

# 基于深度残差学习的彩色图像去噪研究

王晓红<sup>1</sup>, 刘芳<sup>1</sup>, 麻祥才<sup>2</sup>

(1. 上海理工大学, 上海 200093; 2. 上海出版印刷高等专科学校, 上海 200093)

**摘要:** 目的 当噪声存在时, 尤其是等级相对较大的噪声, 会导致彩色图像的视觉质量下降, 为了有效去除噪声的同时使去噪后的图像有更好的视觉效果, 提出一种基于深度残差学习的彩色图像去噪方法。**方法** 首先设计由多个残差单元模块组成的残差层, 然后在每个残差单元模块之间添加跳跃连接, 构成由噪声图像到去噪图像的非线性映射, 并优化残差单元个数, 使网络能学习到更多的图像细节特征, 以提升网络的去噪性能, 同时将每个残差单元模块中的激活函数提到卷积层前面, 以加速网络收敛。**结果** 与常用去噪算法相比, 文中方法在 Kodak24 和 CBSD100 数据集上的主观视觉打分 MOS 值以及客观指标(PSNR 和 SSIM)上, 较其他方法有更好的效果。**结论** 提出的基于深度残差学习的彩色图像去噪方法能有效去除图像中的噪声, 尤其是较严重的噪声, 并取得了良好的视觉效果, 表明该方法具有良好的去噪性能。

**关键词:** 图像去噪; 深度残差学习; 残差单元模块; 去噪方法

**中图分类号:** TS801.3    **文献标识码:** A    **文章编号:** 1001-3563(2019)17-0235-08

**DOI:** 10.19554/j.cnki.1001-3563.2019.17.034

## Color Image Denoising Based on Depth Residual Learning

WANG Xiao-hong<sup>1</sup>, LIU Fang<sup>1</sup>, MA Xiang-cai<sup>2</sup>

(1. Shanghai University of Science and Technology, Shanghai 200093, China;

2. Shanghai Publishing and Printing College, Shanghai 200093, China)

**ABSTRACT:** When the noise exists, especially the relatively serious noise level, the visual quality of color image will be reduced. The work aims to propose a color image denoising method based on depth residual learning, in order to remove noise effectively and make the denoised image have better visual effect. Firstly, a residual layer consisting of several residual unit modules was designed, and then the skip connection was added between residual unit modules to form the non-linear mapping from noise image to denoised image. The number of residual units was optimized, so that the network could learn more image details to improve the denoising performance. At the same time, the activation function of each residual unit module is moved to the front of the convolution layer to accelerate the network convergence. Compared with common denoising algorithms, the proposed method had better effects in subjective visual score MOS values and objective indicators (PSNR and SSM) on Kodak24 and CBSD100 datasets. The proposed color image denoising method based on depth residual learning can effectively remove the noise in the image, especially when the noise is serious, and obtain satisfactory visual effect, which shows that the proposed method has good denoising performance.

**KEY WORDS:** image denoising; depth residual learning; residual unit module; denoising method

---

收稿日期: 2019-02-27

基金项目: 上海市自然科学基金(16ZR1422800);“基于柔印产品特性的智能化印前图像处理”招标课题(ZBKT201809);上海市教育发展基金会和上海市教育委员会“晨光计划”(18CGB09)

作者简介: 王晓红(1971—), 女, 上海理工大学教授, 主要研究方向为数字图像信息处理与色彩再现理论及深度学习。

数字图像在采集、传输过程中受环境、设备、人为因素等影响，不可避免地引入噪声，从而降低图像质量，影响图像的可读性<sup>[1]</sup>。噪声的微小变化，都会影响人眼视觉感知，所以去噪是提高图像质量非常重要的方法之一，同时去噪便于后续处理图像的分类、分割及图像识别等。在日常中，高斯白噪声广泛存在于雷达和通信系统领域，比较难去除，且能更好地模拟真实中的噪声。

图像去噪的目的是从含有被噪声腐蚀的图像中恢复图像原始信息，该过程可由式(1)表示：

$$g(x,y)=f(x,y)+\mu(x,y) \quad (1)$$

式中： $g(x,y)$ 为含有噪声的二维图像； $f(x,y)$ 为无噪声的原始图像； $\mu(x,y)$ 为添加的具有标准偏差 $\sigma$ 的加性高斯白噪声(AWGN)，原始图像经过加性噪声项处理，退化为含噪图像。图像去噪就是为了获得原始图像的一个估计 $f'(x,y)$ ，并使其尽可能接近原始图像的过程。

图像去噪的研究由来已久，传统的研究利用图像先验模型去噪，如非局部自相似(NSS)模型<sup>[2-3]</sup>、梯度模型<sup>[4]</sup>、稀疏字典学习模型<sup>[5]</sup>和马尔可夫随机场(MRF)模型<sup>[6]</sup>等，其中较经典的方法有三维块匹配去噪算法(BM3D)<sup>[3]</sup>及相应的许多变体，如其对彩色图像的扩展CBM3D<sup>[7]</sup>以及用外部先验<sup>[8]</sup>来去除噪声。研究表明，从大量高清的外部图像数据集中选择正确的类似补丁，理论上可以抑制噪声，然而在实际的单个图像去噪时，直接利用来自大量外部数据库中的补丁是不合理的，适用性有限。除此之外，这些模型通常涉及一些比较复杂的优化问题，使去噪过程较为耗时，而且在去噪过程中需要人工调整参数，不能完全实现自动化、智能化<sup>[9]</sup>。

近年来，深度学习方法在图像处理当中取得了巨大成功，很多学者已经开发研究了许多用于图像去噪的深度学习模型，目前基于深度学习的去噪方法主要分为2类：基于多层感知模型(MLP)和基于卷积神经网络模型(CNN)。Burger等首先使用多层感知器(MLP)<sup>[10]</sup>实现类似BM3D的去噪性能，随后，Chen<sup>[11]</sup>等人提出判别式的学习模型(TRND)，并取得比传统方法更好的结果。2008年Jain<sup>[12]</sup>等首次提出用(CNN)处理图像的去噪问题。2016年，Mao<sup>[13]</sup>等提出了深度的卷积编解码网络应用于图像去噪，该网络采用了卷积和解卷积层间的跳跃连接，但是网络较深，不容易收敛。2015年，He等<sup>[14]</sup>提出了残差学习，起初是为解决图像性能退化问题而提出的。2017年，Zhang等提出了(IRCNN)模型<sup>[15]</sup>，采用扩张卷积来学习残差图像进行去噪。Zhang等人还提出了一种针对高斯噪声的深度残差学习模型(DnCNN)<sup>[16]</sup>，该模型利用深度卷积神经网络不断学习每层网络的残差，并引入批标准化，但因为其全卷积的网络结构，训练时间较长。2017

年，Xu等<sup>[17]</sup>提出了多通道加权核范数(MCWNNM)对RGB彩色图像进行去噪，尽管对每个颜色通道使用不同的权重进行处理，但忽略了整体的RGB彩色图像颜色通道之间的关系，去噪后的视觉效果也不佳。2018年，Zhang等人提出了(FFDNet)模型<sup>[18]</sup>，该模型使用噪声估计图作为输入，能有效应对更加复杂的真实场景的噪声，尽管该模型能较好地去除高斯噪声，但是去噪后的图像细节过平滑，边缘信息丢失。

噪声尤其是较严重噪声的存在，使彩色图像去噪后视觉效果不佳，为此文中提出一种基于深度残差学习的彩色图像去噪方法(Color image denoising based on depth residual learning，IDDRRL)。该模型在隐含层引入多个具有跳跃连接的残差单元模块，信号可以从一个残差模块直接传到另一个单元模块，有助于训练的稳定性，避免梯度消失问题，同时每个残差单元模块中将Relu激活函数提到卷积层前面，以加速网络收敛。将含噪图像通过该网络学习端到端的非线性映射方式来重建去噪图像。以Kodak24和CBSD100作为测试集，从主观和客观评价两方面和现有算法进行了比对。

## 1 深度残差去噪网络设计

传统的卷积网络或全连接网络在传递信息时，会存在信息丢失及损耗等问题，而残差网络则通过直接将输入信息传到输出，解决随网络加深梯度消失的问题，以保护信息的完整性，整个网络只需要学习输入与输出之间的差别，不再是一幅完整的图像。典型的残差学习框架见图1。

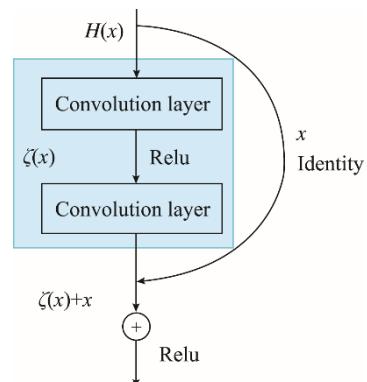


图1 残差学习框架  
Fig.1 Residual learning framework

残差框架结构中的非线性层拟合残差为：

$$\zeta(x) = H(x) - x \quad (2)$$

式中： $H(x)$ 为含噪声图； $\zeta(x)$ 为去噪后的图； $x$ 为残差网络训练预测到的噪声。

利用残差优化找到近似最优的恒等映射。由于残差相比于 $H(x)$ 会减少很多特征，更容易找到最优结果，重要的是网络训练时间也会相应减少，性能也会提高。

残差去噪网络是在传统残差网络的基础上设计一个深度网络模型，主要由 4 部分组成：输入输出层、特征提取层(ReLU+conv)、残差单元模块、网络重构层(conv)。残差模块是由 7 个残差单元块组成的卷积神经网络，每个模块由 4 个预激活函数后接卷积网络组成，每个残差单元块之间有跳跃连接，构成含噪图像与去噪图像的非线性映射关系，见图 2。

1) 输入输出层。提出的网络以原始图像作为输入，避免复杂耗时的图像预处理过程，通过残差去噪网络得到去噪后的图像，输出层与输入层的图像大小一致。

2) 特征提取层(ReLU+conv)。提出的网络采用图像块进行训练，因为使用来自不同图像的局部结构、图案、形状和颜色混合组成的图像块补丁，有助于网络特征的提取。因此将训练集中的无噪声图像分成大小为  $40 \times 40$  的子块，经过加噪处理获得网络所需的含噪图像子块作为训练样本，将这些小块样本从图像空间映射到特征空间，学习图像的特征，然后将这些特征作为滤波器，与整个原始图像作卷积运算，从而得到原始图像中任意位置上不同特征的激活值。使用 ReLU 激活函数和一个  $3 \times 3$  核大小的卷积层，用来提

取图像块的特征值，并将该层中获得的每个神经元传递到残差单元模块。

3) 残差单元模块。该残差单元结构由 7 个残差单元块串联组成，每个残差单元输出直接反馈到后续的残差单元模块中。每个残差单元块有 4 个卷积层，并在每个残差单元模块之间添加跳跃连接，跳跃连接使用恒等映射，从而使网络能学习到更多的图像细节特征，提升网络的去噪性能。另外将非线性激活函数 ReLU 移到每个卷积层(conv)的前面，实验证明这种预激活模式(pre-activation)<sup>[19]</sup>能提高训练过程中的收敛速度，每个残差单元模块的数学表达式为：

$$G^V = F(G^{V-1}) + G^{V-1} \quad (3)$$

式中： $G$  为每个残差单元块； $V$  为单元块的个数， $V = 1, 2, 3, \dots$ ； $F$  为残差映射函数。

4) 网络重构层(conv)。在网络最后一层设置单独的  $3 \times 3$  的卷积层作为网络输出层，通过前面的残差单元块的输出图像块的特征图，馈送到最后的卷积层，以产生具有与输入图像相同数量的通道的张量，最终融合成一个完整的图像。该层直接从噪声图像中预测噪声分量，从含噪声图中减去噪声分量以得到去噪后的图像。模型的重构阶段见图 3。

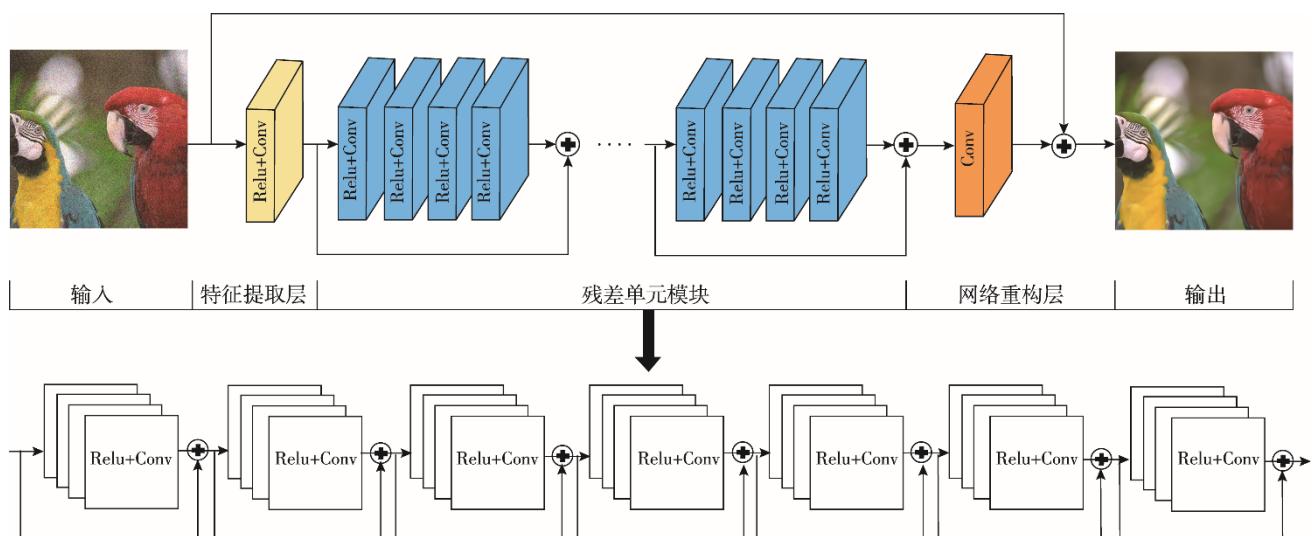


图 2 深度残差去噪网络  
Fig.2 Depth residual denoising network



图 3 模型的重构阶段  
Fig.3 Model reconstruction phase 采用的损失函数

为逐像素损失函数(MSE),计算重构后的去噪图像与原图像的均方根误差,使两者逐像素点比较,公式为:

$$L_{\text{MSE}}(\lambda, \gamma) = \frac{1}{HW} \sum_{i=1}^H \sum_{j=1}^W (F(\lambda)_{i,j} - \gamma_{i,j})^2 \quad (4)$$

式中: $H$ 和 $W$ 分别为输入图像的高度和宽度; $\gamma$ 为输入图像; $F(\lambda)$ 为重构图像, $F(\lambda)_{i,j}$ 中的 $i$ 和 $j$ 分别代表 $F(\lambda)$ 中第 $i$ 行和第 $j$ 列的像素。

## 2 实验结果与分析

### 2.1 数据集和评价指标

#### 2.1.1 数据集

采用经典的Kodak24数据集和CBSD100作为测试集,Kodak24数据集是图像处理领域常用的测试图像,CBSD100来自CBSD500数据集,包含不同的自然场景图。采用的训练集为CBSD400中的400幅自然图像。

#### 2.1.2 评价指标

1)客观评价。采用峰值信噪比(PSNR)和结构相似性(SSIM)作为定量的评价指标,其定义分别为:

$$P_{\text{PSNR}} = 10 \lg \left[ \frac{(2^n - 1)^2}{L_{\text{MSE}}} \right] \quad (5)$$

式中, $L_{\text{MSE}}$ 为原图像与去噪图像的均方根误差。

$$S_{\text{SSIM}}(x, y) = \frac{(2\epsilon_x \epsilon_y + d_1)(2\sigma_{xy} + d_2)}{(\epsilon_x^2 + \epsilon_y^2 + d_1)(\sigma_x^2 + \sigma_y^2 + d_2)} \quad (6)$$

式中: $x$ 和 $y$ 为2幅图像; $\epsilon_x$ , $\epsilon_y$ 为均值; $\sigma_x^2$ 和 $\sigma_y^2$ 为方差; $\sigma_{xy}$ 是 $x$ 和 $y$ 的协方差; $d_1 = (k_1 L)^2$ , $d_2 = (k_2 L)^2$ ; $L$ 是像素值的动态范围; $k_1 = 0.01$ , $k_2 = 0.03$ 。PSNR值为0~100,SSIM的值为0~1,2幅图像越相似,PSNR和SSIM值越大,即去噪效果越好。

2)主观评价。人眼主观评价MOS值进行视觉打分。分数为1~5,1是最低分,代表图像质量差,5是最高分,代表图像质量好。

### 2.2 实验环境与参数选择

训练了针对高斯白噪声的单级别去噪网络,其标准偏差(std)分别为10,30,50,网络的训练和测试都在Caffe<sup>[20]</sup>工具上进行,实验硬件设备为Intel Core i3-4790k 4.0 GHz,NVIDIA Quadro T4000 GPU。

每个网络都是从训练集中随机生成大小为40×40的噪声图像与原图像块对,卷积层采用64个尺寸为3×3的滤波器,采用批大小为10的随机梯度下降算法(SGD)对回归目标进行优化训练,初始学习率设定为0.001,动量参数为0.9,根据文献<sup>[21]</sup>中的方

法,通过随机初始化卷积权重来训练网络和正则化强度,即权重衰减为0.0001,训练60 000次迭代后终止训练。

### 2.3 层数选择

针对每个残差单元模块中的不同卷积层数进行训练,分析了每个残差单元模块中不同网络层数对去噪结果的影响规律,以CBSD100测试集为例,在噪声等级为30时不同层数下的平均PSNR值,见表1。由表1可以看出,每个残差模块的卷积层为2时,PSNR值较低,随着层数的增加,PSNR值也相应增加,当层数为4层以后,PSNR值的变化趋势几乎稳定,见图4。随着网络的不断加深,训练时间成本变大,为了快速并有效去除噪声,选择每个残差单元为4个卷积层的模块,以下实验结果都是在此层数下训练后测试的结果。

表1 每个残差模块不同卷积层数下的平均PSNR值  
Tab.1 Average PSNR/dB values of each residual module for different convolutional layers dB

Dataset	2	3	4	5	6
CBSD100	30.20	30.27	30.31	30.32	30.33

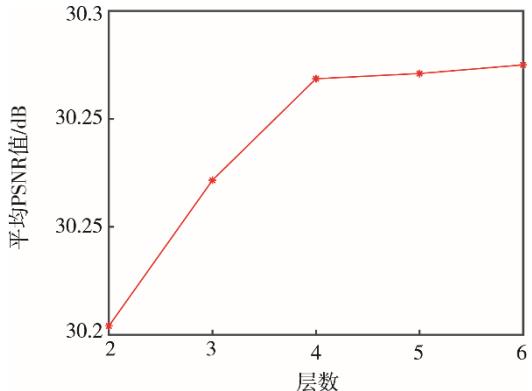


图4 不同层数的变化曲线  
Fig.4 Variation curve of different layers

### 2.4 模块数选择

深度学习中增加网络的深度,往往能够使网络习到更多的细节,得到更优的效果,但是网络也不是越深越好。为了对比不同数量的残差单元模块对去噪性能的影响,训练了不同模块数的网络,结合训练所用时间及去噪效果,以选择最优的残差单元模块。以CBSD100测试集为例,在噪声等级为30时不同层数下的平均PSNR值见表2。可以看出,在残差单元模块数相对较少时,PSNR值较低,随着残差模块数的增多,网络逐渐加深,其PSNR值先上升后趋于稳定,但以相应的时间损耗作为代价,见图5。4个残差单元的模块处理一张图像需要0.24 s,而8个残差模块则需要1.46 s。在训练网络的过程中差距表现得更加

明显，相同的训练周期，4 个残差模块的网络比 8 个残差模块的网络所用时间多几个小时，结合时间及去噪性能的影响，选择去噪效果较好、耗时较少的残差模块数。

表 2 不同残差模块数的平均 PSNR 值

Tab.2 Average PSNR/dB values for different number of residual modules

Dataset	4	6	7	8	9	dB
CBSD100	30.22	30.30	30.31	30.31	30.32	

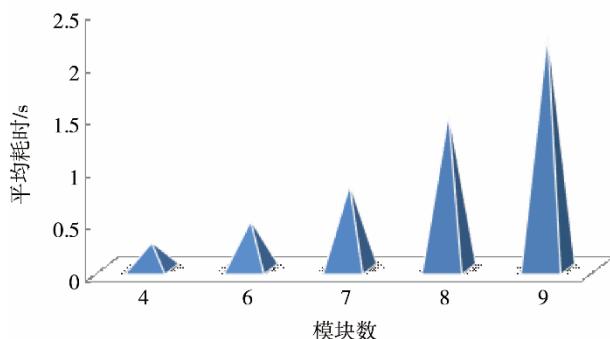


图 5 不同残差模块数测试图像的平均耗时  
Fig.5 Average running time of image tested by different number of residual modules

## 2.5 结果分析

为了验证算法的有效性，采用主观评价和客观评价进行对比实验，与 CBM3D，MCWNNM，DnCNN 和 FFDNet 等当前最具有代表的去噪网络进行比较。

1) 客观评价比对。Kodak24 和 CBSD100 等 2 种

测试集上分别添加标准差为 10, 30, 50 的高斯白噪声，其 PSNR 值和 SSIM 值分别见表 3 和 4。可以看出，IDDRN 算法在 PSNR 和 SSIM 上较其他算法有所提高，尤其是噪声相对较严重时，相比 CBM3D，MCWNNM，DnCNN 和 FFDNet，在 CBSD100 测试集 30 噪声级别时的 PSNR 值分别提高了约 0.77, 1.42, 0.19, 0.11 dB。SSIM 值在 Kodak24 测试集 10 噪声级别时和 FFDNet 相当，但在其他噪声等级相对较大时，SSIM 均比其他算法高。PSNR 值越高意味着失真越小，SSIM 值越接近 1 时，说明处理后图像结构与原图结构相似度越高。

2) 主观评价比对。为了更真实反映算法与其他方法在主观视觉上的差异，分别从 2 个测试集中选取几张样本图片的去噪结果进行主观实验，Kodak24 和 CBSD100 测试集在噪声等级为 30 时的去噪结果见图 6—7，CBSD100 测试集在噪声等级为 50 时的去噪结果见图 8，图 6 为整幅图像，图 7 选取石像的局部细节，图 8 截取花瓶的花纹部分。

由图 8 可以看出，CBM3D 虽然去除了噪声，但是明显产生边缘模糊的光滑部分，MCWNNM 在图像边缘区域产生伪影，且这 2 种方法去噪后的图像细节丢失严重，视觉效果很差。DnCNN 和 FFDNet 较前 2 种方法保留了更多部分细节，但还是不够完善；相比之下，算法 IDDRN 去噪效果最接近原图，恢复出更多的细节信息，视觉效果更佳。尤其石头粗糙不同的表面细节，小孩的嘴唇边缘部分以及花瓶的花纹部分，这说明文中的方法可以得到质量最好的去噪效果。

表 3 2 种测试集在不同方法不同噪声级别的 PSNR 值  
Tab.3 PSNR/dB values of two test sets in different methods and at different noise levels

Dataset	Noise	CBM3D	MCWNNM	DnCNN	FFDNet	IDDRN	dB
Kodak24	10	36.42	36.27	36.66	36.69	36.71	
	30	30.74	30.16	31.19	31.27	31.38	
	50	28.46	27.15	28.85	28.98	29.25	
CBSD100	10	35.75	35.20	35.92	35.97	35.98	
	30	29.54	28.89	30.12	30.12	30.31	
	50	27.19	25.85	27.72	27.76	27.92	

表 4 2 种测试集在不同方法不同噪声级别的 SSIM 值  
Tab.4 SSIM values of two test sets in different methods and at different noise levels

Dataset	Noise	CBM3D	MCWNNM	DnCNN	FFDNet	IDDRN
Kodak24	10	0.9417	0.9402	0.9455	0.9455	0.9453
	30	0.8447	0.8313	0.8597	0.8582	0.8612
	50	0.7759	0.7462	0.7965	0.7941	0.7972
CBSD100	10	0.9052	0.9015	0.9526	0.9529	0.9531
	30	0.8104	0.8490	0.8549	0.8531	0.8556
	50	0.7323	0.7643	0.7789	0.7754	0.7798

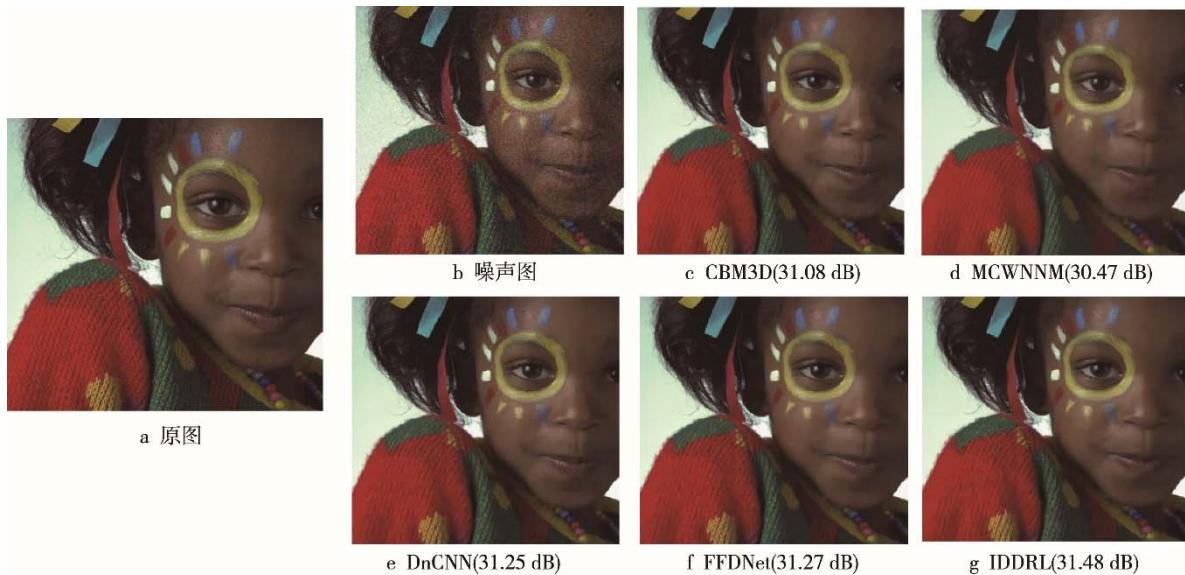


图 6 不同算法在  $\sigma=30$  时去噪结果比较  
Fig.6 Comparison of denoising results of different algorithms ( $\sigma=30$ )

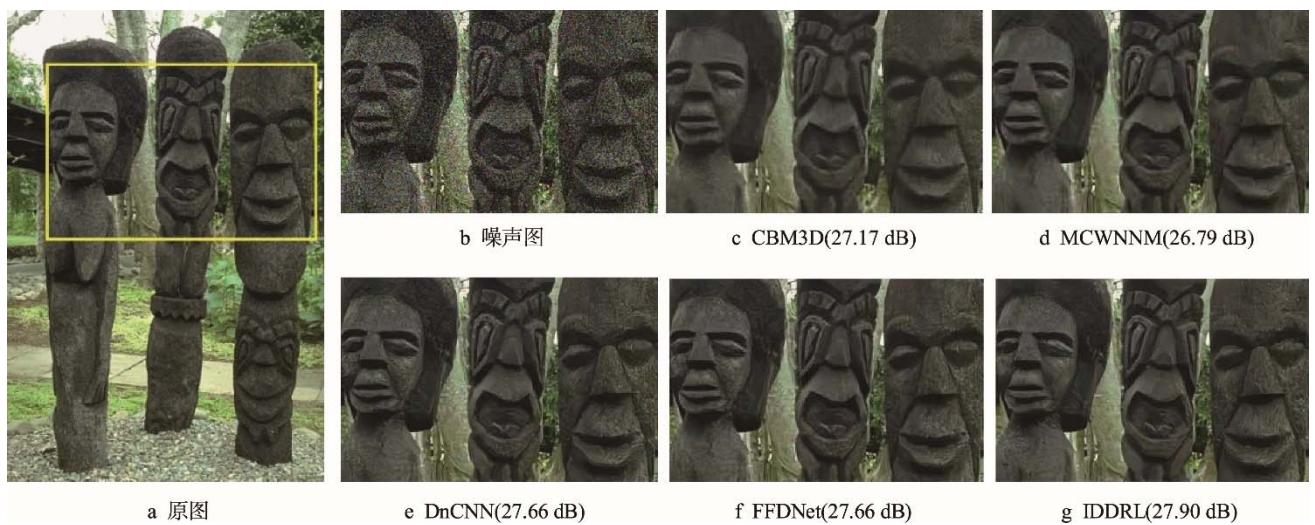


图 7 不同算法在  $\sigma=30$  时去噪结果比较  
Fig.7 Comparison of denoising results of different algorithms ( $\sigma=30$ )

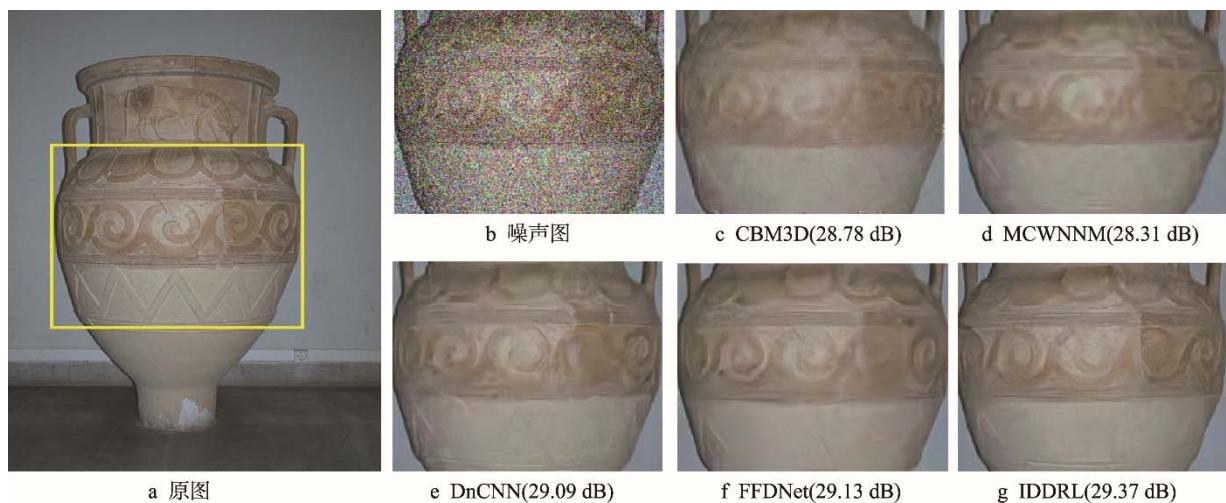


图 8 不同算法在  $\sigma=50$  时去噪结果比较  
Fig.8 Comparison of denoising results of different algorithms ( $\sigma=50$ )

为了更好地评价去噪结果,采用了主观打分。在每次测试中,随机选取 5 幅来自 Kodak24 测试集的图像和 5 幅来自 CBSD100 测试集的图像,同时显示这 4 种方法在噪声等级为 50 时的去噪结果,使用从 1~5 的分数来表示从低质量图像到高质量图像,邀请 20 名评估者对选取图像的去噪结果进行打分,并取其平均值得到最终的分数。主观打分 MOS 值见图 9。

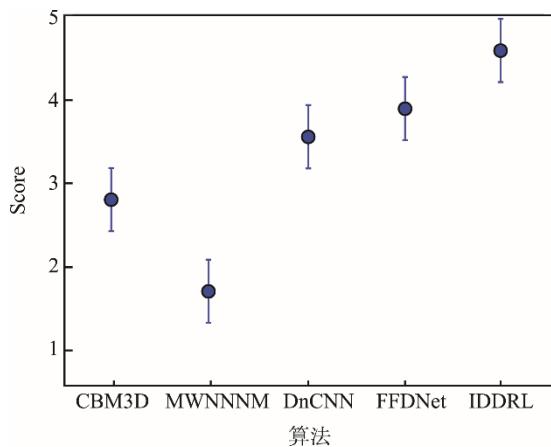


图 9 不同去噪方法的平均主观打分

Fig. 9 Mean subjective scores of different denoising methods

### 3 结语

文中提出一个基于深度残差学习的去噪方法,通过引入多个残差单元模块,并添加跳跃连接学习端到端的深度残差网络。训练了针对不同噪声等级的去噪模型,并分析了不同数量的残差单元模块及每个残差单元模块的不同层数对去噪效果的影响,实验表明随着层数及残差模块数在一定范围内增多,去噪效果越好。通过与其他去噪方法相比,不论从视觉上的主观评价,还是定量的客观评价,提出的方法能取得更佳的去噪效果,这为后续的图像分割及识别的研究奠定了基础。

### 参考文献:

- [1] 李传朋, 秦品乐, 张晋京. 基于深度卷积神经网络的图像去噪研究[J]. 计算机工程, 2017, 43(3): 1000—3428.  
LI Chuan-peng, QIN Pin-le, ZHANG Jin-jing. Research on Image Denoising Based on Deep Convolution Neural Network[J]. Computer Engineering, 2017, 43(3): 1000—3428.
- [2] BUADES A, COLL B, MOREL J M. A Non-Local Algorithm for Image Denoising[C]// Computer Vision and Recognition, 2005. IEEE Computer Society Conference on IEEE, 2005, 2: 60—65.
- [3] DABOV K, FOI A, KATKOVNIK V, et al. Image Denoising by Sparse 3-D Transform-Domain Collaborative Filtering[J]. IEEE Transactions on Image Processing, 2007, 16(8): 2080—2095.
- [4] WEISS Y, FREEMAN W T. What Makes a Good Model of Natural Images[C]// Conference on Computer Vision and Pattern Recognition, 2007: 1—8.
- [5] ELAD M, AHARON M. Image Denoising Via Sparse and Redundant Representations over Learned Dictionaries[J]. IEEE Transactions on Image Processing, 2006, 15(12): 3736—3745.
- [6] ROTH S, BLACK M J. Fields of Experts[J]. International Journal of Computer Vision, 2009, 82(2): 205—229.
- [7] DABOV K, FOI A, KATKOVNIK V, et al. Color Image Denoising Via Sparse 3D Collaborative Filtering with Grouping Constraint in Luminance-Chrominance Space [C]// IEEE International Conference on Image Processing, 2007, 1: 301—313.
- [8] XU J, ZHANG L, ZUO W, et al. Patch Group Based Nonlocal Self-Similarity Prior Learning for Image Denoising[C]// IEEE International Conference on Computer Vision & Image Processing, 2015: 244—252.
- [9] CHIERCHIA G, GHECHE M E, SCARPA G, et al. Multitemporal SAR Image Despeckling Based on Block-matching and Collaborative Filtering[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(10): 5467—5480.
- [10] HARMELING S, SCHULER C J, BURGER H C. Image Denoising: Can Plain Neural Networks Compete with BM3D? [C]// IEEE Conference on Computer Vision & Pattern Recognition, 2012: 2392—2399.
- [11] CHEN Y, POCK T. Trainable Nonlinear Reaction Diffusion: A Flexible Framework for Fast and Effective Image Restoration[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1256—1272.
- [12] JAIN V, SEUNG H S. Natural Image Denoising with Convolutional Networks[C]// International Conference on Neural Information Processing Systems. Curran Associates Inc. 2008: 769—776.
- [13] MAO X J, SHEN C, YANG Y B. Image Restoration Using Convolutional Auto-encoders with Symmetric Skip Connections[J]. 2016.
- [14] HE K, ZHANG X, REN S, et al. Deep Residual Learning for Image Recognition[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770—778.
- [15] ZHANG K, ZUO W, GU S, et al. Learning Deep CNN Denoiser Prior for Image Restoration[C]// IEEE Conference on Computer Vision and Pattern Recognition, 2017.

- [16] ZHANG K, ZUO W, CHEN Y, et al. Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising[J]. *IEEE Transactions on Image Processing*, 2017.
- [17] XU J, ZHANG L, ZHANG D. Multi-channel Weighted Nuclear Norm Minimization for Real Color Image Denoising[C]// *IEEE International Conference on Computer Vision*, 2017.
- [18] ZHANG K, ZUO W, ZHANG L, Ffdnet: Toward a Fast and Flexible Solution for CNN Based Image Denoising[J]. *IEEE Transactions on Image Processing*, 2018.
- [19] HE K M, ZHANG X Y, REN S Q, et al. Identity Mappings in Deep Residual Networks[C]// *Proceedings of the 14th European Conference on Computer Vision*. Amsterdam, The Netherlands: Springer, 2016: 630—645.
- [20] JIA Yang-qing, SHELHAMER. Caffe: Convolutional Architecture for Fast Feature Embedding, 2014: 675—678.
- [21] HE K, ZHANG X, REN S, et al. Delving Deep into Encoders: Surpassing Human-Level Performance on Imagenet Classification[J]. *Computing Research Repository*, 2015.