雾算法 [J]. *激光与光电子学进展*, 2019, 56(11): 111005.
- [7] Lian Q S, Zhang J Q, Chen S Z. Single image super-resolution algorithm based on two-stage and multi-frequency-band dictionaries[J]. *Acta Automatica Sinica*, 2013, 39(8): 1310-1320.
练秋生, 张钧芹, 陈书贞. 基于两级字典与分频带字典的图像超分辨率算法 [J]. *自动化学报*, 2013, 39(8): 1310-1320.
- [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 V, Gool L V. Anchored neighborhood regression for fast example-based super-resolution [C] // 2013 IEEE International Conference on Computer Vision, December 1-8, 2013, Sydney, NSW, Australia. New York: IEEE, 2013: 1920-1927.
- [10] Wu X, He R, Sun Z N, et al. A light CNN for deep face representation with noisy labels [J]. *IEEE Transactions on Information Forensics and Security*, 2018, 13(11): 2884-2896.
- [11] Don C, Loy C C, He K M, et al. Learning a deep convolutional network for image super-resolution [M]//Fleet D, Pajdla T, Schiele B, et al. *Computer Vision-ECCV 2014. Lecture Notes in Computer Science*. Cham: Springer, 2014, 8692: 184-199.
- [12] Shi W Z, 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 (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 1874-1883.
- [13] Kim J, Lee J K, Lee K M. Accurate image super-resolution using very deep convolutional networks [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 1646-1654.
- [14] Hu S Y, Wang G D, Zhao Y, et al. Image super-resolution network based on dense connection and squeeze module [J]. *Laser & Optoelectronics Progress*, 2019, 56(20): 201005.
胡诗语, 王国栋, 赵毅, 等. 基于密集连接与激励模块的图像超分辨率网络 [J]. *激光与光电子学进展*, 2019, 56(20): 201005.
- [15] Shang X W, Liang J, Wang G Z, et al. Color-sensitivity-based combined PSNR for objective video

- quality assessment[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2019, 29(5): 1239-1250.
- [16] Wang H L, Li S J, Jia W, et al. Performance evaluation of convolutional neural network in palmprint recognition[J]. Journal of Image and Graphics, 2019, 24(8): 1231-1248.
王海纶, 李书杰, 贾伟, 等. 卷积神经网络在掌纹识别中的性能评估[J]. 中国图象图形学报, 2019, 24(8): 1231-1248.
- [17] Lu H W, Yuan X T. Dynamic network structured pruning via feature coefficients of layer fusion[J]. Pattern Recognition and Artificial Intelligence, 2019, 32(11): 1051-1059.
卢海伟, 袁晓彤. 基于层融合特征系数的动态网络结构化剪枝[J]. 模式识别与人工智能, 2019, 32(11): 1051-1059.
- [18] Li X K, Jia C Y. Co-filtering method of converting overlap community regularization and implicit feedback [J/OL]. Computer applications. [2020-10-12]. <http://kns.cnki.net/kcms/detail/51.1307.20201009.1605.002.html>.
李翔锟, 贾彩燕. 融合重叠社区正则化及隐式反馈的协同过滤方法[J/OL]. 计算机应用. [2020-10-12]. <http://kns.cnki.net/kcms/detail/51.1307.20201009.1605.002.html>.
- [19] Peng J Y, Shi C Y, Laugeman E, et al. Implementation of the structural SIMilarity (SSIM) index as a quantitative evaluation tool for dose distribution error detection [J]. Medical Physics, 2020, 47(4): 1907-1919.
- [20] Cheng Y, Deng D X, Yan J, et al. Weakly illuminated image enhancement algorithm based on convolutional neural network[J]. Journal of Computer Applications, 2019, 39(4): 1162-1169.
程宇, 邓德祥, 颜佳, 等. 基于卷积神经网络的弱光照图像增强算法[J]. 计算机应用, 2019, 39(4): 1162-1169.
- [21] Chen H H, Liu P. Abnormal events detection based on sparse auto-encoder network of SSIM[J]. Journal of Hangzhou Dianzi University (Natural Sciences), 2019, 39(5): 19-24, 40.
陈华华, 刘萍. 基于 SSIM 稀疏自编码网络的异常事件检测[J]. 杭州电子科技大学学报(自然科学版), 2019, 39(5): 19-24, 40.
- [22] Lei W M, Wang Y N, Li J H. Optimization research of image super resolution reconstruction algorithm based on FSRCNN[J]. Transducer and Microsystem Technologies, 2020, 39(2): 54-57.
雷为民, 王玉楠, 李锦环. 基于 FSRCNN 的图像超分辨率重建算法优化研究[J]. 传感器与微系统, 2020, 39(2): 54-57.