

# 结合小波变换与深度网络的图像超分辨率方法

孙超\*, 吕俊伟\*\*, 宫剑, 仇荣超, 李健伟, 伍恒

海军航空大学岸防兵学院, 山东 烟台 264001

**摘要** 近年来,基于深度学习的单幅图像超分辨率方法已经取得了显著成就。但这些方法仅研究图像空域,忽略了图像频域中高频信息的重要性,从而导致生成的图像相对平滑。利用小波变换能够提取图像细节的特性,因此提出一种结合小波变换与深度网络的单幅图像超分辨率方法。首先,利用小波变换将图像分解为低频子图和三个方向上的高频子图,将低分辨率图像与高频子图作为深度网络的输入。其次,对已有的深度网络进行改进,简化网络结构,减少卷积层数量以减少网络负担,修改网络通道。最后,进行小波逆变换,得到超分辨率图像。在开放测试数据集上进行测试,并将本文方法与其他方法进行比较。实验结果表明,本文方法在主观视觉效果与客观评价指标上均表现良好。

**关键词** 图像处理; 超分辨率; 小波变换; 深度网络; 卷积神经网络

**中图分类号** TN219

**文献标识码** A

**doi:** 10.3788/LOP55.121006

## Image Super-Resolution Method Combining Wavelet Transform with Deep Network

Sun Chao\*, Lü Junwei\*\*, Gong Jian, Qiu Rongchao, Li Jianwei, Wu Heng

College of Coast Defence Arm, Naval Aviation University, Yantai, Shandong 264001, China

**Abstract** In recent years, the single image super-resolution methods based on deep learning have made remarkable achievements. However, these methods focus researches on the image spatial domain, ignoring the significance of information in high frequency in image frequent domain, resulting in a relatively smooth image. A single image super-resolution method combining wavelet transform with deep network is proposed, which takes the advantages of extracting the details by wavelet transform. First, the image is decomposed into a sub-band in low frequency and three sub-bands of different directions in high frequency by wavelet transform, then the low resolution image and sub-bands in high frequency are regarded as the input of the deep network. Second, the existing deep network is improved by simplifying the network, decreasing the number of convolution layers to reduce network burden, and modifying the network channels. Finally, the super-resolution image is obtained by inversely wavelet transforming. The proposed method is tested on the open test datasets, and compared with other state-of-the-art methods. The experimental results demonstrate that the proposed method works well in subjective visual effects and objective evaluation indexes.

**Key words** image processing; super-resolution; wavelet transform; deep network; convolution neural network

**OCIS codes** 100.6640; 100.2000; 110.3010

## 1 引言

高分辨率(HR)图像具有较高密集度的像素分布,能够提供更为丰富的细节信息,改善其视觉效果,使图像更符合人类或计算机的处理要求,从而能够更为准确地描述客观事物,在视频监控、卫星遥感

和医学成像等领域具有相当重要的应用价值。受到实际工艺水平等客观因素的限制,无法单纯依赖硬件上的改良来获得高分辨率的图像。因此利用软件技术,通过图像处理的方式来提高图像分辨率显得极为重要。

在图像处理中,由一幅或多幅低分辨率(LR)的

收稿日期: 2018-05-07; 修回日期: 2018-06-07; 录用日期: 2018-06-20

基金项目: 国家自然科学基金(61471382, 61401495)、山东省自然科学基金(ZR2016FQ17)

\* E-mail: lemony1314@163.com; \*\* E-mail: ljwei369@163.com

图像来重建出相应的高分辨率图像或图像序列的技术,称为超分辨率(SR)<sup>[1]</sup>。现有的超分辨率方法主要分为插值、基于重建和基于学习三类。其中插值法最为简单、高效,但效果差强人意。而凸集投影法、最大后验概率法、迭代反投影法等基于重建的方法则是利用先验知识,以图像退化模型为基础进行图像超分辨率重建。近年来又兴起了基于样例学习的图像超分辨率方法,随着人工智能的蓬勃发展,基于深度学习的超分辨率方法也得到了跨越式发展<sup>[2]</sup>。Dong 等<sup>[3]</sup>提出了基于卷积神经网络的图像超分辨率(SRCNN)方法,采用深度学习方法直接对 HR/LR 图像对进行训练学习,从而实现一个端到端的学习架构。孙超等<sup>[4]</sup>利用去卷积层与池化层组合对特征进行放缩,在实时重建图像的前提下,大幅提高了超分辨率性能。Kim 等<sup>[5]</sup>设计了多层网络来重建图像(VDSR),并借鉴残差网络(ResNet)<sup>[6]</sup>思想,利用残差学习来减轻网络的学习负担。同时, Kim 等<sup>[7]</sup>还提出一种深度递归卷积网络(DRCN)来增加网络的感受野,避免过多的网络参数,且效果相比 SRCNN 有了很大的提升。Tai 等<sup>[8]</sup>提出一种全局残差与局部残差相结合的训练网络(DRRN),并采用多权重的递归学习方法。Shi 等<sup>[9]</sup>在 SRCNN 上进行改进,提出一种利用亚像素卷积层的超分辨率(ESPCN)方法,通过重新排列特征图来获得高分辨率图像,大幅提高了运算速度。郑向涛等<sup>[10]</sup>提出一种自外而内的图像超分辨率复原算法,同时考虑外在样例和内在自相似性,利用图像的先验知识进行正则化约束。

但上述方法仅在空域对图像的超分辨率重建进行研究,通过对图像各像素点的变换来改善图像质量,所生成的图像相对平滑,缺少细节,即丢失了高频信息。而频域方法是在频域上消除频谱混叠效应,从而提高图像的空间分辨率效果,如小波变换可以在频域上将图像分解为平滑子图与细节子图,细节子图能够协助重建出高质量图像<sup>[11]</sup>。因此,本文借助小波变换能够提取细节信息的特性与深度网络优异的图像重建性能,提出一种结合小波变换与深度网络的超分辨率方法,在空域与频域的基础上,对图像进行重建。采用离散小波变换(DWT)将图像分解为低频子图与不同方向的高频子图,利用优化的深度网络对分解的子图进行重建,再将结果通过小波逆变换得到超分辨率图像。

理论分析与实验结果表明,本文方法具有良好的超分辨率性能。

## 2 小波变换

小波变换具有多分辨率分析功能和逐步分解等特性,因此常被用于信号处理领域。同时,小波变换的多尺度分解特性也更加符合人类的视觉机制。图像超分辨率重建面临的难点在于如何恢复图像在重建过程中损失的高频信息,也就是边缘细节信息等。传统的插值方法会对重建图像高频边缘细节成分产生平滑效应,即无法很好地保留丰富的高频成分,从而造成图像的模糊。而基于小波变换的图像超分辨率重建方法,借助小波分析能够提供优异的时频局部化特征信息,具有提取图像的边缘、细节信息的优势,能够在图像重建过程中全面利用图像的信息,使得超分辨率重建后的图像富含更多有价值的信息,且细节更加清晰明确<sup>[12]</sup>。

一维 DWT 可以看作将一维信号  $x[n]$  通过低通滤波器  $G_L(k)$  与高通滤波器  $G_H(k)$ , 二维 DWT 可看作一维 DWT 的延伸。例如,对图像  $I(x, y)$  进行二维小波变换,先沿着第  $x$  行的信号  $I(x, :)$  进行一维小波变换,然后再沿着第  $y$  列的信号  $I(:, y)$  进行一维小波变换。为叙述的方便,本文中所提到的小波变换即指二维小波变换,且本文选用 Haar 作为小波基函数。小波变换将图像分解为长宽仅为原始图像  $1/2$  的 4 个子图,这 4 个子图分别对应着水平低频垂直低频分量(LL)、水平高频垂直低频分量(LH)、水平低频垂直高频分量(HL)和水平高频垂直高频分量(HH),即低频部分和水平、垂直与对角三个方向的高频信号,分解过程示意图如图 1 所示。

低频分量对应着图像的主要轮廓,高频分量则对应着图像的边缘、细节,如图 2 所示,图片为数据集 Set5<sup>[13]</sup> 中的 butterfly\_GT.bmp,左侧为原始图像的灰度图,右侧为进行 DWT 操作分解得到的 4 个子图。为更好地体现出高频细节,将分解得到的三个高频子图进行二值化操作,图 2(a)~(d)分别为水平低频垂直低频分量 LL、水平低频垂直高频分量 HL、水平高频垂直低频分量 LH、水平高频垂直高频分量 HH。从图中可以看出,LL 子带图像基本保留了原始图像的大致信息,HL、LH、HH 子带图像则具有目标的边缘信息。

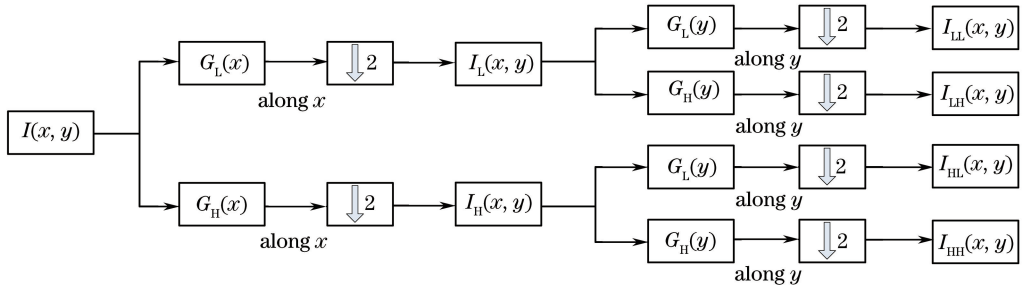
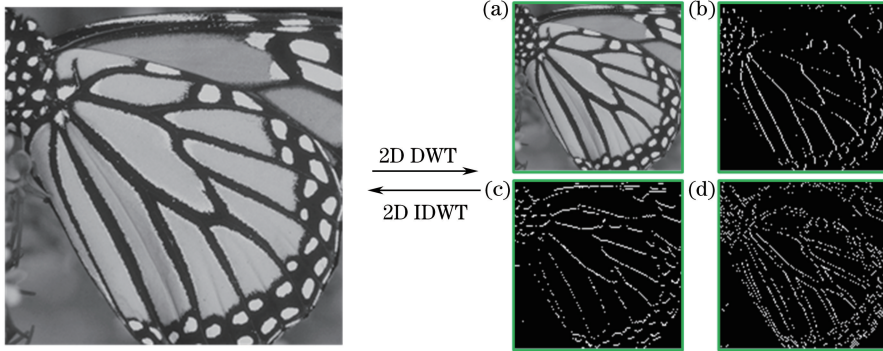
图 1 对图像  $I(x, y)$  进行二维小波变换的过程Fig. 1 Process of two-dimensional wavelet transform for image  $I(x, y)$ 

图 2 Set5 中的 butterfly\_GT.bmp 的二维 DWT 效果图

Fig. 2 Effects of two-dimensional DWT for butterfly\_GT.bmp in Set5

传统的基于小波变换的超分辨率图像重建方法主要分为三步:1)利用小波变换,将图像分解为低频分量 LL 与三个高频分量 HL、LH、HH;2)利用超分辨率方法,对每个分量都进行重建;3)对重建得到的分量进行离散小波逆变换(IDWT),从而得到超分辨率图像。离散小波逆变换的实现公式可表示为

$$\begin{cases} I_1 = i_{LL} + i_{HL} + i_{LH} + i_{HH} \\ I_2 = i_{LL} - i_{HL} + i_{LH} - i_{HH} \\ I_3 = i_{LL} + i_{HL} - i_{LH} - i_{HH} \\ I_4 = i_{LL} - i_{HL} - i_{LH} + i_{HH} \end{cases}, \quad (1)$$

式中  $i_{LL}$ 、 $i_{HL}$ 、 $i_{LH}$ 、 $i_{HH}$  分别表示 4 个子带图像对应位置的像素值,  $I_1$ 、 $I_2$ 、 $I_3$ 、 $I_4$  分别表示 IDWT 后得到的图像对应位置的像素值。

结合小波变换与深度网络的图像超分辨率方法,正常情况下需要把低分辨率、小尺寸图像  $I_S$  通过双三次插值法根据尺寸要求比例放大到对应大小的低分辨率图像  $I_{LR}$  中,再将  $I_{LR}$  小波分解为低频子图  $I_{LR-LL}$  与高频子图  $I_{LR-HL}$ 、 $I_{LR-LH}$ 、 $I_{LR-HH}$ ,之后将其输入到深度网络进行超分辨率重建,将输出结果通过小波逆变换得到超分辨率图像  $I_{SR}$ 。而根据 Haar 小波的尺度插值特性,将图像  $I_S$  进行插值操作得到  $I_{LR}$  后再进行 DWT,原图  $I_S$  可直接作为小波变换分解得到的低频信号部分  $I_{LR-LL}$ ,与其他三个高频信号

部分结合起来,通过这样的方式可以保留大部分的低频信息。因此,在利用深度网络对 4 个分量进行超分辨率重建时,仅需要把  $I_S$  与三个高频子图  $I_{LR-HL}$ 、 $I_{LR-LH}$ 、 $I_{LR-HH}$  作为网络输入。

### 3 深度网络

#### 3.1 网络结构

近几年来,众多研究人员积极开展对基于深度学习的图像超分辨率重建方法的研究,如 SRCNN、基于卷积神经网络的快速超分辨率(FSRCNN)<sup>[14]</sup>、ESPCN、VDSR、DRCN、DRRN 等,其中 SRCNN、FSRCNN、ESPCN 采用浅层网络,VDSR、DRCN、DRRN 采用深度网络。前者网络层数较少,网络参数少,训练快,不容易出现梯度爆炸或消失,但映射能力相对较弱,性能相比更深的网络略逊一筹;后者网络层数较多,从而产生较多的网络参数,训练负担大,且容易出现梯度爆炸或消失问题,但超分辨率性能相对较好。

其中由 Tai 等<sup>[8]</sup>提出的 DRRN 是受到 ResNet、VDSR、DRCN 的启发,采用全局残差学习结合多路径模式的局部残差学习,并采用多权重的递归学习,在基于深度网络的超分辨率方法中也展现出了优异性能。但 DRCN 中总共包含 52

层卷积层,结构臃肿且训练速度较慢,相比与VDSR 20层的网络结构,DRCN的超分辨率性能虽有所提升,但幅度不大。同时,DRCN中每个递归单元仅包含两个卷积层,映射能力不足。因此

本文从三个方面对文献<sup>[8]</sup>提出的深度递归残差网络DRRN进行修改,简化网络结构,加快训练速度,并使其能够完美结合小波变换方法。本文方法的流程如图3所示。

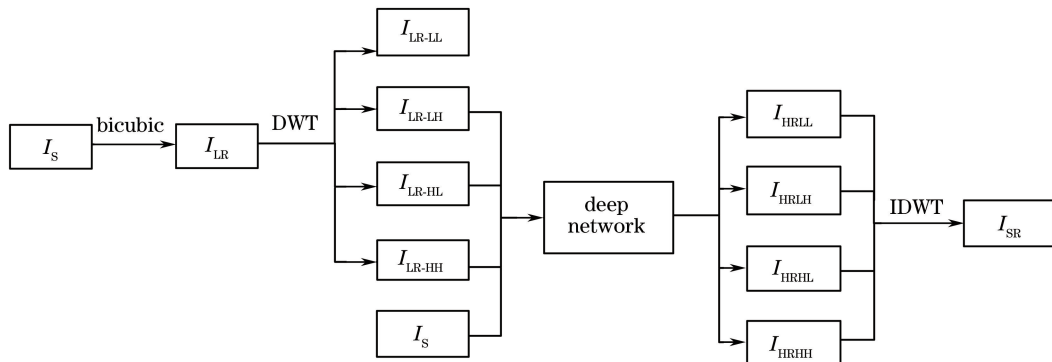


图3 本文方法流程图

Fig. 3 Flowchart of the proposed method

### 3.1.1 简化网络结构

DRRN的网络结构如图4(a)所示,红色单元表示递归块,黄色单元为卷积层,“+”表示图像间像素级相加,即残差学习。由图4可知,DRRN中采用若干递归“块”相串联,且前后“块”利用“skip connection”相连,使得每个递归残差单元都共有一个相同的输入,即深度网络中第一个卷积层输出的特征图,该操作为局部残差学习。DRRN将输入的低分辨率图像 $I_{LR}$ 与网络最后一个卷积层的输出相加,得到

超分辨率图像 $I_{SR}$ ,该操作为全局残差学习。

DRRN中每个“块”的内部结构如图4(b)中红色虚线框所示,每个“块”均包含两个归一层(BN)、激活层、卷积层,并按图示依次排列,其中激活层采用的是修正线性单元(ReLU)作为激活函数。DRRN中共有25个递归“块”,加上网络首尾各有一个卷积层,因此累计有52个卷积层,且每个“块”对应位置的卷积层共享权重,从而达到减少网络参数的目的。




图4 DRRN的网络结构图。(a)整体框架;(b)递归“块”的结构

Fig. 4 Network architecture of DRRN. (a) Hole architecture; (b) structure of recursive block

DRRN中“块”的结构是借鉴ResNet,而ResNet的提出是为了对图像进行分类识别,其中的BN层起到了很大的作用。但图像分类领域对图像的比例大小信息并不敏感,而在图像的超分辨率领域中,图像的比例信息至关重要。而且通过实验证明,在网络中加入BN层后,网络的收敛速度相对没

有BN层的较慢,且网络损失的波动较大<sup>[15]</sup>。除此之外,加入BN层还会增加计算机的内存消耗和训练负担。综合以上因素,本文去除了“块”中的BN层。

同时,本文改用带参数的修正线性单元(PReLU)作为激活函数,它能够在一定程度上起到

正则的效果<sup>[16]</sup>。此时,深度网络中的递归“块”内部结构如图 5(a)所示。相比于 DRRN 中的 ReLU, PReLU 以增添少量参数为代价,提升了网络的收敛速度,其公式可表示为

$$g(x_i) = \begin{cases} x_i, & \text{if } x_i > 0 \\ \alpha_i x_i, & \text{if } x_i < 0 \end{cases}, \quad (2)$$

式中  $\alpha_i$  表示可学习的参数,  $\alpha_0 = 0.25$ 。

### 3.1.2 减少卷积层

DRRN 中共计 25 个递归“块”,且每个“块”中包含两个卷积层,DRRN 是通过将这两个卷积层进

行递归学习,以少量网络参数为代价实现图像超分辨率。但每个递归单元中简单地包含两个卷积层,有权重更新的卷积层仅有 4 个,映射能力相对不足;并且网络共有 52 个卷积层,结构相对臃肿,训练速度较慢。因此,本文将 DRRN 中的递归“块”个数缩减为 6 个,并在每个递归单元中相应地加上两个卷积层与激活函数层,修改后的递归单元内部结构如图 5(b)所示。此时简化后的网络中仅有  $26(4 \times 6 + 2 = 26)$  个卷积层,相比 DRRN 而言,数量减少了 1/2。




图 5 修改后的递归“块”结构。(a) 去除 BN 层;(b) 减少卷积层

Fig. 5 Structure of modified recursive block. (a) Removing BN layers; (b) decreasing convolution layers

### 3.1.3 修改网络通道

人眼对图像的亮度信息更为敏感,因此在对低分辨率图像进行超分辨率重建时,通常将图像由 RGB 格式转换为 YCbCr 格式,再提取 YCbCr 图像中的 Y 通道图像,即亮度通道进行超分辨率重建,从而超分辨率网络的输入输出通道数均为 1。而在本文中,需要将低分辨率小尺寸图像  $I_S$  与低分辨率图像  $I_{LR}$  小波变换得到的三个高频子图  $I_{LR-HL}$ 、 $I_{LR-LH}$ 、 $I_{LR-HH}$  作为网络输入,并相应地得到 4 个低频与高频的输出子图。因此在本文中,深度网络输入

输出的通道数相应修改为 4。

本文结合小波变换与深度网络的图像超分辨率方法(CWTDN)的实现示意图如图 6 所示。首先低分辨率小尺寸图像  $I_S$  通过双三次插值放大为低分辨率图像  $I_{LR}$ ,再通过小波变换得到低频子图  $I_{LR-LL}$  与高频子图  $I_{LR-HL}$ 、 $I_{LR-LH}$ 、 $I_{LR-HH}$ ,之后将  $I_S$  与  $I_{LR-HL}$ 、 $I_{LR-LH}$ 、 $I_{LR-HH}$  输入到深度网络进行超分辨率重建,最后将输出结果  $I_{SR-LL}$ 、 $I_{SR-HL}$ 、 $I_{SR-LH}$ 、 $I_{SR-HH}$  通过小波逆变换得到超分辨率图像  $I_{SR}$ 。




图 6 所提方法的实现示意图

Fig. 6 Realization schematic of the proposed method

## 3.2 网络训练

通常情况下,用一组真实图像  $\{I_{\text{truth}}\}$  和网络预测图像  $\{I_{\text{SR}}\}$  的均方误差(MSE)来表示损失函数,公式表示为

$$L_{\text{loss}} = \frac{1}{n} \sum_{i=1}^n \| I_{\text{SR}} - I_{\text{truth}} \|_2^2, \quad (3)$$

式中  $n$  为训练集的数目。

而在本文中,需要计算真实图像  $\{I_{\text{truth}}\}$  的小波变换结果  $I_{\text{truth-DWT}} = \{I_{\text{truth-LL}}, I_{\text{truth-LH}}, I_{\text{truth-HL}}, I_{\text{truth-HH}}\}$  与深度网络输出结果  $I_{\text{SR-DWT}} = \{I_{\text{SR-LL}}, I_{\text{SR-LH}}, I_{\text{SR-HL}}, I_{\text{SR-HH}}\}$  的均方误差来计算网络的损失,其公式表示为

$$L_{\text{loss}} = \frac{1}{n} \sum_{i=1}^n \| I_{\text{truth-DWT}} - I_{\text{SR-DWT}} \|_2^2. \quad (4)$$

本文采用峰值信噪比(PSNR)作为超分辨率重建图像质量的客观评价指标。PSNR 值越高,说明图像失真越小,即图像的质量越高。

## 4 实验设置与结果分析

### 4.1 实验设置

采用文献[13]提供的 91 幅图像与文献[5]提供的 200 幅图像作为训练图像集,采用文献[13]中的 Set5、Set14 与文献[17]中 Berkeley Segmentation Datasets 的 BSD100 作为测试集。

首先通过缩放与旋转的方式,对训练图像的数量进行增强,再将训练样本集中的图像按比例进行降采样,从而得到对应的低分辨率小尺寸图像,然后设置子图像大小为  $f_{\text{sub}}=41$ 、步长为 21,将训练集裁剪成若干子图像,之后提取出相应的亮度通道图像  $I_S$ ,并进行小波变换得到低频子图  $I_{\text{LR-LL}}$  与高频子图  $I_{\text{LR-HL}}$ 、 $I_{\text{LR-LH}}$ 、 $I_{\text{LR-HH}}$ ,  $I_S$  与  $I_{\text{LR-HL}}$ 、 $I_{\text{LR-LH}}$ 、 $I_{\text{LR-HH}}$  即为网络训练阶段的输入。

网络的学习方法采用最小块梯度下降法,其中设置动量  $\mu=0.9$ ,学习率  $\epsilon=0.1$ ,权重衰减为  $10^{-4}$ ,每训练 10 个数据周期将学习率  $\epsilon$  减小 1/2。同时采用可调节梯度裁剪策略来加速网络收敛速度并抑制梯度的爆炸。

实验所用电脑搭载的是 Intel Core i7-7700K

表 1 不同放大比例下各测试集经不同方法处理后 PSNR 的平均值

Table 1 Mean PSNR of test datasets processed by all methods with different up-scale factors

dB

Dataset	Scale	Bicubic	Self-Ex	SRCNN	SCN	FSRCNN	ESPCN	VDSR	DRRN	SDN	CWTDN
Set5	×2	33.66	36.67	36.49	36.65	37.02	36.82	37.49	37.61	37.53	37.74
	×3	30.39	32.58	32.58	32.75	33.19	32.87	33.62	33.92	33.69	33.98
	×4	28.42	30.3	30.31	30.48	30.75	30.71	31.30	31.60	31.36	31.71
Set14	×2	30.23	32.35	32.22	32.29	32.67	32.58	33.00	33.14	33.01	33.20
	×3	27.54	29.13	29.16	29.28	29.46	29.40	29.73	29.85	29.70	29.96
	×4	26.00	27.33	27.40	27.49	27.62	27.51	27.95	28.14	27.99	28.28
BSD100	×2	29.56	31.49	31.18	31.36	31.68	31.59	31.85	31.96	31.90	32.04
	×3	27.21	28.30	28.29	28.41	28.52	28.49	28.77	28.86	28.79	28.97
	×4	25.95	26.86	26.84	26.90	27.02	26.98	27.20	27.30	27.22	27.38

为了更清晰地对比本文方法与其他方法的结果,图 7 所示为 3 倍放大比例下,双三次插值、SRCNN、FSRCNN、VDSR、DRRN 与本文 SDN、SWTDN 等 7 种方法对 Set14 测试集中 monarch.bmp 图像的测试结果。图 8 所示为 4 倍放大比例下,上述 7 种方法对 BSD100 测试集中 21077.bmp 图像的测试结果。

CPU,NVIDIA 11G GTX1080 Ti 显卡,软件配置的是 64 位的 Ubuntu 16.04 LTS 与 Caffe、Mtalab 2015a、CUDA 8.0、Cudnn 5.1。

### 4.2 结果及分析

为了验证所提 CWTDN 方法的图像超分辨率性能,本文在相关公开数据集上进行了测试,并将实验结果与双三次插值及经典方法 SRCNN、基于稀疏编码网络(SCN)<sup>[18]</sup>的方法、FSRCNN、ESPCN、利用变换自相似(Self-Ex)<sup>[19]</sup>的方法、VDSR、DRRN 进行了对比。同时,还对本文简化的深度网络(SDN)按常规方法进行测试,即不结合小波变换,仅对亮度通道的图像进行超分辨率重建。

表 1 所示为在 2、3、4 倍放大比例下,各方法对测试集中图像重建结果的 PSNR 平均值。从表 1 可以看出,本文改进的简化深度网络 SDN 方法生成的图像相比大部分方法的实验结果,具有更高的 PSNR 值,但仍稍逊于 DRRN 的结果,而 CWTDN 取得了最高的 PSNR 值。由此可知,SDN 的超分辨率性能近似于 VDSR,稍逊于 DRRN,而 CWTDN 相比现有方法,具有最佳的超分辨率性能。与此同时,SDN、DRRN、CWTDN 的网络训练时间分别为 47,71,52 h,对 Set14 测试集的运行时间分别为 0.86,1.59,0.95 s,SDN 相比 DRRN 的训练与测试速度分别提高了 33.8%、45.9%,CWTDN 相比 DRRN 提高了 26.8%、40.3%。

图 7 所示为原图与处理后的效果图,同时在各图中用红色矩形框标注了一块区域(蝴蝶翅膀条纹部分)并放大置于图片左下角,便于更直观清晰地对比。其中图 7(b)中双三次插值法重建效果最为模糊,难以分辨边缘,无法判断;SRCNN、FSRCNN 这两种浅层网络的超分辨率效果稍好,但普遍弱于下方采用深度网络的 4 种方法。本文 CWTDN 方法



图 7 3 倍放大比例下, Set14 测试集中 monarch.bmp 经处理后的整体及局部效果对比图。(a) 真实图像; (b) Bicubic/29.43 dB; (c) SRCNN/32.39 dB; (d) FSRCNN/32.44 dB; (e) VDSR/34.51 dB; (f) DRRN/34.68 dB; (g) 本文 SDN/34.53 dB; (h) 本文 CWTDN/34.82 dB

Fig. 7 Whole and local comparisons of "monarch.bmp" in Set14 processed with scale  $\times 3$ . (a) Real image; (b) Bicubic/29.43 dB; (c) SRCNN/32.39 dB; (d) FSRCNN/32.44 dB; (e) VDSR/34.51 dB; (f) DRRN/34.68 dB; (g) proposed SDN/34.53 dB; (h) proposed CWTDN/34.82 dB




图 8 4 倍放大比例下, BSD100 测试集中 "21077.bmp" 经处理后的整体及局部效果对比图。(a) 真实图像; (b) Bicubic/24.88 dB; (c) SRCNN/25.84 dB; (d) FSRCNN/26.13 dB; (e) VDSR/26.57 dB; (f) DRRN/26.75 dB; (g) 本文 SDN/26.60 dB; (h) 本文 CWTDN/26.91 dB

Fig. 8 Whole and local comparisons of "21077.bmp" in BSD100 processed with scale  $\times 4$ . (a) Real image; (b) Bicubic/24.88 dB; (c) SRCNN/25.84 dB; (d) FSRCNN/26.13 dB; (e) VDSR/26.57 dB; (f) DRRN/26.75 dB; (g) proposed SDN/26.60 dB; (h) proposed CWTDN/26.91 dB

重建出的蝴蝶最为清晰, 纹理放大部分能够清晰分辨纹路、有更为锐利的边缘, 能够看出黑色纹路、白色纹路与黄色底纹的交替过渡, 与原图放大效果最为相似, 具有最好的视觉效果。

图 8 也对原图中赛车左前方一角与地面相交处进行了局部放大并置于图片左上角。由列出的 8 幅图中可以明显对比看出, 仅有 DRRN 与本文的 CWTDN 方法重建出了相对清晰的边缘, 其中本文方法的超分辨率效果最佳, 其他方法的结果都略显模糊, 难以分辨。本文简化的深度网络 SDN 重建图像的视觉效果与 VDSR 近似, 仅次于 DRRN 与 CWTDN。

## 5 结 论

针对现有基于学习的超分辨率方法难以恢复图像细节的问题, 提出了一种结合小波变换与深度网络的图像超分辨率方法, 将小波变换能够提取图像

高频信息的特点与深度网络优异的图像重建性能相结合, 优化已有的深度网络模型并作出修改来相应结合小波变换。相关实验结果表明, 本文方法能够良好地恢复图像细节, 具有优异的超分辨率性能。下一步, 将进一步研究小波变换与深度网络之间更佳结合方式, 从而提高超分辨率性能。

## 参 考 文 献

- [1] Su H, Zhou J, Zhang Z H. 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.
- [2] 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.
- [3] 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.
- [4] 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.
- [5] Kim J, Lee J K, Lee K M. Accurate image super-resolution using very deep convolutional networks [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2016: 1646-1654.
- [6] He K M, Zhang X Y, Ren S Q, *et al.* Deep residual learning for image recognition [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [7] Kim J, Lee J K, Lee K M. Deeply-recursive convolutional network for image super-resolution [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2016: 1637-1645.
- [8] Tai Y, Yang J, Liu X M. Image super-resolution via deep recursive residual network [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2790-2798.
- [9] Shi WZ, Caballero J, Huszár F, *et al.* Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2016: 1874-1883.
- [10] Zheng X T, Yuan Y, Lu X Q. Single image super-resolution restoration algorithm from external example to internal self-similarity [J]. Acta Optica Sinica, 2017, 37(3): 0318006.  
郑向涛, 袁媛, 卢孝强. 自外而内的单幅图像超分辨率复原算法 [J]. 光学学报, 2017, 37(3): 0318006.
- [11] Anbarjafari G, Demirel H. Image super resolution based on interpolation of wavelet domain high frequency subbands and the spatial domain input image [J]. ETRI Journal, 2010, 32(3): 390-394.
- [12] Chavez-Roman H, Ponomaryov V. Super resolution image generation using wavelet domain interpolation with edge extraction via a sparse representation [J]. IEEE Geoscience and Remote Sensing Letters, 2014, 11(10): 1777-1781.
- [13] 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.
- [14] Dong C, Loy C C, Tang X. Accelerating the super-resolution convolutional neural network [C] // European Conference on Computer Vision. Springer, Cham, 2016: 391-407.
- [15] Nah S, Kim T H, Lee K M. Deep multi-scale convolutional neural network for dynamic scene deblurring [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2017: 257-265.
- [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] Martin D, Fowlkes C, Tal D, *et al.* A database of Human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics [C] // IEEE International Conference on Computer Vision, 2001: 416-423.
- [18] Wang Z W, Liu D, Yang J C, *et al.* Deep networks for image super-resolution with sparse prior [C] // IEEE International Conference on Computer Vision (ICCV), 2015: 370-378.
- [19] Huang J B, Singh A, Ahuja N. Single image super-resolution from transformed self-exemplars [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2015: 5197-5206.