

基于通道注意递归残差网络的图像超分辨率重建



郭琳^{1,2,3} 李晨¹ 陈晨¹ 赵睿¹ 范仕霖¹ 徐星雨¹

1 湖北大学计算机与信息工程学院 武汉 430062

2 智慧政务与人工智能应用湖北省工程研究中心 武汉 430062

3 湖北省教育信息化工程技术研究中心 武汉 430062

摘要 近年来,深度学习被广泛应用于图像超分辨率重建。针对基于深度学习的超分辨率重建方法存在的特征提取不充分、细节丢失和梯度消失等问题,提出一种基于通道注意的递归残差深度神经网络模型,用于单幅图像的超分辨率重建。该模型采用残差嵌套网络和跳跃连接构成一种简洁的递归残差网络结构,能够加快深层网络的收敛,同时避免网络退化和梯度问题。在特征提取部分,引入注意力机制来提升网络的判别性学习能力,以提取到更准确、有效的深层残差特征;随后结合并行映射重建网络,最终实现超分辨率重建。在数据集 Set5,Set14,B100 和 Urban100 上进行放大 2 倍、3 倍和 4 倍的重建测试实验,并从客观指标和主观视觉效果上将所提方法与主流方法进行比较。实验结果显示,所提方法在全部 4 个测试数据集上的客观指标对比方法均有明显提升,其中,相比插值法和 SRCNN 算法,在放大 2 倍、3 倍、4 倍时所提方法的平均 PSNR 值分别提升了 3.965 dB 和 1.56 dB、3.19dB 和 1.42 dB、2.79 dB 和 1.32 dB。视觉效果对比也表明所提方法能更好地恢复图像细节。

关键词: 超分辨率;深度学习;通道注意;残差网络;跳跃连接

中图分类号 TP391

Image Super-resolution Reconstruction Using Recursive Residual Network Based on Channel Attention

GUO Lin^{1,2,3}, LI Chen¹, CHEN Chen¹, ZHAO Rui¹, FAN Shi-lin¹ and XU Xing-yu¹

1 School of Computer Science and Information Engineering, Hubei University, Wuhan 430062, China

2 Hubei Provincial Engineering Research Center for Smart Government Affairs and Artificial Intelligence Application, Wuhan 430062, China

3 Research Center of Educational Informatization Engineering and Technology, Hubei Province, Wuhan 430062, China

Abstract In recent years, deep learning has been widely used in image super-resolution reconstruction. To solve the problems of inadequate feature extraction, loss of details and gradient disappearance in super-resolution reconstruction methods based on deep learning, a deep recursive residual neural network model based on channel attention is proposed for single image super-resolution reconstruction. The proposed model constructs a simple recursive residual network structure by residual nested networks and jump connections to deepen the network and speed up its convergence while avoiding network degradation and gradient problems. An attention mechanism is introduced into the feature extraction part to improve the discriminant learning ability of the network for more accurate and more effective extraction of deep residual features, which is combined with the subsequent reconstruction network with parallel mapping structure to ensure the final accurate reconstruction. Quantitative and qualitative assessments are performed on benchmark dataset Set5, Set14, B100 and Urban100 at the magnification of 2, 3 and 4 times by comparison with the mainstream methods. Experimental results show that the objective index values of the proposed method increase significantly compared to the comparative methods on all four test data sets. Among them, compared with the interpolation method and the SRCNN algorithm, the average PSNR improves 3.965dB and 1.56 dB, 3.19dB and 1.42dB, 2.79dB and 1.32dB, respectively, at the magnification of 2, 3 and 4 times. Visual effects show that the proposed method can recover image details better.

Keywords Super-resolution, Deep learning, Channel attention, Residual network, Skip connections

1 引言

单幅图像超分辨率 (Single Image Super-Resolution,

SISR) 重建是指从单幅退化的低分辨率 (Low Resolution, LR) 图像中恢复出一幅具有更高质量的高分辨率 (High Resolution, HR) 图像, 其在城市安防、卫星遥感、医学图像等众多领

到稿日期:2020-05-28 返修日期:2020-09-17 本文已加入开放科学计划(OSID), 请扫描上方二维码获取补充信息。

基金项目:国家自然科学基金(61806076);湖北省自然科学基金项目(2018CFB158)

This work was supported by the National Natural Science Foundation of China(61806076) and Hubei Provincial Natural Science Foundation of China(2018CFB158).

通信作者:郭琳(guolin@hubu.edu.cn)

域有着重要应用价值。图像超分辨率重建方法可以分为基于插值的方法^[1]、基于重建的方法^[2]和基于学习的方法^[3-7]。基于插值的方法利用周边的像素信息对高分辨率图像进行估计,重建速度比较快。但利用此类方法重建的图像过于平滑,且图像边缘会产生锯齿效应^[8]。基于重建的方法首先对引起图像退化的因素进行分析和建模,然后利用图像的先验信息对重建过程进行约束,重建效果比插值法好。但该方法十分依赖于高分辨率图像的先验知识,若图像较为复杂,重建倍数较大,则重建效果会受到严重影响。基于学习的方法是通过训练样本得到高、低分辨率图像间的映射关系,从而估计高分辨率图像,重建效果要优于传统方法。

Dong 等最早将深度学习用于图像超分辨率重建,提出了 SRCNN(Super-Resolution Convolutional Neural Network)^[9]方法。该方法采用 3 层结构的卷积神经网络(Convolutional Neural Networks, CNN)学习 LR 图像和 HR 图像之间的映射关系,3 层网络分别对应于特征提取、非线性映射和重建网络。SRCNN 的优点是网络结构简单,与插值法、稀疏编码等方法相比,性能更优,但其缺点是训练时收敛太慢。随后,为了提高训练速度,Dong 等又提出了 FSRCNN^[10]方法。该方法直接输入原始的低分辨率图像,并在网络最后使用反卷积层放大图像尺寸,加快了训练速度而且提升了性能。由于深层网络模型在图像分类问题上取得很大的突破,受此启发, Kim 等提出了深度卷积神经网络模型 VDSR^[11]和深度递归神经网络模型 DRCN^[12]。VDSR 采用 20 层卷积网络,仅对 LR 图像和 HR 图像的残差进行学习,在加快收敛的同时提高了重建质量。DRCN 则是将深度卷积神经网络设计成递归结构,大幅减少了卷积层的网络参数,而且递归结构加深了卷积层深度,从而使网络性能相比 VDSR 有所提高。Lai 等提出的 LapSRN^[13]方法构建了一个拉普拉斯多层金字塔结构,直接从低分辨率图像由底层逐级预测残差,最终重建 HR 图像。该方法在减少计算量的同时,进一步提高了重建质量。

为了提高超分辨率重建的性能,本文设计了一种利用通道注意力机制的残差递归深度神经网络模型。本文方法有 3 个特点:1)引入通道注意力(Channel Attention, CA)机制,使网络获得判别性学习能力且专注于更有用的残差通道,从而学习到更准确的残差特征,提高重建精确度;2)利用残差网络和跳跃连接(skip connections),设计了一种基于 CA 模块的残差递归网络结构,以简洁的结构实现了一种较深的可训练网络模型,并解决了梯度消失和网络退化问题;3)重建网络采用并行映射结构以捕获不同的有效特征,保障重建效果,并采用子像素卷积实现上采样,以降低网络复杂度。

2 残差网络

文献^[14]表明,网络深度对神经网络模型的性能至关重要。理论上,越深的网络非线性表达能力越强,性能也越好,但简单地增加网络深度会导致梯度弥散或梯度爆炸问题。采用数据初始化(normalized initialization)和批归一化(batch normalization),可以在加深网络的同时解决梯度问题,但容易导致网络性能退化,使错误率随着网络深度的增加而上升。He 等提出的残差网络(ResNet)^[15]采用短路机制(shortcut),同时解决了网络退化问题和梯度问题,提高了网络性能。

残差单元结构如图 1 所示,设第 l 个残差单元的输入为 x_l ,输出为 x_{l+1} ,则残差单元的结构可表示为:

$$x_{l+1} = x_l + F(x_l, \{w_l^i\}) \quad (1)$$

$$F(x_l, \{w_l^i\}) = w_l^2 \sigma(w_l^1 x_l) \quad (2)$$

其中, $\{w_l^i\}$ 为权值参数, σ 表示 ReLU 激活函数,省略偏置项以简化表示,函数 $F(\cdot)$ 表示学习到的残差映射。




图 1 残差单元结构图

Fig. 1 Structure of residual unit

残差网络一般包含多层单元结构,从而使网络可以学习到从浅层到深层的多层特征。于是,由式(1)可得第 $(n-1)$ 个残差单元的输出 x_n 为:

$$x_n = x_l + \sum_{k=l}^{n-1} F(x_k, \{w_k^i\}) \quad (3)$$

式(3)表明,深层网络比浅层网络包含更多的图像信息,即解决了网络的退化问题。设残差网络的损失函数为 $Loss$,则有:

$$\frac{\partial Loss}{\partial x_l} = \frac{\partial Loss}{\partial x_n} \cdot \frac{\partial x_n}{\partial x_l} = \frac{\partial Loss}{\partial x_n} \left(1 + \frac{\partial F(x_l, \{w_l^i\})}{\partial x_l} \right) \quad (4)$$

其中,1 表明短路机制可以无损地传播梯度,它的存在解决了梯度消失问题,同时,加法的计算使更深层的网络训练变得更加容易、稳定。

3 本文方法

3.1 网络模型结构

本文提出的基于通道注意残差递归网络的超分辨率重建模型如图 2 所示,整个网络模型分为特征提取网络和重建网络两个部分。

(1)特征提取网络。将经过双三次插值的 LR 图像作为输入,使用 3×3 卷积层从 LR 图像中提取浅层特征;然后,将浅层特征输入本文设计的基于 CA 模块的残差递归网络进行深度特征的提取。该残差递归网络使用 16 个 CA 模块,以跳跃连接的方式构成简洁的残差递归结构,加快深层网络模型的收敛,同时避免网络退化和梯度问题。在每个 CA 模块中,利用通道注意力机制进行选择性的残差特征学习,使网络更专注于有用的特征信息,从而使网络能够学习到更准确、有效的残差特征信息。最后,使用 concatenate 函数,将卷积层提取的浅层特征和 CA 模块提取的多层深度特征进行融合。

(2)重建网络。采用并行映射的结构,两条支路不同的网络结构捕捉不同的有效特征,以增强映射的多样性和非线性,可以防止过拟合现象,有助于提高重建效果。由于经过 concatenate 操作后,融合的特征维数非常高,因此网络利用 1×1 卷积核进行降维,以此来降低网络复杂度。最后,采用子像素卷积(sub-pixel convolution)^[16]的上采样方法完成 HR 图像的重建。该上采样方法与 DRRN^[17]和 MemNet^[18]等方法相比,在计算复杂度和重建性能上都更优。

3.2 通道注意(CA)模块

此前的基于 CNN 的重建方法^[9-13]是均等地对待各通道特征,这种方式实际上并不合理。例如,LR 空间中的信息具有丰富的低频成分和有价值的高频成分,低频部分更加扁平

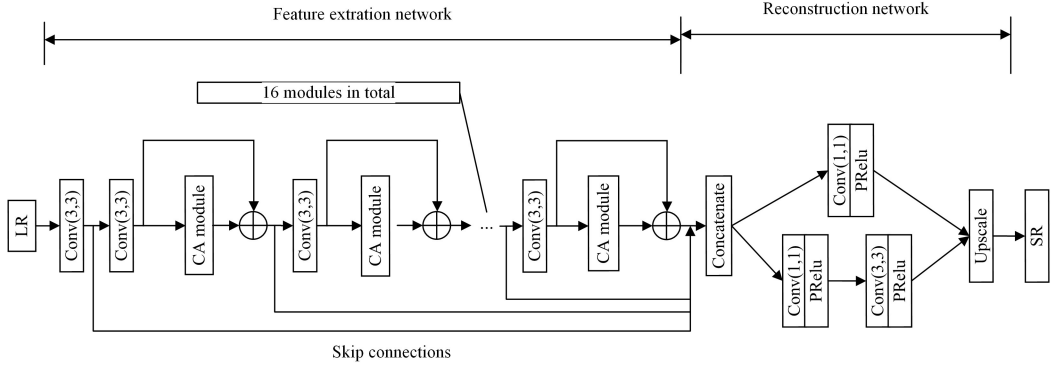


图2 基于通道注意递归残差网络的重建模型

Fig. 2 Reconstruction model based on CA residual recursive network

通道注意机制^[19]通过考虑通道之间的相互依赖性,自适应地重新调整来自各通道的特征,并通过特征通道之间的相互依赖性进行建模,来自适应地重新缩放每个通道的特征。这种 CA 机制使网络能够专注于更有用的通道,从而增强网络的判别性学习能力。本文的 CA 单元结构如图 3 所示。




图3 通道注意模块结构

Fig. 3 Structure of channel attention model

图3中,设 $\mathbf{X}=[x_1, \dots, x_c, \dots, x_C]$ 为输入,表示具有 C 个特征图,尺寸为 $H \times W$ 。全局平均池化将每个通道内所有的特征值相加后再平均,得到通道统计 $\mathbf{z} \in \mathbb{R}^C$,则 \mathbf{z} 的第 c 个元素可表示为:

$$z_c = H_{GP}(x_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_c(i, j) \quad (5)$$

其中, $x_c(i, j)$ 是第 c 个特征 x_c 在位置 (i, j) 的值, H_{GP} 表示全局平均函数。信道统计可以看作全局空间信息的集合,用最终的统计表示整个图像。

为了利用全局平均池化操作后汇总的信息,捕获通道相关性,网络使用 Sigmoid 激活函数构成门控机制,定义如下:

$$s_c = \delta(w_d \sigma(w_d z_c)) \quad (6)$$

其中, σ 和 δ 分别表示 PReLU 激活函数和 Sigmoid 函数; w_d 和 w_u 是 1×1 卷积层的权重集, w_d 以比率 r 的形式进行通道缩减,由 PReLU 激活后, w_u 以比率 r 的形式进行通道增加,然后获得最终的通道统计信息 $\{s_c\}$ 。最后,将 s_c 用于重新缩放输入 x_c 。

$$y_c = s_c \cdot x_c \quad (7)$$

其中, s_c 和 x_c 分别是第 c 个通道中的比例因子和特征图。

CA 模块各层的通道数如表 1 所列。

化,高频部分则通常包含了丰富的边缘、纹理和其他细节。另一方面,卷积层中的每个卷积核都以局部接收场运行,因此,直接进行卷积后的输出无法利用本地区域之外的通道信息。

表1 CA 模块各层的通道数

Table 1 Number of channels in each layer of CA model

输入	全局平均池化	1×1 卷积	PReLU	1×1 卷积	Sigmoid	输出
64	64	4	4	64	64	64

3.3 激活函数和损失函数

为了解决激活函数 ReLU 强行将负数置零可能导致的特征丢失问题,本文采用带参数的修正线性单元 (Parametric Rectified Linear Unit, PReLU)^[20] 作为激活函数。

$$PReLU(x_i) = \begin{cases} x_i, & x_i > 0 \\ a_i x_i, & x_i \leq 0 \end{cases} \quad (8)$$

其中,参数 a_i 是个非常小的固定值(如 $a_i = 0.01$)。当 $a_i = 0$ 时, PReLU 即为 ReLU。PReLU 激活函数不但可以保留 ReLU 加速收敛的优势,同时也能防止特征丢失。

本文方法采用 L1 损失函数,定义为:

$$L(\theta) = \frac{1}{n} \sum_{i=1}^n \|F(\mathbf{Y}_i; \theta) - \mathbf{X}_i\| \quad (9)$$

其中, \mathbf{Y}_i 表示 LR 图像的插值图, \mathbf{X}_i 表示 HR 图像, θ 是权值参数和偏置的集合, i 表示遍历整个训练集的图像的序号。

4 实验结果及分析

4.1 实验说明

本文实验的运行操作系统是 64 位的 Windows10,内存 16GB, GPU 为 GTX 1080Ti。使用的深度学习框架为 Pytorch,编程语言为 Python3.6。设置 dropout 为 0.5,选择 Adam 优化器,设初始学习率为 0.0002。

本文方法的实现主要有以下 4 步:1) 训练所需的外部图像库的建立;2) 搭建网络模型;3) 利用建立的外部图像库进行训练,不断优化网络参数,得到输入图像的特征表达和先验信息;4) 将 LR 图像重建得到 HR 图像。

本文采用的训练集为 DIV2K 数据集。该数据集由 1000 幅高清图组成,每幅图像的像素在 200 万左右。图像的细节部分清晰,非常适合用于超分辨率训练。通过旋转、缩放等方式对数据进行变换,使数据扩充数倍,可以有效避免过拟合。

为评估本文方法的重建效果,本文分别从客观指标和视觉效果两个方面进行对比。客观指标包括 PSNR 和 SSIM,对比方法包括 Bicubic、SRCNN、DRCN、LapSRN 和文献[21]方法,测试集采用 Set5, Set14, BSD100, Urban100 标准图像数据集。

4.2 结果分析

将本文方法与 Bicubic、SRCNN、DRCN 和 LapSRN 方法训练得到的网络模型分别在 Set5, Set14, BSD100, Urban100 数据集上进行 2 倍、3 倍、4 倍的超分辨率重建测试。表 2 列出了 5 种方法分别对 Set5 数据集中的每一幅图进行 2 倍超分辨率重建后的 PSNR 值的对比结果(单位为 dB)。表 3 列出了 5 种方法在 Set5, Set14, BSD100 和 Urban100 这 4 个测试数据集上分别进行 2 倍、3 倍、4 倍放大后的平均 PSNR 值(单位为 dB)和 SSIM 值的对比结果。从表 1 和表 2 可以看出,无论是单幅图像的 PSNR 指标,还是各个数据集图像的平均

PSNR 指标和 SSIM 指标,本文方法均明显优于其他方法。客观评价结果表明,相比当前主流的图像超分辨率重建方法,本文方法的重建图像具有更好的图像质量。分析原因,本文提出的网络模型引入了通道注意机制,使网络更专注于包含更多细节的通道,而且本文在通道注意基础上构建了递归结构的残差网络,使本文模型在加深网络的同时保证梯度持续存在,从而保证了本文方法具有更好的重建性能。

表 2 不同方法下 Set5 数据集中每一幅图重建后的 PSNR 值对比
Table 2 Comparison of PSNR values of each image after reconstruction by different methods on Set5 dataset

Set5	尺度	Bicubic	SRCNN	DRCN	LapSRN	本文方法
Baby	×2	37.05	38.52	38.79	38.75	38.93
Bird	×2	36.79	40.90	42.67	42.47	43.39
Butterfly	×2	27.43	32.74	34.56	34.42	35.52
Head	×2	34.84	35.71	35.95	35.92	36.03
Woman	×2	32.14	35.35	36.15	36.04	36.49

表 3 本文算法与其他算法在不同数据集上的平均 PSNR/SSIM 值对比

Table 3 Average PSNR and SSIM comparisons of the proposed method and other methods on four datasets

数据集	尺度	Bicubic	SRCNN	DRCN	LapSRN	本文方法
Set5	×2	33.66/0.9299	36.66/0.9542	37.63/0.9588	37.52/0.9591	38.07/0.9607
	×3	30.39/0.8682	32.75/0.9090	33.82/0.9226	33.82/0.9227	34.48/0.9278
	×4	28.42/0.8104	30.48/0.8628	31.53/0.8854	31.54/0.8855	32.25/0.8960
Set14	×2	30.24/0.8688	32.45/0.9067	33.04/0.9118	33.08/0.9130	33.59/0.9176
	×3	27.55/0.7742	29.30/0.8215	29.76/0.8311	29.79/0.8320	30.39/0.8437
	×4	26.00/0.7027	27.50/0.7513	28.02/0.7670	28.19/0.7720	28.63/0.7836
BSD100	×2	29.56/0.8431	31.36/0.8879	31.85/0.8942	31.08/0.8950	32.23/0.9102
	×3	27.21/0.7385	28.40/0.7863	28.80/0.7963	28.82/0.7973	29.15/0.8063
	×4	25.96/0.6675	26.90/0.7101	27.23/0.7233	27.32/0.7280	27.60/0.7371
Urban100	×2	26.88/0.8403	29.50/0.8946	30.75/0.9133	30.41/0.9101	32.31/0.9343
	×3	24.46/0.7349	26.24/0.7989	27.15/0.8276	27.07/0.8272	28.32/0.8517
	×4	23.14/0.6577	24.52/0.7221	25.14/0.7510	25.21/0.7553	26.21/0.7910

为了充分验证本文提出的基于注意力机制的递归残差网络模型的有效性,将本文方法与 Bicubic、SRCNN、DRCN、LapSRN 和文献[21]中的方法从重建图像的视觉效果上进行对比。

首先,分别从 Set5, Set14, BSD100 和 Urban100 测试数据

集中各随机抽取一幅图像,将它们都进行 3 倍下采样处理,再输入到各个网络模型中。图 4 给出了不同方法下每幅图像的 3 倍超分辨率重建图像的局部放大图与原始高分辨率图像局部放大图的对比结果。

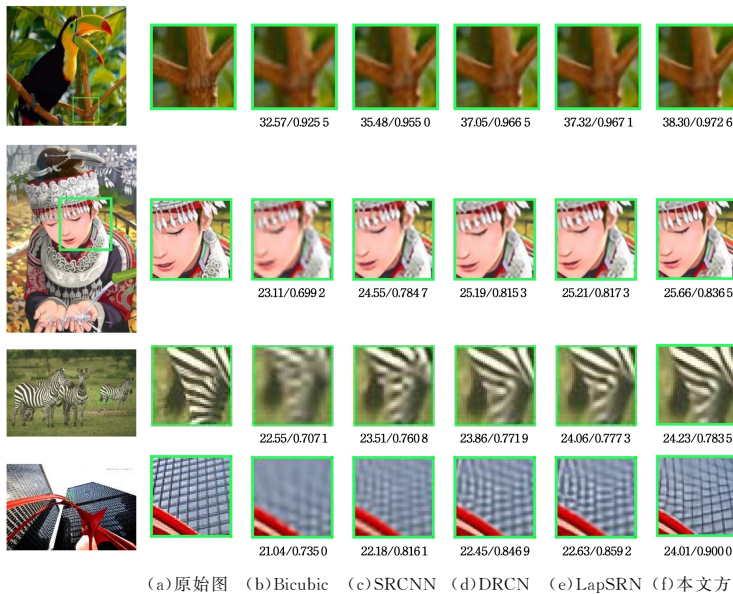


图 4 3 倍放大时不同方法的重建结果对比图(PSNR/SSIM)

Fig. 4 Comparison of reconstruction results of different algorithms at 3× magnification(PSNR/SSIM)

观察图 4 可以明显看出,与其他方法相比,本文方法恢复的图像其边缘和纹理等细节更加清晰,与原始图像的视觉效果更接近。同时,本文方法的 PSNR 和 SSIM 值也优于其他方法。

为了进一步验证本文方法在原始高清图未知的情况下对给定 LR 图像进行超分辨率重建的性能,取文献[21]中的 LR 图作为超分辨率重建对象,采用不同的方法对其进行 4 倍重

建放大。图 5 给出了 LR 图与 Bicubic、SRCNN、DRCN、LapSRN、文献[21]中的方法和本文方法重建后图像两处局部放大的对比结果。从图 5 可以看出,DRCN、LapSRN、文献[21]中的方法以及本文方法的重建图像的清晰度显著高于插值方法和 SRCNN。其中,DRCN、LapSRN 和文献[21]中的方法恢复的图像在细节纹理上仍存在不同程度的模糊,而本文方法恢复的图像具有更好的视觉效果。




图 5 原始图未知情况下不同方法 4 倍重建结果对比图

Fig. 5 Comparison of reconstruction results of different algorithms at $4\times$ magnification with unknown original image

结束语 本文提出一种基于注意力机制的递归残差网络图像超分辨率重建方法。该算法先采用 16 层的递归残差神经网络来加快深层网络模型的收敛,解决了梯度消失和网络退化问题;采用通道注意力机制使网络获得判别性学习的能力,从而提高重建精确度;然后采用并行映射的方式加宽网络模型,一定程度上可防止过拟合问题。此外,使用 PReLU 激活函数以进一步提高重建质量。实验证明,无论在主观视觉效果上还是客观评价指标上,本文方法均优于现有的主流方法。接下来的工作可以在保证重建精确度的前提下进一步优化模型,降低时间复杂度,提高速度。

参考文献

- [1] ZHANG H, ZHANG L, SHEN H. A blind super-resolution reconstruction method considering image registration errors [J]. *International Journal of Fuzzy Systems*, 2015, 17(2): 353-364.
- [2] ZHANG K B, GAO X B, TAO D A, et al. Single image super-resolution with non-local means and steering kernel regression [J]. *IEEE Transactions on Image Processing*, 2012, 21(11): 4544-4556.
- [3] TIMOFTE R, DE V, GOOL L V. Anchored neighborhood regression for fast example-based super-resolution [C] // *Proceedings of 2013 IEEE International Conference on Computer Vision*. Sydney, NSW, Australia: IEEE, 2013: 1920-1927.
- [4] TIMOFTE R, DESMET V, VANGOOL L. A+: adjusted anchored neighborhood regression for fast super-resolution [C] // *Proceedings of 12th Asian Conference on Computer Vision*. Singapore: Springer, 2014: 111-126.
- [5] PELEG T, ELAD M. A statistical prediction model based on sparse representations for single image super-resolution [J]. *IEEE Transactions on Image Processing*, 2014, 23(6): 2569-2582.
- [6] QIN X J, SHAN Y Y, XIAO J J, et al. Self-learning single image super-resolution reconstruction based on compressive sensing and SVR [J]. *Computer Science*, 2017, 44(S2): 169-174.
- [7] LI J H, WU Y R, LV J J. Onlinesingle image super-resolution algorithm based on group sparse representation [J]. *Computer Science*, 2018, 45(4): 312-318.
- [8] THAPA D, RAAHEMIFAR K, BOBIER W R, et al. A performance comparison among different super-resolution techniques [J]. *Computers & Electrical Engineering*, 2016, 54: 313-329.
- [9] DONG C, LOY C C, HE K M, et al. Image super-resolution using deep convolutional networks [J]. *IEEE Transaction on Pattern Analysis & Machine Intelligence*, 2016, 38(2): 295-307.
- [10] DONG C, CHEN C L, TANG X. Accelerating the Super-Resolution Convolutional Neural Network [C] // *European Conference on Computer Vision*. Springer, Cham, 2016: 391-407.
- [11] KIM J, JUNG K L, KYOUNG M L. Accurate Image Super-Resolution Using Very Deep Convolutional Networks [J]. *IEEE Conference on Computer Vision and Pattern Recognition*. 2016: 1646-1654.
- [12] KIM J, JUNG K L, KYOUNG M L. Deeply-recursive convolutional network for image super-resolution [C] // *IEEE Conference on Computer Vision and Pattern Recognition*. 2016: 1637-1645.
- [13] LAI W S, HUANG J B, NARENDRA A, et al. Deep laplacian pyramid networks for fast and accurate super-resolution [C] // *IEEE Conference on Computer Vision and Pattern Recognition*. 2017: 624-632.
- [14] QU Y, LIN L, SHEN F, et al. Joint Hierarchical Category Structure Learning and Large-Scale Image Classification [J] *IEEE Transactions on Image Processing*, 2017, 26(9): 4331-4346.
- [15] HE K, ZHANG X, REN S, et al. Deep Residual Learning for Image Recognition [C] // *IEEE Conference on Computer Vision and Pattern Recognition*. 2016: 770-778.
- [16] SHI W Z, CABALLERO J, HUSZAR 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.
- [17] TAI Y, YANG J, LIU X M. Image super-resolution via deep re-

cursive residual network [C] // IEEE Conference on Computer Vision and Pattern Recognition. 2017;3147-3155.

[18] TAI Y, YANG J, LIU X M. Memnet: A persistent memory network for image restoration [C] // IEEE International Conference on Computer Vision. 2017;4539-4547.

[19] HU J, LI S, ALBANIE S, et al. Squeeze-and-Excitation Networks [C] // IEEE Conference on Computer Vision and Pattern Recognition. 2018;7132-7141.

[20] HE K, ZHANG X, REN S, et al. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification [C] // Proceedings of the IEEE International Conference on

Computer Vision Santiago, Chile, 2015:1026-1034.

[21] QIN Z S, ZHU L L, ZANG H J. An image super-resolution reconstruction method based on convolutional neural network: China Patent, 201910149271.6 [P]. 2019-06-18 [2020-09-17].



GUO Lin, born in 1978, Ph.D, associate professor. Her main research interests include signal processing, machine vision and deep learning.