

结构化混合注意力网络的图像超分辨率重建

喻九阳, 张德安, 戴耀南, 胡天豪, 夏文凤

引用本文

喻九阳, 张德安, 戴耀南, 胡天豪, 夏文凤. 结构化混合注意力网络的图像超分辨率重建[J]. 计算机科学, 2023, 50(6A): 220600240-5.

YU Jiuyang, ZHANG Dean, DAI Yaonan, HU Tianhao, XIA Wenfeng. [Image Super-resolution Reconstruction Based on Structured Fusion Attention Network](#) [J]. Computer Science, 2023, 50(6A): 220600240-5.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于多编码器的多模态MRI脑肿瘤分割](#)

Multimodal MRI Brain Tumor Segmentation Based on Multi-encoder Architecture
计算机科学, 2023, 50(6A): 220200108-6. <https://doi.org/10.11896/jsjcx.220200108>

[基于稀疏编码非局部注意力对偶网络的病理图像超分辨率重建](#)

Pathological Image Super-resolution Reconstruction Based on Sparse Coding Non-local AttentionDual Network
计算机科学, 2023, 50(6A): 220700016-8. <https://doi.org/10.11896/jsjcx.220700016>

[基于改进B-RRT*算法的移动机器人路径规划](#)

Path Planning of Mobile Robot Based on Improved B-RRT* Algorithm
计算机科学, 2023, 50(6A): 220500038-7. <https://doi.org/10.11896/jsjcx.220500038>

[基于深度神经网络的块压缩感知图像重构](#)

Block-based Compressed Sensing of Image Reconstruction Based on Deep Neural Network
计算机科学, 2022, 49(11A): 210900118-9. <https://doi.org/10.11896/jsjcx.210900118>

[基于动态金字塔和子空间注意力的图像超分辨率重建网络](#)

Image Super-resolution Reconstruction Network Based on Dynamic Pyramid and Subspace Attention
计算机科学, 2022, 49(11A): 210900202-8. <https://doi.org/10.11896/jsjcx.210900202>

结构化混合注意力网络的图像超分辨率重建

喻九阳 张德安 戴耀南 胡天豪 夏文凤

湖北省绿色化工装备工程技术研究中心 武汉 430205

武汉工程大学机电工程学院 武汉 430205

(yji@wit.edu.cn)

摘要 针对现有图像超分辨率模型存在特征提取能力弱、模型参数量较复杂等问题,提出了一种结构化混合注意力网络的图像超分辨率重建模型,该模型在提高图像超分辨率重建效果的同时降低了模型的参数量。首先,对编码器进行结构化处理,通过通道数量的不同来提取更多的图像特征。其次,对编码器的输出特性进行注意力网络混合重组,从而加强图像的特征特性。最后,采用残差方式将输入的浅层图像特征直接与强化特征相混合,降低网络的参数量。实验结果表明,在公共数据集及不同放大倍率的前提下,文中构建模型的 PSNR 值和 SSIM 值基本是最优的,且网络结构的参数量较低,较好地平衡了图像超分辨率重建过程中性能和参数复杂度间的关系。

关键词: 图像处理; 超分辨率; 结构化残差; 混合注意力; 低模型参数

中图分类号 TP391

Image Super-resolution Reconstruction Based on Structured Fusion Attention Network

YU Jiuyang, ZHANG Dean, DAI Yaonan, HU Tianhao and XIA Wenfeng

Hubei Green Chemical Equipment Engineering Technology Research Center, Wuhan 430205, China

School of Mechanical and Electrical Engineering, Wuhan Institute of Technology, Wuhan 430205, China

Abstract Aiming at the problems of weak feature extraction ability and complex model parameters in existing image super-resolution models, an image super-resolution reconstruction model based on structured hybrid attention network is proposed. This model can reduce the number of parameter while improving the super-resolution reconstruction effect. First, the encoder is structured to extract more image features through the difference in the number of channels. Second, the attention network hybrid reorganization is performed on the output features of the encoder to enhance the feature characteristics of the image. Finally, a residual method is used to directly mix the input shallow image features with the enhanced features to reduce the amount of network parameters. Experimental results show that under the premise of public data sets and different magnifications, the PSNR value and SSIM value of the proposed model are basically optimal, and the parameter amount of the network structure is low, which better balances the relationship between performance and parameter complexity in the process of image super-resolution reconstruction.

Keywords Image processing, Super-resolution, Structured residuals, Fused attention, Low model parameters

1 引言

超分辨率重建(Super-resolution Reconstruction, SR)技术主要是将输入低分辨率(Low Resolution, LR)图像重建出包含丰富细节的高分辨率(High Resolution, HR)图像,在这一过程中需要尽可能多地收集和分析特征点相邻像素,以重建出具有更高像素密度的图像。该技术现已被广泛的应用在机器人图像探测、医学图像、卫星遥感等领域^[1]。

目前,SR的研究重点主要是构建参数量较少的模型来提取更丰富的特征信息,恢复更多的图像细节。Lan等^[2]提出了一种级联残差网络(Cascading Residual Networks, CRNs),采用双全局路径结构来简化模型的训练,并结合非局部操作从输入低分辨率(LR)信息中捕捉到长距离空间要素,通过引入多尺度块(Multi-scale Block, MSB)从LR图像中的低级特征获取

不同尺度下输入的特征表示。Hu等^[3]提出了图像超分辨率重构方法,在上采样阶段将低分辨率图像缩放至指定大小,在特征提取阶段提取低分辨率图像的初始特征,将提取到的初始特征送入卷积编解码结构进行图像特征去噪,最后使用残差学习快速优化网络重建出高分辨率图像。Yang等^[4]提出了一个多分支注意力SR模型,均分所有通道,关注高频特征,解决了较深的卷积神经网络带来的计算量大、训练困难以及效率低的问题。Wang等^[5]提出了一种双剩余注意模块(Double Residual Attention Module, DRAM)网络,该网络致力于恢复高频细节并在两个不同大小的感受野之间共享信息,构建了本地信息集成(Local Information Integration, LFI)模块作为基本模块,充分利用本地图像信息,抑制不重要的特征,提高图像分辨率的重构质量。Kim等^[6]提出了一种高精度单幅图像超分辨率模型,该模型采用20个权重层,在深层

基金项目:湖北省重点研发计划(2020BAB030)

This work was supported by the Key R & D Program of Hubei Province(2020BAB030).

通信作者:戴耀南(dyn1121758919@163.com)

网络结构中采用多次级联过滤器,有效地利用大图像区域上的上下文信息。Liu 等^[7]提出了一种新的残差特征聚合(Residual Feature Aggregation, RFA)框架,以有效提取图像特征信息并优化该模块,并衍生出增强的空间注意力块,将剩余特征集中于关键的空间内容,使得设计的空间模块更加精准且高效。Zhang 等^[8]提出了一种新的残差稠密网络(Residual Dense Net, RDN),用于提高图像的 SR,通过残差密集块(Residual Dense Block, RDB)连接卷积层来提取并自适应学习丰富的局部特征,在充分获得密集的局部特征后,采用全局特征混合法来整合和自适应地学习全局的层次特征。

上述方法虽然提升了特征信息的提取能力,但是仍存在收敛速度慢、计算量大、图像细节容易丢失、图像特征信息层面混合和互通能力较差等问题,因此在低级特征到高级特征的提取、网络宽度的利用、降低参数复杂度等方面仍有很大的研究空间。

针对以上问题及可研究性,本文提出了一种结构化混合注意力网络的图像超分辨率重建(SFSR)模型^[9]。SFSR 使用 PReLU 函数^[10]作为激活函数,将残差块作为基本模块,网络的通道数随着感受野的增加而增加,充分利用网络宽度来增加图像特征信息的提取。SFSR 将编码器得到的图像特征信息分别输入到通道注意力模块和空间注意力模块中,以串联的方式将双通道组合在一起,通过一种新的通道混合方法将高图像的层级信息和浅层级信息相互关联,将 smooth L1 作为损失函数。




图 1 SFSR 的整体框架

Fig. 1 Overall framework of SFSR

2.2 编码器模块

注意力残差组由多个残差块组成,SFSR 中的残差块是在 ResNets 使用的标准残差块的基础上改进的,单个残差块的结构如图 2 所示。具体改进如下。

(1)激活函数使用 PReLU 激活函数代替 ReLU 函数^[14],因为 PReLU 激活函数在几乎没有增加额外参数的前提下可以提升模型的拟合能力,又可以减小过拟合风险,其表达式如下:

$$\text{PReLU}(y_i) = \begin{cases} y_i, & \text{if } y_i > 0 \\ a_i y_i, & \text{if } y_i \leq 0 \end{cases} \quad (1)$$

其中, i 代表不同的通道, y_i 是激活函数在第 i 个通道的输入, a_i 是斜率。

(2)中间的卷积层采用比传统卷积^[15-16]具有运算成本低、参数个数少的优点的 3×3 深度可分离卷积层。

3个残差注意力块(b_1, b_2, b_3)分别由多个残差块组成,由于浅层特征的感受野较小, b_1 中的单个残差块没有设置 3×3 深度可分离卷积层。随着特征信息提取的深入, b_2 和 b_3 中的残差块包含 3×3 深度可分离卷积层。为了降低 SFSR 模型的参数复杂度,经过大量实验,将3个注意力块中的残差块数和通道放大率分别设置为(6, 8, 6)和($\times 1, \times 2, \times 4$)。

最后,SFSR 利用残差结构将输入图像的浅层特征信息与网络解码器通过长跳跃输出的增强特征信息进行全局连接。

2 模型构建

SFSR 主要由编码器模块、解码器模块和残差模块 3 部分组成。编码器模块由不同的结构化残差注意力块和混合域注意力模块组成,基于残差理论,将卷积^[11]得到的浅层图像特征输入到编码器中。解码器模块主要基于注意力机制,将细化后的图像特征信息平均导入通道注意力模块和空间注意力模块进行特征增强,设计新的通道混合法,将两个注意力模块进行混合后,利用 PixelShuffle^[12]方法重构解码器,以 smooth L1 作为损失函数,解码器的数量由上采样的倍数决定。残差模块主要采用全局跳跃连接方式,通过最近的上采样模块,将增强后的输出特征与原始输入图像的浅层特征信息进行叠加,即整个 SR 网络形成一个整体的残差结构,只需要学习残差特征,从而加快网络的收敛速度。

2.1 SFSR 模型

SFSR 的整体结构如图 1 所示,包括最近邻插值上采样模块(Nearest Upsample)、残差注意力模块(Residual Attention)、混合域注意力模块(MDAM)、卷积模块(CONV)^[13]以及解码器模块(Decoders),其中 b_1, b_2 和 b_3 是3个不同的残差注意力模块, W 和 H 代表特征图的宽度和高度, C_1, C_2, C_3 表示通道数。

MDAM 是一种混合域注意力模块,编码器中 MDAM 的重建放大倍数为 1,不进行 PixelShuffle 重建,即 MDAM 只对空间注意力模块和通道注意力模块中的特征信息进行混合和细化,来提高图像提取的特征信息。




图 2 残差块结构

Fig. 2 Residual block structure

2.3 解码器模块

SFSR 的解码器模块由 MDAM 和 Sub-pixel Convolution 模块组成,首先利用通道之间的相互作用以及图像特征的空间状态设计注意力模块的组合形式,对于输入一个 $W \times H \times C$ 的特征 F ,通道注意力模块得到 $1 \times 1 \times C$ 的通道描述,空间

注意力模块得到 $W \times H \times 1$ 的通道描述,进行两通道的顺序组合得到缩放后的新特征。

在 SFSR 解码过程中,首先将经过编码器处理后的图像特征输入解码器中,经过 3×3 卷积层对图像特征进行细化增强图像特征;其次,将增强后的图像特征经过通道注意力模块将所得特征相加后,经过激活函数处理得到缩放后的新特征 F' ,新特征 F' 经过空间注意力模块的特征识别与增强处理,得到缩放后的新特征 F'' ,通过 1×1 卷积核对新的特征图进行特征映射得到特征图;最后,基于子像素卷积模块中的 PixelShuffle 对特征进行上采样。当上采样倍数为 n 时,PixelShuffle 需要 n_2 个通道来重组一个像素周围的空间。因此,SFSR 并行采用了空间注意力模块和通道注意力模块来降低网络的结构复杂度,满足 PixelShuffle 算法的特点。

图像的放大以及原生图低分辨率都会影响上采样法对特征图放大的效果,采用不同的信道组合方式可以很好地恢复图像特征,信道顺序组合(见图 3(a))^[17] 与并行组合(见图 3(b))^[17] 可以产生不同的效果,采取顺序组合可以获得更好的像素级特征,提高采样的精确度^[18]。

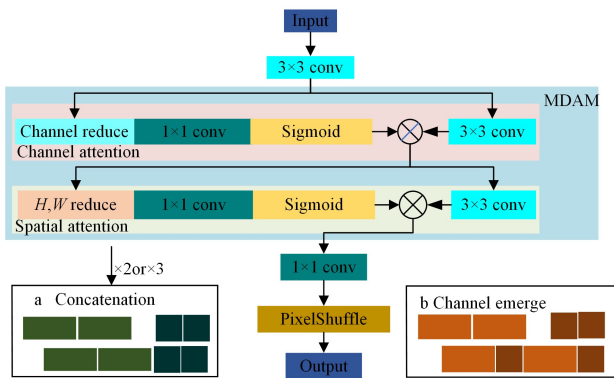


图 3 解码器模块结构

Fig. 3 Decoder module structure

2.4 结构残差模块

根据 DRSR^[16] 网络的相关优点,本文采用全局连接的方法对输入图像进行最近插值,在输入的低分辨率图像上叠加增强后的图像特征信息。由于输入的低分辨率图像已经包含低频信息特征,残差模块可以通过基于浅层特征信息的上采样方法来直接预测高分辨率结果,从而大大减少模型的参数量。

损失函数的选择在很大程度上影响着网络性能,目前常使用 L1 loss 和 L2 loss。L1 loss 虽然有稳定的梯度,但在零点处不平滑且学习慢。L2 loss 虽然连续且光滑,但是鲁棒性较差^[19],因此 SFSR 结合 L1 与 L2 的优点,采用梯度下降快、鲁棒性能强的 smooth L1 作为损失函数,其表达式为:

$$\text{Smooth}_{L1}(x, y) = \begin{cases} 0.5 * (y_i - f(x_i))^2, & \text{if } |y_i - f(x_i)| < 1 \\ |y_i - f(x_i)| - 0.5, & \text{otherwise} \end{cases} \quad (2)$$

其中, y_i 表示真实值, $f(x_i)$ 表示预估值。

3 实验与结构分析

3.1 实验设置

(1) 实验平台及数据集选择

本文采用 NVIDIA RTX 3060Ti 显卡,采用软件 Python3.8

软硬件平台进行编译,操作系统平台为 Ubuntu 22.04。

本实验采用高质量的通用图像数据集 (DIV2K)^[20] 作为训练集和验证集,将 5 个常见的公共数据集 (Set5, Set14, B100, Urban100 和 Manga109) 用于评估模型的性能。Batch Size 设置为 64,全数据集 (epoch) 设置为 600,一个 epoch 迭代 200 次,重建尺度设置为 $\times 2$,并将 $\times 3$ 和 $\times 4$ 的尺度应用于重建图像,与其他主流的 SR 算法进行比较。

(2) 评价指标

选取峰值信噪比 (PSNR) 和结构相似度 (SSIM) 作为图像的定性评价指标。PSNR 和 SSIM 的值越高,其效果越好,PSNR^[21] 和 SSIM^[22] 的计算式如下:

$$\text{PSNR} = 10 \log_{10} \left(\frac{\text{MAX}_I^2}{\text{MSE}} \right) = 20 \log_{10} \left(\frac{\text{MAX}_I}{\sqrt{\text{MSE}}} \right) \quad (3)$$

$$\text{SSIM}(X, Y) = \frac{(2\mu_X\mu_Y + C_1)(2\sigma_{XY} + C_2)}{(\mu_X^2 + \mu_Y^2 + C_1)(\sigma_X^2 + \sigma_Y^2 + C_2)} \quad (4)$$

其中, MAX_I 是表示图像点颜色的最大数值; (μ_X, μ_Y) 和 (σ_X, σ_Y) 分别表示 X, Y 的平均值和方差, σ_{XY} 是 X 和 Y 的协方差, C_1 和 C_2 是正常数。

3.2 实验分析

消融实验用于评价结构化模块和混合注意力模块对 SF-SR 的有效性,根据文献[9],本次实验仅训练 DIV2K 数据库中的 800 个训练集。

实验比较内容包括编码器残差块中的 3×3 深度可分离卷积层、解码器注意力模块中的顺序性混合,本文展示了 Set14 在 400 个 epochs 上的 PSNR 值和 SSIM 值,缩放倍数为 2 倍。结果如表 1 所列,可以看出,SFSR 的编码器和解码器中增加或改进了模块,不仅可以提取更多的图像特征,也有效地降低了参数数量。

表 1 编码器模块和解码器模块消融实验

Table 1 Encoder module and decoder module ablation experiments

Components	Combination					
DACL		✓		✓		✓
Parallelism		✓	✓	✓	✓	✓
Fusion				✓		✓
PSNR	29.01	31.98	30.93	32.15	32.42	32.78
SSIM	0.8857	0.8993	0.8936	0.9091	0.9110	0.9203
Parameter	2.3	2.0	2.1	1.8	2.1	1.7

图 4 给出了 DIV2K 训练集在 600 个 epochs 上的 PSNR 值和 SSIM 值,缩放倍数为 $\times 2$,验证使用或者不适用高频残差模块时,模型的性能变化。由图 4 可知,在本文方法上加入高频残差模块时,epoch 为 410 时就已经稳定,反之,在 epoch 为 495 时才趋于稳定。结果表明,加入高频残差模块的收敛特性远远优于不使用高频残差模块的模型。




图 4 残差模块的消融实验

Fig. 4 Ablation experiment of high-frequency residual module

3.3 模型对比分析

表 2 列出了本文方法与 Bicubic^[22]、MCRAN+^[22] 和 ED-SR^[23] 方法的定量评估汇总。由表 2 可知,本文方法生成图像的平均 PSNR 值和 SSIM 与 MCRAN+ 相差不大,但是与其他 SR 重建图像的方法的质量有大幅度的提升。同时,如图 5 所示,在这种方法下,本文方法的准确率更高。

表 2 DIV2K 实验对比
Table 2 DIV2K experiment comparison

method	scale	DIV2K validation set			
		Bicubic	EDSR	MCRAN+	Our SFSR
×2	PSNR	31.35	35.03	36.60	38.75
	SSIM	0.9076	0.9695	0.9487	0.9489
×3	PSNR	28.49	31.26	32.82	34.19
	SSIM	0.8339	0.9340	0.8940	0.9308
×4	PSNR	26.92	29.25	30.81	31.68
	SSIM	0.7774	0.9017	0.8457	0.9002




图 5 基于 DIV2K 的 SFSR 收敛性分析

Fig. 5 Convergence analysis of SFSR based on DIV2K

将本文方法与现有几种先进的超分辨率重建方法 (Bicubic, DIN^[24], SRCNN^[25], VDSR^[6], DRCN^[26], DRSR^[16]) 在公开数据集上 (Set5, Set14, BSD100) 进行图像重建效果对比,进而评估此方法的特性以及性能。

表 3、表 4 列出了多种 SR 方法在多个公开数据集上的测试结果。可以发现,在这些数据集中,本文方法对比其他网络 SR 方法,在 PSNR 和 SSIM 上均有明显的提高。

表 3 数据集在不同结构下的 PSNR 平均值

Table 3 Average PSNR of datasets with different structures

Data set	Scale	Bicubic	DIN	SRCNN	VDSR	DRCN	DRSR	Our SFSR
Set5	×2	33.66	38.26	36.33	37.53	38.26	38.21	38.35
	×3	30.39	34.76	32.75	33.66	34.75	34.68	34.96
	×4	28.42	32.67	30.48	31.35	32.60	32.43	32.80
Set14	×2	30.24	34.03	32.45	33.05	34.02	33.92	34.43
	×3	27.55	30.65	29.30	29.78	30.59	30.55	30.81
	×4	26.00	28.87	27.50	28.02	28.88	28.86	29.10
BSD100	×2	29.56	32.35	31.36	31.91	32.36	32.33	32.61
	×3	27.21	29.29	28.41	28.83	29.33	29.25	29.53
	×4	25.96	27.78	26.90	27.29	27.70	27.74	27.96

表 4 数据集在不同结构下的 SSIM 平均值

Table 4 Average SSIM of datasets with different structures

Data set	Scale	Bicubic	DIN	SRCNN	VDSR	DRCN	DRSR	Our SFSR
Set5	×2	0.9299	0.9616	0.9542	0.9587	0.9615	0.9612	0.9626
	×3	0.8682	0.9298	0.9090	0.9140	0.9300	0.9290	0.9330
	×4	0.8104	0.9006	0.8628	0.8657	0.9002	0.8984	0.9031
Set14	×2	0.8688	0.9214	0.9063	0.9088	0.9213	0.9204	0.9260
	×3	0.7742	0.8480	0.8209	0.8242	0.8476	0.8464	0.8532
	×4	0.7027	0.7890	0.7503	0.7535	0.7890	0.7879	0.7939
BSD100	×2	0.8431	0.9018	0.8879	0.8906	0.9020	0.9016	0.9057
	×3	0.7385	0.8098	0.7863	0.7897	0.8114	0.8088	0.8234
	×4	0.6675	0.7437	0.7101	0.7128	0.7416	0.7415	0.7481

为了更直观地评估各种方法重建图像的效果,采用不同的缩放倍数 (×2, ×3 和 ×4) 对部分数据集上的图像进行细节缩放,如图 6—图 8 所示。

图 6 采用两倍放大因子,可以观测到结果图在细节恢复方面更加清晰;图 7 采用 3 倍放大因子,观测到本文方法在抗锯齿以及清晰度方面更优;图 8 采用四倍放大因子,可以观测到发饰边界特征更加明显,线条更清晰。相比其他超分辨率方法,本文方法重建图像的清晰度以及分辨率更优。




图 6 两倍放大因子下不同算法处理后 flower 图像的超分辨率结果
Fig. 6 Super-resolution results of flower images processed by different algorithms under twice magnification factor




图 7 三倍放大因子下不同算法处理后 bird 图像的超分辨率结果
Fig. 7 Super-resolution results of bird images processed by different algorithms under triple magnification factor




图 8 四倍放大因子下不同算法处理后 comic 图像的超分辨率结果
Fig. 8 Super-resolution results of comic images processed by different algorithms under four times magnification factor

通过对比发现,无论是在客观的数据对比还是在主观的视觉效果对比上,本文所获取的重建图片效果明显较其他先进 SR 方法更优,故 SFSR 在高倍图像的 SR 上具有明显的性能优势。

结束语 针对图像超分辨率重构模型中缺乏图像特征信息的互通、收敛速度慢、计算量大、图像细节容易丢失等问题,提出了一种基于结构化混合注意力网络的图像超分辨率重建 (SFSR) 模型。首先,通过设置不同的通道数来改变残差模块,提取更多的图像特征;其次,将通道注意力模块和空间注意力模块采用顺序连接的方式组合在一起,并利用 PixelShuffle 方法重构解码器的功能;最后,残差模型的设置不仅加速了网络残差的收敛,也提高了图像重建效果。实验结果表明,对比其他方法,SFSR 在 Set5, Set14 和 B100 测试集上的平均 PSNR 和 SSIM 的值都有所提高,并且 SFSR 的视觉对比度更佳,图像纹理、细节特征更突出。

本文方法在取得优异成果的情况下,也存在着一些不足。主要问题集中在对图像细节信息提取的速度以及图像特征提取少且慢。未来研究中,将继续深化对本文的研究工作,加快图像特征提取的速度以及准确率,优化本文提出的模型,缩短计算量,从而更有效地提高图像超分辨率重建效果。

参 考 文 献

- [1] CHEN Q, SONG H, YU J, et al. Current development and applications of super-resolution ultrasound imaging [J]. *Sensors*, 2021, 21(7): 2417.
- [2] LAN R, SUN L, LIU Z, et al. Cascading and enhanced residual networks for accurate single-image super-resolution [J]. *IEEE Transactions on Cybernetics*, 2020, 51(1): 115-125.
- [3] HU X Y, GUO H R, ZHU R. Image Super-Resolution Reconstruction Based on Hybrid Deep Convolutional Networks [J]. *Computer Applications*, 2020, 40(7): 2069-2076.
- [4] YANG X, GUO Y, LI Z, et al. Image super-resolution network based on a multi-branch attention mechanism [J]. *Signal, Image and Video Processing*, 2021, 15(7): 1397-1405.
- [5] WANG X, GU Y, GAO X, et al. Dual residual attention module network for single image super resolution [J]. *Neurocomputing*, 2019, 364: 269-279.
- [6] KIM J, LEE J K, LEE K M. Accurate image super-resolution using very deep convolutional networks [C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2016: 1646-1654.
- [7] LIU J, ZHANG W, TANG Y, et al. Residual feature aggregation network for image super-resolution [C] // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2020: 2359-2368.
- [8] ZHANG Y, TIAN Y, KONG Y, et al. Residual dense network for image restoration [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, 43(7): 2480-2495.
- [9] DAI Y, YU J, HU T, et al. Structured Fusion Attention Network for Image Super-Resolution Reconstruction [J]. *IEEE Access*, 2022, 10: 31896-31906.
- [10] 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*. 2015: 1026-1034.
- [11] CHOLLET F. Xception: Deep learning with depthwise separable convolutions [C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2017: 1251-1258.
- [12] LI J, FANG F, MEI K, et al. Multi-scale residual network for image super-resolution [C] // *Proceedings of the European Conference on Computer Vision (ECCV)*. 2018: 517-532.
- [13] CHEN H, GU J, ZHANG Z. Attention in attention network for image super-resolution [J]. *arXiv:2104.09497*, 2021.
- [14] MISRA D, NALAMADA T, ARASANIPALAIA U, et al. Rotate to attend: Convolutional triplet attention module [C] // *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*. 2021: 3139-3148.
- [15] ZOU D, CAO Y, ZHOU D, et al. Gradient descent optimizes over-parameterized deep ReLU networks [J]. *Machine Learning*, 2020, 109(3): 467-492.
- [16] YANG X, XIE T, LIU L, et al. Image super-resolution reconstruction based on improved Dirac residual network [J]. *Multidimensional Systems and Signal Processing*, 2021, 32(4): 1065-1082.
- [17] LAI W S, HUANG J B, AHUJA N, et al. Deep laplacian pyramid networks for fast and accurate super-resolution [C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2017: 624-632.
- [18] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module [C] // *Proceedings of the European Conference on Computer Vision (ECCV)*. 2018: 3-19.
- [19] LYAQINI S, QUAFARFOU M, NACHAOUMI, et al. Supervised learning as an inverse problem based on non-smooth loss function [J]. *Knowledge and Information Systems*, 2020, 62(8): 3039-3058.
- [20] TIMOFTE R, AGUSTSSON E, VAN GOOL L, et al. Ntire 2017 challenge on single image super-resolution: Methods and results [C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*. 2017: 114-125.
- [21] CHEN Y, LIU L, PHONEVILAY V, et al. Image super-resolution reconstruction based on feature map attention mechanism [J]. *Applied Intelligence*, 2021, 51(7): 4367-4380.
- [22] LIU Z, HUANG J, ZHU C, et al. Residual attention network using multi-channel dense connections for image super-resolution [J]. *Applied Intelligence*, 2021, 51(1): 85-99.
- [23] LIM B, SON S, KIM H, et al. Enhanced deep residual networks for single image super-resolution [C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*. 2017: 136-144.
- [24] LI F, CONG R, BAI H, et al. Deep interleaved network for image super-resolution with asymmetric co-attention [J]. *arXiv:2004.11814*, 2020.
- [25] DONG C, LOY C C, TANG X. Accelerating the super-resolution convolutional neural network [C] // *European Conference on Computer Vision*. Cham: Springer, 2016: 391-407.
- [26] KIM J, LEE J K, LEE K M. Deeply-recursive convolutional network for image super-resolution [C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2016: 1637-1645.



YU Jiuyang, born in 1963, master, second-level professor. His main research interests include chemical machinery process equipment control, oil and gas chemical pipeline robots.



DAI Yaonan, born in 1993, Ph.D, lecturer. His main research interests include chemical pipeline robot motion control and mobile robot image recognition.