

# 结合降噪卷积神经网络和条件生成对抗网络的 图像双重盲降噪算法

井贝贝<sup>1</sup>, 郭嘉<sup>2</sup>, 王丽清<sup>1</sup>, 陈静<sup>1</sup>, 丁洪伟<sup>1\*</sup>

(1. 云南大学信息学院, 昆明 650500; 2. 云南省广播电视局科技处, 昆明 650000)

(\*通信作者电子邮箱 dhw1964@163.com)

**摘要:**针对图像降噪中降噪效果差、计算效率低的问题,提出了一种结合降噪卷积神经网络(DnCNN)和条件生成对抗网络(CGAN)的图像双重盲降噪算法。首先,使用改进的DnCNN模型作为CGAN的生成器来对加噪图片的噪声分布进行捕获;其次,将剔除噪声分布后的加噪图片和标签一同送入判别器进行降噪图像的判别;然后,利用判别结果对整个模型的隐层参数进行优化;最后,生成器和判别器在博弈中达到平衡,且生成器的残差捕获能力达到最优。实验结果表明,在Set12数据集上,当噪声水平分别为15、25、50时:所提算法与DnCNN算法相比,基于像素点间误差评价指标,其峰值信噪比(PSNR)值分别提升了1.388 dB、1.725 dB、1.639 dB;所提算法与三维块匹配(BM3D)、加权核范数最小化(WNNM)、DnCNN、收缩场级联(CSF)和一致性神经网络(CSNET)等现有算法相比,结构相似性(SSIM)评价指标值平均提升了0.000 2~0.104 1。实验结果验证了所提算法的优越性。

**关键词:**图像双重盲降噪;降噪卷积神经网络;条件生成对抗网络;生成器;判别器

中图分类号:TP391.41 文献标志码:A

## Image double blind denoising algorithm combining with denoising convolutional neural network and conditional generative adversarial net

JING Beibei<sup>1</sup>, GUO Jia<sup>2</sup>, WANG Liqing<sup>1</sup>, CHEN Jing<sup>1</sup>, DING Hongwei<sup>1\*</sup>

(1. School of Information Science and Engineering, Yunnan University, Kunming Yunnan 650500, China;

2. Technology Department, Yunnan Radio and Television Bureau, Kunming Yunnan 650000, China)

**Abstract:** In order to solve the problems of poor denoising effect and low computational efficiency in image denoising, a double blind denoising algorithm based on Denoising Convolutional Neural Network (DnCNN) and Conditional Generative Adversarial Net (CGAN) was proposed. Firstly, the improved DnCNN model was used as the CGAN generator to capture the noise distribution of the noisy image. Secondly, the noisy image after eliminating the noise distribution and the tag were sent to the discriminator to distinguish the noise reduction image. Thirdly, the results of discrimination were used to optimize the hidden layer parameters of the whole model. Finally, a balance between the generator and the discriminator was achieved in the game, and the generator's residual capture ability was optimal. Experimental results show that on Set12 dataset, when the noise levels are 15, 25, 50 respectively: compared with the DnCNN algorithm, the proposed algorithm has the Peak Signal-to-Noise Ratio (PSNR) increased by 1.388 dB, 1.725 dB and 1.639 dB respectively based on the error evaluation index between pixel points. Compared with the existing algorithms such as Block Matching 3D (BM3D), Weighted Nuclear Norm Minimization (WNNM), DnCNN, Cascade of Shrinkage Fields (CSF) and ConSensus neural NETwork (CSNET), the proposed algorithm has the index value of Structural SIMilarity (SSIM) improved by 0.000 2 to 0.104 1 on average based on the evaluation index of structural similarity. The above experimental results verify the superiority of the proposed algorithm.

**Key words:** image double blind denoising; Denoising Convolutional Neural Network (DnCNN); Conditional Generative Adversarial Net (CGAN); generator; discriminator

## 0 引言

图像去噪一直是计算机视觉领域的研究热点,在不断被提出的新算法的推进下该领域的研究得到了稳步发展。一般

而言,大多数的图像降噪模型都在降噪效果和计算效率之间取舍,如:文献[1-2]中的牺牲计算效率的马尔可夫随机场(Markov Random Field, MRF)模型,文献[3-4]中的非局部自相似(Non-local Self-Similarity, NSS)模型。为克服传统模型

收稿日期:2020-09-03;修回日期:2020-11-01;录用日期:2020-11-24。

基金项目:国家自然科学基金资助项目(61461053);云南大学服务云南行动计划项目(C176240501007)。

作者简介:井贝贝(1993—),男,河南洛阳人,硕士研究生,主要研究方向:图像处理、神经网络;郭嘉(1981—),男,云南昆明人,副教授,博士,主要研究方向:无线电通信;王丽清(1971—),女,云南昆明人,副研究员,博士,主要研究方向:智能信息处理、移动网络;陈静(1982—),女,云南昆明人,讲师,硕士,主要研究方向:机器学习、图像处理;丁洪伟(1964—),男,云南昆明人,教授,博士,主要研究方向:机器学习、图像处理。

的弊端,文献[5]提出了一种收缩场级联(Cascade of Shrinkage Fields, CSF)方法,使用的模型框架能够利用许多线性滤波器影响非线性函数,并且具有很高的并行性,该方法极大地提高了模型的计算效率。此外,文献[6]针对核范数极小化平均正则化所导致的自身受局限而提出的加权核范数最小化(Weighted Nuclear Norm Minimization, WNNM)算法要优于文献[7]的三维块匹配(Block Matching 3D, BM3D)算法。文献[8]中提出的去噪卷积神经网络(Denoising Convolutional Neural Network, DnCNN)模型,使用深度卷积的残差学习对图片进行盲降噪,克服了文献[5, 9-10]中TNRD(Trainable Nonlinear Reaction Diffusion)单一噪声水平下对应单一模型的缺点。

为了进一步提高图像降噪的性能,文献[11]中提出了多降噪器最优组合(Optimal Combination of Image Denoisers, OCID)模型,将两个或者三个经典降噪模型相组合来提升降噪效果,最终BM3D和DnCNN组合的降噪效果最为明显,但模型计算效率并不理想。文献[12]中则是结合平稳小波变换和卷积神经网络的优势,将图像进行尺度为1的平稳小波分解后把高、低频分量送入不同的残差网络中训练,测试阶段使用逆变换获得预测图像,且计算效率相较于文献[11]算法有所提高。文献[8]算法和文献[13]算法一样都是采用残差学习策略,不同的是文献[13]算法使用空洞卷积结构提取全局信息,并结合多尺度特征以恢复图像细节。文献[14-15]提出了一种较为新颖的降噪方法,均对图片进行分区处理,其中:文献[14]提出了一种新型降噪超分辨率的插值结构,将基于纹理特征的超分辨率算法和基于差异曲率的降噪算法相结合,能够将含噪图像分为平滑点区域、噪点区域及边缘点区域,然后实现对含噪图片的超分辨率;文献[15]中首先通过反向传播(Back Propagation, BP)神经网络预测并区分超声图像中的噪声区域和组织区域,然后与双边滤波器结合实现对超声图像的自适应滤波,不可避免的是文献[14-15]算法均存在计算效率低的缺点。文献[16]中提出了FFDNet(Fast and Flexible Network based on image Denoising)模型,虽能在少量无重复性结构上获得良好的降噪效果,但却要求降噪图像和训练所用的图像存在相似结构。文献[17]中则利用凸优化和神经网络技术将多个降噪器的降噪图像进行加权以提升降噪效果,但计算效率仍有待提高。

文献[11-17]方法虽然相较传统方法性能有一定程度的提高,但在计算效率和降噪效果权衡上仍有很大的提升空间,本文将改进的DnCNN模型作为条件生成对抗网络(Conditional Generative Adversarial Net, CGAN)的生成器,DnCNN中包括由卷积层(Conv)、批标准化(Batch Normalization, BN)和线性整流单元(Rectified Linear Unit, ReLU)组成的残差块,能够很好地捕获图像噪声分布。将加噪图片剔除生成器输出的噪声分布后与未加噪的干净图片通过判别器形成博弈,在博弈过程中隐层参数不断调整使得最终模型达到博弈平衡。实验结果表明,本文所提出的算法在DnCNN现有的优势上进一步提升了模型的降噪效果。

本文算法的特点有:1)将残差学习的DnCNN模型改进后和CGAN相结合,残差提取能力更强;2)采用将三个单一水平降噪模型并联组成盲降噪模型,泛化能力更强;3)具有较浅的模型深度(19层)并适用于GPU并行计算,计算效率更高。

## 1 相关工作

### 1.1 DnCNN 模型

深度学习被大量应用于图像降噪算法<sup>[18-21]</sup>。DnCNN模型是在修改VGG19(Visual Geometry Group network 19)的基础上通过调整卷积核为 $3 \times 3$ 并去掉所有的池化层获取的。该模型不再是简单地从加噪图像 $c = m + u$ 中学习映射函数 $F(c) = m$ ,而是通过将卷积、ReLU和BN层相结合不断对隐层参数训练得到 $R(c) = u$ 的映射,即从加噪的图片中学习噪声的分布,然后将学习到的噪声分布与真实噪声分布的均方误差(Mean Square Error, MSE)作为损失函数,类似于文献[18]提出的EPLL(Expected Patch Log Likelihood)和文献[6]中提出的WNNM噪声消除策略。DnCNN的模型架构如图1所示,损失函数如式(1)。

$$\text{loss}(\theta) = \frac{1}{2N} \sum_{i=1}^N \left\| R(y_i; \theta) - (y_i - x_i) \right\|_F^2 \quad (1)$$

式中: $x_i$ 和 $y_i$ 分别表示样本和加噪样本; $R(y_i; \theta)$ 表示学习到的噪声分布; $N$ 表示样本数; $\theta$ 表示需要训练的参数,后续使用自适应矩估计(Adaptive moment estimation, Adam)优化器进行优化。

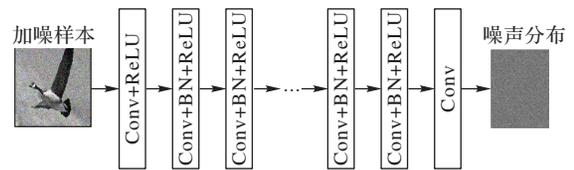


Fig. 1 DnCNN model architecture

### 1.2 CGAN

文献[22]中提出的生成对抗网络(Generative Adversarial Net, GAN)是由生成器和判别器两部分组成,生成器(Generator,  $G$ )利用噪声生成和样本尽可能相似的图像以骗过判别器(Discriminator,  $D$ )。 $D$ 通过对样本和生成图片的判别来不断提高判别的准确度,从而生成器和判别器形成博弈,如式(2)。文献[23]中所提的CGAN是在GAN的基础上改进而来,针对GAN不可控的缺点加入了监控条件 $s$ ,CGAN模型结构如图2所示,损失函数由式(2)变为式(3)。

$$\min_G \max_D V(D, G) = E_{x \sim p_{data}(x)} [\text{lb} D(x)] + E_{z \sim p_g(z)} [\text{lb}(1 - D(G(z)))] \quad (2)$$

$$\min_G \max_D V(D, G) = E_{x \sim p_{data}(x)} [\text{lb} D(x|s)] + E_{z \sim p_g(z)} [\text{lb}(1 - D(G(z|s)))] \quad (3)$$

$$D(G(x)) = \frac{P_{data}(x)}{P_{data}(x) + P_g(x)} \quad (4)$$

式中: $x$ 表示来自数据集的样本矩阵, $z$ 表示噪声矩阵; $G(z)$ 表示生成器生成的图片, $D(x)$ 和 $D(G(z))$ 分别表示对样本和生成图片判别后的真实概率; $s$ 表示监控条件。对于判别器而言, $D(x)$ 和 $D(G(z))$ 的期望值分别是1和0,然后把这个结果反馈给生成器和判别器,生成器通过调节隐藏层的参数使得 $D(G(z))$ 趋于1以骗过判别器,判别器则通过对隐层参数的调节来提高判别的准确率。在不断的博弈当中,生成器和判别器趋于平衡状态,最终判别器对于真实数据和生成数据的判别结果都接近0.5,此时目标函数式(4)得到最优解,式(3)在此基础上增加了监控条件 $s$ 。

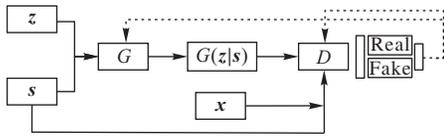


图2 CGAN模型架构

Fig. 2 CGAN model architecture

1.3 Dropout层抑制过拟合

过拟合问题是深度学习中经常遇到的问题。用于解决过拟合问题的Dropout层与传统的受限玻尔兹曼机(Restricted Boltzmann Machine, RBM)使用权重衰减策略不同,Dropout层是对每个隐含节点的权值设置一个服从Bernoulli分布的约束条件。如果约束条件被激活,则该节点以p概率被舍弃,以此使得模型权重稀疏化从而达到解决过拟合的目的。标准网络如图3所示,Dropout层的使用如图4所示,式(5)~(6)是增加Dropout层前后神经层传递数据方式的变化。

$$h_i^{(l+1)} = w_i^{(l+1)} k^{(l)} + b_i^{(l+1)} \quad \tilde{k}^{(l)} = r^l \times k^{(l)}$$

$$\tilde{h}_i^{(l+1)} = w_i^{(l+1)} \tilde{k}^{(l)} + b_i^{(l+1)} \quad (r_j^{(l)} \sim \text{Bernoulli}(p)) \quad (5)$$

$$k_i^{(l+1)} = \beta(h_i^{(l+1)}) \rightarrow \tilde{k}_i^{(l+1)} = \beta(\tilde{h}_i^{(l+1)}) \quad (6)$$

式中: $k^{(l)}$ 、 $r^l$ 、 $l$ 分别代表神经元的传递数据、Dropout的概率、层序数; $w_i^{(l)}$ 、 $b_i^{(l)}$ 、 $\beta$ 分别代表权值矩阵、偏置矩阵和激活函数。

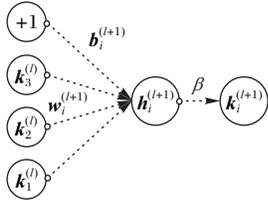


图3 标准网络

Fig. 3 Standard network

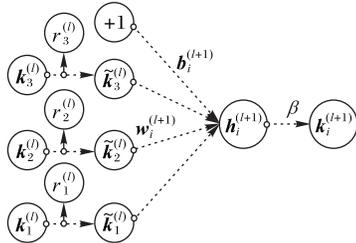


图4 Dropout层的使用

Fig. 4 Use of Dropout layer

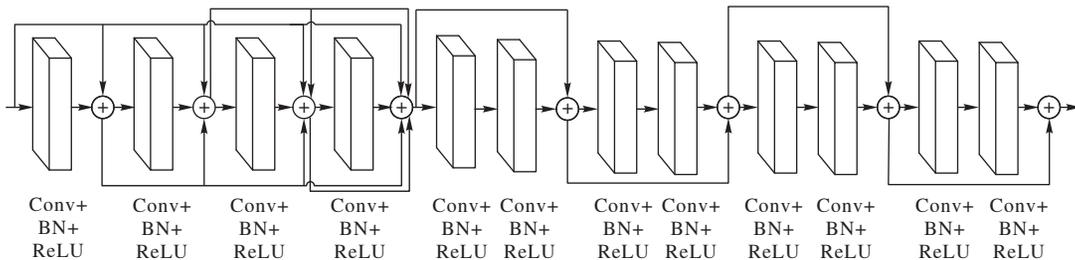


图5 生成器中IRDB结构

Fig. 5 IRDB structure in generator

由图6模型架构所示,首先将加噪样本 $y$ 喂入生成器,生成器捕获噪声分布 $R(y)$ ,然后以真实样本和 $y - R(y)$ 的MSE作为DnCNN损失,即生成器损失,计算式如式(7),值得注意的是本文并不是捕获图像分布 $R(y) = x$ ,而是捕获噪声分布 $R(y) = v$ 。模型损失是在经典GAN损失函数基础上改进而来

2 本文图像双重盲降噪算法

2.1 模型架构及损失函数设计

生成器依据DnCNN的特点,本文在VGG19的基础上移除了所有的池化层,并且将各层的卷积核设定为 $3 \times 3$ 。在第 $d$ 层的感受野是 $(2d + 1) \times (2d + 1)$ ,仍采用0填充的方式处理边界伪影。图像降噪中,随着模型深度的增加会出现计算效率低、过拟合、模型退化等问题。计算效率低可以通过并行GPU运算来解决;过拟合可以通过适当正则化、添加Dropout层解决;模型深度增加导致的模型退化的问题,也可以通过改变模型结构使用ResNet网络来解决。对于模型中单一层的输出并不能充分捕获图像特征的分布规律,本文改进并使用了文献[24]提出的改进残差密集块(Improved Residual Dense Block, IRDB),其作用是将浅层与深层的输出相叠加继续传递,这样就防止了浅层特征在传递过程中消失,进而提高了生成器捕获噪声分布的能力,生成器中IRDB结构如图5所示。判别器的设计相对比较简单,由两组连续的Conv层、BN层、LeakyReLU(Leaky ReLU)层、概率为0.5的Dropout层,外加Flatten、Dense层组成。对于贴片尺寸,本文模型在参考了文献[8]中根据不同的噪声水平和感受野设置样本贴片的大小,文献[8]通过实验给出了固定噪声水平( $\delta = 25$ )下几种降噪模型样本贴片的有效尺寸,并根据噪声水平和感受野设置输入模型贴片为 $40 \times 40$ , $\delta = 25$ 时不同模型的有效贴片尺寸如表1所示。EPLL与文献[8]模型感受野相近,其有效样本贴片为 $36 \times 36$ ,文献[8]模型的感受野为 $35 \times 35$ ,有效样本贴片为 $40 \times 40$ 。本文模型的噪声和文献[8]模型同为15、25、50三个水平,但本文模型的感受野略大于文献[8]模型的 $35 \times 35$ ,为 $39 \times 39$ ,故将样本贴片的有效尺寸设置为 $43 \times 43$ 。整个模型的结构如图6所示,图中DP表示Dropout层。

表1  $\delta = 25$ 时不同模型的有效贴片尺寸

Tab. 1 Effective patch sizes of different models when  $\delta = 25$

模型	贴片尺寸
BM3D <sup>[7]</sup>	49×49
CSF <sup>[5]</sup>	61×61
EPLL <sup>[18]</sup>	36×36
TNRD <sup>[10]</sup>	61×61
WNNM <sup>[6]</sup>	361×361
DnCNN <sup>[8]</sup>	40×40
本文模型	43×43

的,生成器求出生成器损失和生成器可训练参数之间的梯度,然后由生成器的优化器进行优化。判别器则根据对标签和生成输入的判别结果求出判别损失,优化过程和生成器类似,后将判别结果反馈给整个模型,使得模型参数得到优化,计算式如式(8),最终模型在博弈当中不断优化。

$$loss(\theta) = \frac{1}{2N} \sum_{i=1}^N \|x_i - (y_i - R(y_i))\|_2^2 \quad (7)$$

$$\min_G \max_D V(D, G) = E_{x \sim p_{data}(x)} [\text{lb} D(x|s)] + E_{y \sim p_g(y)} \{\text{lb}[1 - D((y - R(y)) | s)]\} \quad (8)$$

式中:  $x_i, x$  分别表示样本和样本矩阵;  $y_i, y$  分别表示加噪样本和加噪样本矩阵;  $R(y_i), R(y)$  分别表示捕获的噪声分布和捕获的噪声分布矩阵;  $s, v$  分别表示监控条件和噪声矩阵。通过式(7)~(8)的不断优化,生成器对噪声的捕获能力不断增强。

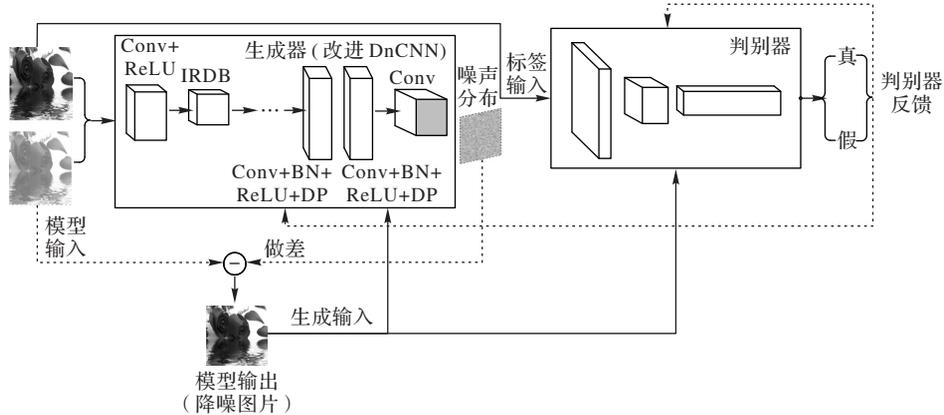


图 6 整个模型的架构

Fig. 6 Architecture of whole model

### 2.2 IRDB 有效性的论述

在生成器中最重要的结构是 IRDB, 这里对其起作用的原因进行解释。为方便讨论, 假设不使用任何激活函数, 且输入输出维度一致。从前向传播来看, 第  $l_2$  层残差块的输出由式(9)表示, 不难看出, 任意低层的特征可以直接映射到高层, 使得高层对于图像特征分布的捕获更加充分, 从而抑制了特征在传播的过程中退化。从反向传播来看, 最终的损失对某底层的梯度如式(10)所示, 表明反向传播的错误信号可以避开中间权重直接传播到低层, 这样就避免了梯度消失。

$$e^{(l_2)} = e^{(l_2-1)} + f(e^{(l_2-1)}) = e^{(l_2-2)} + f(e^{(l_2-2)}) + e^{(l_2-1)} = e^{(l_1)} + \sum_{i=l_1}^{l_2-1} f(e^{(i)}) \quad (9)$$

$$\frac{\partial \varepsilon}{\partial e^{(l_1)}} = \frac{\partial \varepsilon}{\partial e^{(l_1)}} + \frac{\partial \varepsilon}{\partial e^{(l_1)}} \sum_{i=l_1}^{l_2-1} f(e^{(i)}) \quad (10)$$

式中:  $l_i$  表示层序号;  $f$  表示残差函数(学习直接沿网络传播的映射);  $e^{(l)}$  表示第  $l$  残差块的输出矩阵;  $\varepsilon$  表示损失矩阵。

### 2.3 批量大小和学习率的选择

批量随机梯度下降(Stochastic Gradient Descent, SGD)的权重更新如式(11)~(12)所示, 从中不难看出权重的更新由学习率  $\eta$ 、批量大小  $n$ 、梯度  $\nabla loss(x, w_i)$  共同决定。

$$\nabla loss(x, w_i) = \frac{\partial loss(x, w_i)}{\partial w_i} \quad (11)$$

$$w_{i+1} = w_i - \frac{\eta}{n} \sum_{x \in \alpha} \nabla l(x, w_i) \quad (12)$$

式中:  $\nabla loss(x, w_i)$  表示某个样本的损失矩阵对于权重矩阵的梯度, 由该样本对权重求导而得;  $w_i$  表示权重矩阵;  $x$  表示样本矩阵;  $\eta$  表示学习率;  $n$  表示批量大小。

学习率直接决定着权重更新的步长, 它对模型的影响体现在初始学习率和学习率变换方案两个方面。初始学习率过大则会导致模型不收敛, 过小则会导致模型收敛慢甚至不收敛, 为此只有通过搜索法来确定最佳的学习率。针对学习率变换方案, 虽然文献[25-26]中证明经过调优的随机梯度下降(SGD)算法可能会取得更好的训练效果, 但学习率是一个特

别敏感的参数, 保守起见本文采用的是 Adam 调优策略, 给定初始学习率  $\eta$  为  $10^{-3}$ , 迭代步长为 5 200, 迭代率为 0.5, 即每迭代 5 200 步学习率降为原来的 1/2。文献[27]表明, 批量大小  $n$  对模型影响如图 7 所示, 在一定范围内增加  $n$  值会有助于提高模型的稳定性, 但是随着  $n$  值的继续增加模型性能会下降; 文献[28]表明, 小的  $n$  值携带的噪声有助于逃离 sharp minimum 从而达到 flat minimum, 后者具有更好的泛化能力, 批量大小  $n$  对极值的影响如图 8 所示; 文献[29]表明, 随着训练时间的增加, 大的  $n$  值仍会收敛到 flat minimum 点。由此可见, 在训练时间足够长的情况下增加  $n$  值会给模型性能带来良性影响, 基于显卡运算能力本文选用的  $n$  值为 128。具体参数设定如表 2 所示。

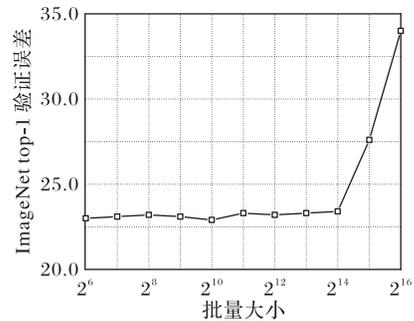


图 7 批量大小  $n$  对模型影响

Fig. 7 Impact of batch size  $n$  on model

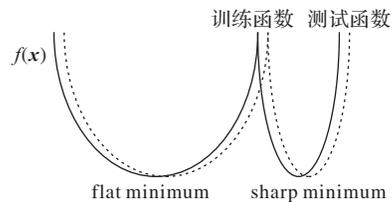


图 8 批量大小  $n$  对极值的影响

Fig. 8 Influence of batch size  $n$  on extremums

### 2.4 Dropout 层对模型的影响

DnCNN 模型的降噪原理和文献[5]的观点不同, 文献[5]

是基于  $F(y) = x$  的映射,而 DnCNN 则是基于  $R(y) = v$  的映射。为了控制变量,实验均是基于  $F(y) = x$  的映射,在分别使用 SGD 和 Adam 优化器情况下,观察模型损失。为验证 Dropout 层具有解决过拟合问题的能力,本文搭建了一个由一个 Flatten 层加一个 Dense 层,外加一个概率为 0.4 的 Dropout 层,最后再加一个 Dense 层组成的模型来验证。该模型除最后一层的激活函数为 Softmax 外其他激活函数均为 ReLU,输入图片大小为  $28 \times 28$ 。

Adam 优化器和 SGD 优化器下的模型损失分别如图 9~10 所示。由图 9~10 可以看出,随着迭代次数的增加,带 Dropout 层的损失在不断下降,而无 Dropout 层的损失在第 7 次迭代时趋于分离,即训练损失在下降,真实损失却在上升,模型的泛化能力不再提升,出现过拟合,在 Adam 优化器下更加明显,从而表明 Dropout 层能够有效解决过拟合问题的能力。

表 2 部分超参数设定

Tab. 2 Partial hyperparameter setting

参数	值
初始学习率 $\eta$	$10^{-3}$
批量大小 $n$	128
迭代步长	5 200
迭代率	0.5

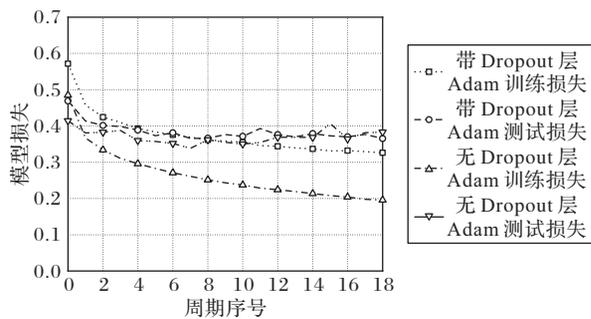


图 9 Adam 优化器下的模型损失

Fig. 9 Model loss under Adam optimizer

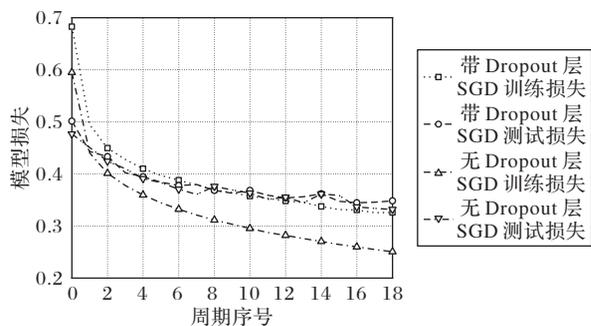


图 10 SGD 优化器下的模型损失

Fig. 10 Model loss under SGD optimizer

### 3 实验与结果分析

本文训练模型所采用的两个优化器均是 Adam,初始学习效率为  $10^{-3}$ ,迭代周期为 1 200。本文训练的模型采用的噪声水平分别是 15、25、50,改进后的 DnCNN 模型作为生成器输入的图片采用  $43 \times 43$  的样本贴片,模型深度降为 19 层,其中:0 层采用 Conv 加 ReLU 结构;1~11 层为 IRDB 结构;12~18 层均是由 Conv、BN 和激活函数 ReLU 所组成,为防止模型过拟合,第 16、17 层的激活函数后添加了概率为 0.5 的 Dropout 层(一

般加在深卷积层后,因为此时参数较多更容易产生过拟合),均采用  $3 \times 3$  的卷积核,卷积核数均为 64,采用残差学习策略。判别器的设计和模型架构中的描述一致。

实验所用到的操作系统为 Windows 10,CPU 为 intel 酷睿 i7-9700k, GPU 为 RTX2080TI。训练模型环境为 tensorflow2.0,python3.7。本文中所使用的激活函数(ReLU 和 LeakyReLU)均为默认参数。在训练单一模型阶段采用的图像质量评价指标和 DnCNN 一样都是峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)(单位为 dB),PSNR 是基于像素误差对图像进行评估,其值越高表示去噪质量越好。PSNR 计算公式如下:

$$PSNR = 10 \lg \left( \frac{(2^n - 1)^2}{MSE} \right) \quad (13)$$

$$MSE = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W (X(i,j) - Y(i,j))^2 \quad (14)$$

式中: $H$ 、 $W$ 表示图片长宽; $X(i,j)$ 、 $Y(i,j)$ 表示两张图片的像素点;其余均为常数。

#### 3.1 $\delta=15, \delta=25, \delta=50$ 下不同算法降噪效果

为了验证本文算法的降噪效果,分别选用 BM3D、CSF、DnCNN-B、DnCNN-S、EPLL、TNRD、WNNM 等七种算法进行对比实验,使用的数据集是 Set12。通过视觉效果和评价指标 PSNR 两个方面来比较各个算法的降噪效果。在噪声水平  $\delta$  分别为 15、25、50 时,数据集中各图片通过降噪后的 PSNR 值如表 3 所示,最优的 PSNR 值已作加粗处理。通过表 3 对比可知,在  $\delta=15, 25, 50$  下,本文算法的 PSNR 相较原来的 DnCNN 算法平均提高了 1.388 dB、1.725 dB、1.639 dB。文献[30-31]研究表明,降噪水平优于 BM3D 达到 0.3 dB 的算法是很难实现的,然而本文算法在三个降噪水平上不仅优于 BM3D 算法,也优于 DnCNN。虽然本文算法在 Peppers、Parrot、Starfish 三张图片上 PSNR 值小于 DnCNN 算法,但就整个数据集而言,本文算法的降噪水平还是优于 DnCNN。 $\delta = 15$  时不同算法降噪效果如图 11 所示。

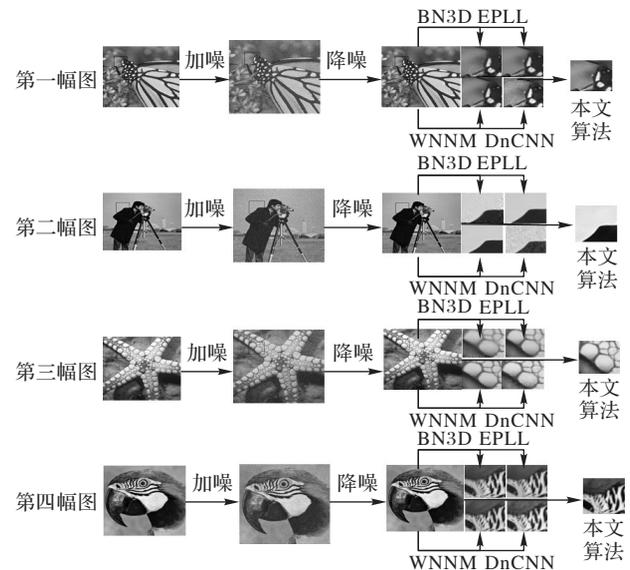


图 11  $\delta = 15$  时不同算法降噪效果

Fig. 11 Denoising effects of different algorithms when  $\delta = 15$

由图 11 可以明显看出, BM3D 和 DnCNN 算法在第一幅和第二幅图像上出现明显的模糊; WNNM 在边缘区域会出现明显的块状,这一点在第二幅图片上较为明显。综上,用于对比的四种算法在边缘细节处理上都有明显的模糊,而本文算法

在边缘特征和纹理上相较对比算法都有所改善。本文对比的数据参考了文献[8]中的实验结果。

表3  $\delta = 15, 25, 50$  时不同算法的 PSNR  
Tab. 3 PSNR of different algorithms when  $\delta = 15, 25, 50$

单位: dB  
unit: dB

$\delta$	算法	图片												平均值
		Airpl	Barbara	Boat	C. man	Couple	House	Lena	Monar	Man	Peppers	Parrot	Starfish	
15	BM3D <sup>[7]</sup>	31.07	33.10	32.13	31.91	32.10	34.93	34.26	31.85	31.92	32.69	31.37	31.14	32.372
	CSF <sup>[5]</sup>	31.33	31.92	32.01	31.95	31.98	34.39	34.06	32.33	32.08	32.85	31.37	31.55	32.318
	DnCNN-S <sup>[8]</sup>	31.70	32.64	32.42	32.61	32.47	34.97	34.62	33.09	32.46	<b>33.30</b>	<b>31.83</b>	<b>32.20</b>	32.859
	DnCNN-B <sup>[8]</sup>	31.56	32.09	32.35	32.10	32.41	34.93	34.56	32.94	32.41	33.15	31.63	32.02	32.680
	EPLL <sup>[18]</sup>	31.19	31.38	31.93	31.85	31.93	34.17	33.92	32.10	32.00	32.64	31.42	31.13	32.138
	TNRD <sup>[10]</sup>	31.46	32.13	32.14	32.19	32.11	34.53	34.24	32.56	32.23	33.04	31.63	31.75	32.502
	WNNM <sup>[6]</sup>	31.39	<b>33.60</b>	32.27	32.17	32.17	35.13	34.27	32.71	32.11	32.99	31.62	31.82	32.696
	本文算法	<b>33.89</b>	<b>33.52</b>	<b>34.91</b>	<b>37.39</b>	<b>32.57</b>	<b>38.04</b>	<b>36.37</b>	<b>35.03</b>	<b>34.47</b>	31.84	30.24	30.74	<b>34.084</b>
25	BM3D <sup>[7]</sup>	28.42	30.71	29.90	29.45	29.71	32.85	32.07	29.25	29.61	30.16	28.93	28.56	29.969
	CSF <sup>[5]</sup>	28.72	29.03	29.76	29.48	29.53	32.39	31.79	29.62	29.71	30.32	28.90	28.80	29.837
	DnCNN-S <sup>[8]</sup>	29.13	30.00	30.21	30.18	30.12	33.06	32.44	30.28	30.10	<b>30.87</b>	<b>29.43</b>	<b>29.41</b>	30.436
	DnCNN-B <sup>[8]</sup>	29.09	29.69	30.20	29.94	30.10	33.05	32.42	30.25	30.09	30.84	29.35	29.34	30.362
	EPLL <sup>[18]</sup>	28.61	28.61	29.74	29.26	29.53	32.17	31.73	29.39	29.66	30.17	28.95	28.51	29.692
	TNRD <sup>[10]</sup>	28.88	29.41	29.91	29.72	29.71	32.53	32.00	29.85	29.87	30.57	29.18	29.02	30.055
	WNNM <sup>[6]</sup>	28.69	<b>31.24</b>	30.03	29.64	29.82	33.22	32.24	29.84	29.76	30.42	29.15	29.03	30.257
	本文算法	<b>32.00</b>	30.92	<b>33.95</b>	<b>36.15</b>	<b>30.72</b>	<b>36.01</b>	<b>34.40</b>	<b>32.62</b>	<b>32.01</b>	29.03	27.86	28.12	<b>31.982</b>
50	BM3D <sup>[7]</sup>	25.10	27.22	26.78	26.13	26.46	29.69	29.05	25.82	26.81	26.68	25.90	25.04	26.722
	DnCNN-S <sup>[8]</sup>	25.87	26.22	27.20	27.03	26.90	30.00	29.39	26.78	27.24	27.32	<b>26.48</b>	25.70	27.178
	DnCNN-B <sup>[8]</sup>	25.89	26.38	27.23	27.03	26.91	30.02	29.38	26.83	27.23	<b>27.39</b>	<b>26.48</b>	<b>25.72</b>	27.206
	EPLL <sup>[18]</sup>	25.31	24.83	26.74	26.10	26.30	29.12	28.68	25.94	26.79	26.80	25.95	25.12	26.471
	TNRD <sup>[10]</sup>	25.59	25.70	26.94	26.62	26.50	29.48	28.93	26.31	26.98	27.10	26.16	25.42	26.812
	WNNM <sup>[6]</sup>	25.42	<b>27.79</b>	26.97	26.45	26.64	30.33	29.25	26.32	26.94	26.95	26.14	25.44	27.052
	本文算法	<b>28.57</b>	26.46	<b>32.03</b>	<b>33.02</b>	<b>27.59</b>	<b>31.98</b>	<b>32.08</b>	<b>29.08</b>	<b>29.05</b>	25.59	24.56	24.29	<b>28.691</b>

3.2 盲降噪模型的构成和评估

为得到盲降噪模型,本文训练了  $\delta = 15, 25, 50$  等三个模型。不同模型下的降噪效果如图 12 所示,随着噪声水平的增加,模型的降噪效果递减,在较低噪声水平下模型的降噪效果明显,且在  $\delta = 50$  时 PSNR 值稳定在 30 dB 左右。基于上述实验结果,本文将三个单一水平降噪模型并连成一个盲降噪模型,加噪图片输入模型后由三个子模型并行处理,然后比较各个子模型输出的图像衡量指标 EAV 值<sup>[32]</sup>,最终取其最大值所对应的降噪图像为模型输出,盲降噪模型结构如图 13 所示,图中  $\frac{df}{dx}$  为边缘法向的灰度变化率,  $M \times N$  表示图片大小。为进一步验证本文模型的降噪效果,引入了结构相似性 (Structural SIMilarity index, SSIM), 计算式如式 (15):

$$SSIM = \frac{2\mu_X\mu_Y + C_1}{\mu_X^2 + \mu_Y^2 + C_1} \cdot \frac{2\phi_X\phi_Y + C_2}{\phi_X^2\phi_Y^2 + C_2} \cdot \frac{\phi_{XY} + C_3}{\phi_X\phi_Y + C_3} \quad (15)$$

式中:  $\mu_X, \mu_Y, \phi_X, \phi_Y$  及  $\phi_{XY}$  分别表示  $X, Y$  的均值、方差及  $X, Y$  的协方差; 其余均为常数。

SSIM 是一种从亮度、对比度和结构上进行对比的全参考图像质量评价指标,能够准确评估两幅图片纹理和边缘的相似度。在噪声水平分别为 20、30、40、50 下比较 BM3D、WNNM、DnCNN、FFDNET、一致性神经网络 (ConSensus neural NETwork, CSNET) 这五种算法与本文算法的 PSNR 和 SSIM 值,具体结果如表 4 所示。从表 4 中不难看出,本文算法在降噪效果上更优,表明本文算法的性能优于目前的其他主流降噪算法,虽然在噪声水平为 40 时,本文算法性能略差于 FFDNET,但是总体而言本文算法在结构 (纹理和边缘) 上的

降噪效果更明显。

不同算法处理图像的用时比较如表 5 表示。从表 5 中可看出,本文算法的执行时间与文献 [8] 算法相当。

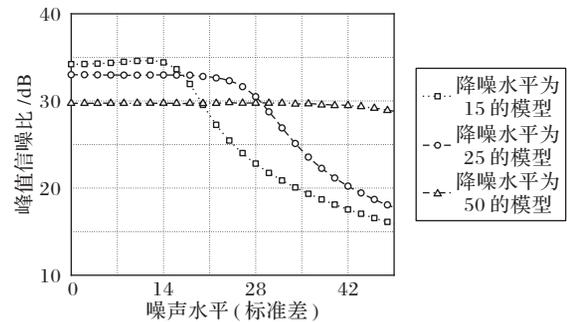


图 12 不同模型下的降噪效果

Fig. 12 Denoising effect under different models

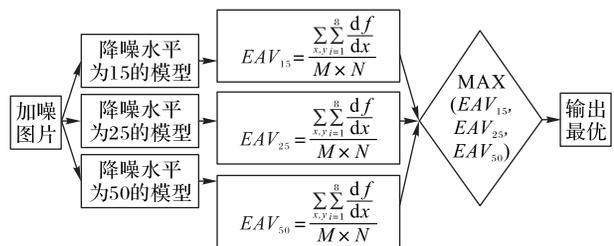


图 13 盲降噪模型结构

Fig. 13 Blind denoising model structure

本文算法对遥感图片的降噪结果如图 14 所示,是盲降噪模型对遥感图片在一定噪声水平下的降噪结果。从图 14 可以看出,三幅图片的边缘,特别是第一幅河道边缘和第三幅的

建筑边缘出现不同程度的模糊,表明本文算法在一些需要超分辨率技术恢复的图像上降噪性能仍有所不足。

表4 不同算法在Lena图像上的PSNR和SSIM值

Tab. 4 PSNR and SSIM values of different algorithms on Lena image

算法	$\sigma = 20$		$\sigma = 30$		$\sigma = 40$		$\sigma = 50$		平均值	
	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM
BM3D <sup>[7]</sup>	33.43	0.9001	31.40	0.8666	30.05	0.8369	29.12	0.8193	31.00	0.8557
WNNM <sup>[6]</sup>	33.29	0.9002	31.62	0.8712	30.25	0.8420	29.37	0.8266	31.13	0.8599
DnCNN <sup>[8]</sup>	33.67	0.9026	31.78	0.8774	30.47	0.8537	29.51	0.8341	31.35	0.8669
FFDNET <sup>[16]</sup>	33.81	0.9102	32.05	0.8851	<b>30.80</b>	<b>0.8643</b>	29.82	0.8459	<b>31.62</b>	0.8763
CSNET <sup>[20]</sup>	30.74	0.8429	29.14	0.7941	28.14	0.7556	27.19	0.7235	28.80	0.7790
本文算法	<b>34.14</b>	<b>0.9133</b>	<b>32.12</b>	<b>0.9035</b>	30.33	0.8497	<b>29.91</b>	<b>0.8467</b>	<b>31.62</b>	<b>0.8783</b>

表5 不同算法的执行时间对比 单位:s

Tab. 5 Comparison of execution time of different algorithms unit:s

算法	耗时	算法	耗时
WNNM <sup>[6]</sup>	240.56	DnCNN-S <sup>[8]</sup>	<b>0.01</b>
EPLL <sup>[18]</sup>	53.53	本文算法	<b>0.01</b>
DnCNN-B <sup>[8]</sup>	0.02		

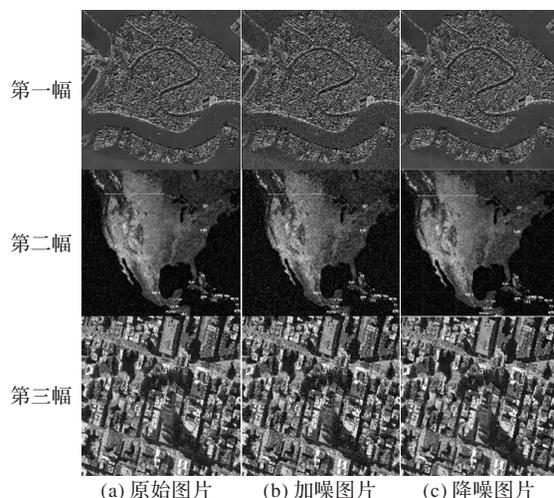


图14 本文算法对遥感图片的降噪结果

Fig. 14 Denoising results of proposed algorithm on remote sensing images

## 4 结语

本文将DnCNN、IRBD、GAN相结合提出了一种新的降噪算法。该算法克服了传统算法计算效率低、单一水平降噪等缺点,改善了图像降噪质量。实验结果表明,本文所提算法的降噪效果相较于DnCNN模型无论在图片纹理的处理效果还是PSNR值上都有了较高的提升。此外,本文算法还具有盲降噪和降噪速度快等特点。针对高噪声水平下的图片降噪,本文算法的降噪效果虽然有所提升,但仍有降噪性能不足的问题。下一步研究将继续对本文算法进行改进,将超分辨率技术用于一般图像的降噪,使之在高水平噪声降噪的研究上能取得进一步突破。

### 参考文献 (References)

- [1] LI S Z. Markov Random Field Modeling in Image Analysis [M]. London: Springer, 2009:49-86.
- [2] ROTH S, BLACK M J. Fields of experts [J]. International Journal of Computer Vision, 2009, 82(2): Article No. 205.
- [3] MAIRAL J, BACH F, PONCE J, et al. Non-local sparse models for image restoration [C]// Proceedings of the IEEE 12th International Conference on Computer Vision. Piscataway: IEEE, 2009: 2272-2279.
- [4] XU J, ZHANG L, ZUO W, et al. Patch group based nonlocal self-similarity prior learning for image denoising [C]// Proceedings of the 2015 IEEE International Conference on Computer Vision. Piscataway: IEEE, 2015:244-252.
- [5] SCHMIDT U, ROTH S. Shrinkage fields for effective image restoration [C]// Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2014: 2774-2781.
- [6] GU S, ZHANG L, ZUO W, et al. Weighted nuclear norm minimization with application to image denoising [C]// Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2014: 2862-2869.
- [7] 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.
- [8] 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, 26(7): 3142-3155.
- [9] CHEN Y, YU W, POCK T, et al. On learning optimized reaction diffusion processes for effective image restoration [C]// Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2015: 5261-5269.
- [10] CHEN Y, POCK T. Trainable nonlinear reaction diffusion: a flexible framework for fast and effective image restoration [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1256-1272.
- [11] 徐少平,林珍玉,陈孝国,等. 采用多通道浅层CNN网络构建的多降噪器最优组合模型[J/OL]. 自动化学报: 1-16. [2020-08-12]. <https://doi.org/10.16383/j.aas.c190736>. (XU S P, LIN Z Y, CHEN X G, et al. Optimal combination model of multiple denoisers constructed by multi-channel shallow CNN network [J/OL]. Acta Automatica Sinica: 1-16. [2020-08-12]. <https://doi.org/10.16383/j.aas.c190736>.)
- [12] 陈清江,石小涵,柴昱洲. 基于小波变换与卷积神经网络的图像去噪算法[J]. 应用光学, 2020, 41(2): 288-295. (CHEN Q J, SHI X H, CHAI Y Z. Image denoising algorithm based on wavelet transform and convolutional neural network [J]. Journal of Applied Optics, 2020, 41(2): 288-295.)
- [13] 潘凯,侯亮. 基于卷积神经网络的遥感图像降噪[J]. 现代信息技术, 2020, 4(12): 60-65. (PAN K, HOU L. Denoise of remote sensing image based on convolutional neural network [J]. Modern Information Technology, 2020, 4(12):60-65.)
- [14] 杨飘. 基于区域分析的图像超分辨与降噪技术研究[D]. 成都:电子科技大学, 2020: 13-64. (YANG P. Research on image

- super-resolution and noise reduction technology based on area analysis [D]. Chengdu: University of Electronic Science and Technology of China, 2020: 13-64. )
- [15] 朱小方, 净亮, 邵党国. 基于反向传播神经网络的自适应双边滤波的超声图像降噪[J]. 激光与光电子学进展, 2020, 57(24): 163-172. (ZHU X F, JING L, SHAO D G. Ultrasonic image denoising using adaptive bilateral filtering based on back propagation neural network [J]. Laser and Optoelectronics Progress, 2020, 57(24): 163-172. )
- [16] 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, 27(9):4608-4622.
- [17] CHOI J H, OMAR A. Optimal combination of image denoisers [J]. IEEE Transactions on Image Processing, 2019, 28(8):4016-4031
- [18] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [C]// Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2015: 1-9.
- [19] HEGAZY M A A, CHO M H, LEE S Y. Image denoising by transfer learning of generative adversarial network for dental CT [J]. Biomedical Physics and Engineering Express, 2020, 6(5): Article No. 055024.
- [20] RADOSLAY L. CSNET [J]. Proceedings of FPCA, 2012, 7(7): 429-462.
- [21] 马红强, 马时平, 许悦雷, 等. 基于改进栈式稀疏去噪自编码器的自适应图像去噪[J]. 光学学报, 2018, 38(10):120-127. (MA H Q, MA S P, XU Y L, et al. Adaptive image denoising based on improved stacked sparse denoising auto-encoder [J]. Acta Optica Sinica, 2018, 38(10): 120-127. )
- [22] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets [C]// Proceedings of the 2014 27th International Conference on Neural Information Processing Systems. Cambridge: MIT Press, 2014:2672-2680.
- [23] GAUTHIER J. Conditional generative adversarial nets for convolutional face generation [EB/OL]. [2020-08-25]. <http://www.foldl.me/uploads/papers/tr-cgans.pdf>.
- [24] 郭恒意, 贾振堂. 结合残差密集块的卷积神经网络图像去噪方法[J]. 计算机工程与设计, 2020, 41(7): 1998-2003. (GUO H Y, JIA Z T. Convolutional neural network image denoising method combined with dense residual block [J]. Computer Engineering and Design, 2020, 41(7): 1998-2003. )
- [25] REDDI S J, KALE S, KUMAR S, et al. On the convergence of Adam and beyond [EB/OL]. [2020-08-25]. <https://arxiv.org/pdf/1904.09237.pdf>.
- [26] LUO L, XIONG Y, LIU Y, et al. Adaptive gradient methods with dynamic bound of learning rate [EB/OL]. [2020-08-25]. <https://arxiv.org/pdf/1902.09843.pdf>.
- [27] GOYAL P, DOLLÁR P, GIRSHICK R, et al. Accurate, large minibatch SGD: training ImageNet in 1 hour [EB/OL]. [2020-08-26]. <https://arxiv.org/pdf/1706.02677.pdf>.
- [28] KESKAR N S, MUDIGERE D, NOCEDAL J, et al. On large-batch training for deep learning: generalization gap and sharp minima [EB/OL]. [2020-08-26]. <https://arxiv.org/pdf/1609.04836.pdf>.
- [29] HOFFER E, HUBARA I, SOUDRY D. Train longer, generalize better: closing the generalization gap in large batch training of neural networks [C]// Proceedings of the 2017 31st International Conference on Neural Information Processing. Red Hook: Curran Associates Inc., 2017: 1729-1739.
- [30] LEVIN A, NADLER B. Natural image denoising: optimality and inherent bounds [C]// Proceedings of the 2011 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2011: 2833-2840.
- [31] LEVIN A, NADLER B, DURAND F, et al. Patch complexity, finite pixel correlations and optimal denoising [C]// Proceedings of the 2012 12th European Conference on Computer Vision, LNCS 7576. Berlin: Springer, 2012: 73-86.
- [32] 王鸿南, 钟文, 汪静, 等. 图像清晰度评价方法研究[J]. 中国图象图形学报, 2004, 9(7): 828-831. (WANG H N, ZHONG W, WANG J, et al. Research of measurement for digital image definition [J]. Journal of Image and Graphics, 2004, 9(7): 828-831. )

This work is partially supported by the National Natural Science Foundation of China (61461053), the Yunnan University Servicing Yunnan Action Program (C176240501007).

**JING Beibei**, born in 1993, M. S. candidate. His research interests include image processing, neural network.

**GUO Jia**, born in 1981, Ph. D., associate professor. His research interests include radio communication.

**WANG Liqing**, born in 1971, Ph. D., associate research fellow. Her research interests include intelligent information processing, mobile network.

**CHEN Jing**, born in 1982, M. S., lecturer. Her research interests include machine learning, image processing.

**DING Hongwei**, born in 1964, Ph. D., professor. His research interests include machine learning, image processing.