

基于梯度引导的轻量化红外图像超分辨率重建

朱琨 沈良吉 姜文涛 叶超杰 黎中豪 魏巍 刘吉龙

Lightweight infrared image super-resolution reconstruction based on gradient guidance

ZHU Kun, SHEN Liangji, JIANG Wentao, YE Chaojie, LI Zhonghao, WEI Wei, LIU Jilong

引用本文:

朱琨, 沈良吉, 姜文涛, 等. 基于梯度引导的轻量化红外图像超分辨率重建[J]. 应用光学, 2025, 46(3): 695–702. DOI: 10.5768/JAO202546.0304002

ZHU Kun, SHEN Liangji, JIANG Wentao, et al. Lightweight infrared image super-resolution reconstruction based on gradient guidance[J]. Journal of Applied Optics, 2025, 46(3): 695–702. DOI: 10.5768/JAO202546.0304002

在线阅读 View online: <https://doi.org/10.5768/JAO202546.0304002>

您可能感兴趣的其他文章

Articles you may be interested in

基于轻量级网络的光纤环图像超分辨率重建

Super-resolution reconstruction of fiber optic coil image based on lightweight network

应用光学. 2022, 43(5): 913–920 <https://doi.org/10.5768/JAO202243.0502005>

基于多尺度双阶段网络的图像超分辨率重建

Image super-resolution reconstruction based on multi-scale two-stage network

应用光学. 2023, 44(6): 1343–1354 <https://doi.org/10.5768/JAO202344.0602004>

基于亚像素和梯度引导的光场图像超分辨率

Light field images super-resolution based on sub-pixel and gradient guide

应用光学. 2024, 45(5): 956–965 <https://doi.org/10.5768/JAO202445.0502003>

基于深度反向投影的感知增强超分辨率重建模型

Perceptually enhanced super-resolution reconstruction model based on deep back projection

应用光学. 2021, 42(4): 691–697, 716 <https://doi.org/10.5768/JAO202142.0402009>

多尺度融合超分辨率算法在无人机探测中的应用

Application of multi-scale fusion super-resolution algorithm in UAV detection

应用光学. 2021, 42(3): 462–473 <https://doi.org/10.5768/JAO202142.0302003>

基于二次引导滤波的红外图像增强算法及其FPGA实现

Infrared image enhancement algorithm based on secondary guided filtering and its implementation on FPGA

应用光学. 2023, 44(4): 777–785 <https://doi.org/10.5768/JAO202344.0402002>



关注微信公众号, 获得更多资讯信息

文章编号: 1002-2082 (2025) 03-0695-08

引用格式: 朱琨, 沈良吉, 姜文涛, 等. 基于梯度引导的轻量化红外图像超分辨率重建[J]. 应用光学, 2025, 46(3): 695-702.

ZHU Kun, SHEN Liangji, JIANG Wentao, et al. Lightweight infrared image super-resolution reconstruction based on gradient guidance[J]. Journal of Applied Optics, 2025, 46(3): 695-702.



在线阅读

基于梯度引导的轻量化红外图像超分辨率重建

朱 琨, 沈良吉, 姜文涛, 叶超杰, 黎中豪, 魏 巍, 刘吉龙

(西安应用光学研究所, 陕西 西安 710065)

摘 要: 现有的图像超分辨率网络大多针对可见光图像, 对红外图像超分辨率的研究较少, 且大多沿用可见光图像超分辨率。针对红外图像分辨率低、边缘模糊等问题, 提出了一种基于梯度引导的红外图像超分辨率重建网络。该网络充分利用低分辨率红外图像中的梯度信息, 将梯度图与提取出的特征相融合, 使最终生成的高分辨率图像边缘更加清晰、对比度更高。对比实验与消融实验的结果表明, 本文方法在红外图像超分辨率重建中优于其他对比方法, 生成的高分辨率图像质量更高。

关键词: 红外图像; 超分辨率; 深度学习; 轻量化

中图分类号: TN219; TP301

文献标志码: A

DOI: 10.5768/JAO202546.0304002

Lightweight infrared image super-resolution reconstruction based on gradient guidance

ZHU Kun, SHEN Liangji, JIANG Wentao, YE Chaojie, LI Zhonghao, WEI Wei, LIU Jilong

(Xi'an Institute of Applied Optics, Xi'an 710065, China)

Abstract: Existing image super-resolution networks are mostly designed for visible light images, with relatively fewer studies focusing on infrared image super-resolution, and most of them simply adopt methods from visible light image super-resolution. In response to the low resolution and blurred edges of infrared images, a gradient-guided infrared image super-resolution reconstruction network was proposed. The gradient information in low-resolution infrared images was fully utilized by the network, fusing the gradient map with the extracted features, thereby resulting in a high-resolution image with clearer edges and higher contrast. The experimental results of the comparative and ablation studies demonstrate that the proposed method outperforms other comparative methods in infrared image super-resolution reconstruction, generating high-resolution images of higher quality.

Key words: infrared images; super-resolution; deep learning; lightweight

引言

红外成像技术能够在无需接触的情况下进行温度测量和夜间监视, 在军事侦察、安全监控、医疗诊断和遥感探测等多个关键领域中发挥着重要作用。然而, 由于探测器像素尺寸的限制、光学系

统的衍射限制和环境噪声等因素, 红外图像往往分辨率较低, 细节不够清晰, 这限制了其在精确目标识别和复杂场景分析等高级应用中的有效性。通过硬件升级的方式来提高图像分辨率(例如增加红外焦平面阵列的像素密度), 通常需要复杂的制

收稿日期: 2024-11-01; 修回日期: 2025-03-24

基金项目: 国家自然科学基金 (62203353)

作者简介: 朱琨 (1998—), 男, 硕士研究生, 主要从事图像处理研究。E-mail: zhukun299@163.com

通信作者: 沈良吉 (1984—), 男, 硕士, 研究员, 主要从事红外成像及探测研究。E-mail: 1165015310@qq.com

造工艺和高昂的成本。相比之下,采用超分辨率算法来提高图像分辨率,可以有效地避免硬件制造的复杂性和成本问题。

图像超分辨率(super-resolution, SR)技术^[1]是一种通过软件算法将低分辨率图像(low resolution, LR)重建为高分辨率图像(high resolution, HR)的过程。根据算法原理,传统的超分辨率方法可以被分为三大类:插值法、重构法和学习法。插值法操作简单,处理速度快,然而,其在处理图像中像素突变区域时效果欠佳,容易产生模糊或锯齿效应。重构法在图像处理方面表现较好,但需要对图像有充分的先验知识,这限制了其适用性,尤其是在图像放大倍数较高时。学习法在恢复图像纹理和细节方面更为精细,相较于其他两种方法,其重建效果更为卓越。

近年来,在图像超分辨率领域,通过深度学习来进行超分辨率重建已成为主导研究方向。2014年,DONG C等研究者^[2]首次引入卷积神经网络以实现图像超分辨率,并提出了SRCNN(super-resolution convolutional neural network)模型,该模型通过3层神经网络提取图像特征,并通过激活函数进行非线性映射,以模拟传统超分辨率技术流程,实现图像重建。随后,该团队进一步提出了FSRCNN(fast super-resolution convolutional neural network)^[3]模型,直接以LR图像作为输入,并在网络末端以反卷积层进行上采样,最终生成HR图像。2016年,KIM J等研究者^[4]首次提出利用残差深度网络解决图像超分辨率问题,其核心理念在于低频信息在LR图像与HR图像间大致相同,通过学习HR图像与LR图像间的高频残差,可有效实现超分辨率重建。2017年,LEDIG C等研究者^[5]提出了SRGAN(super-resolution generative adversarial network),首次将GAN技术应用于图像超分辨率重建,在视觉效果上取得了显著成果。

近年来,各种深度学习方法在可见光图像超分辨率重建领域展现出了很好的性能,如IMDN(lightweight image super-resolution with information multi-distillation network)^[6]、BSRN(blueprint separable residual network for efficient image super-resolution)^[7]、MSID(multi-scale information distillation network for efficient image super-resolution)^[8]、OmniSR(omni aggregation networks for lightweight image super-resolution)^[9]、SAFMN(spatially-adaptive feature modulation for efficient image super-resolu-

tion)^[10]等。然而,红外图像在成像机制和灰度动态范围等方面与可见光图像存在显著差异。相比可见光图像,红外图像往往对比度低,边缘模糊,细节纹理不清晰,这使得从低分辨率图像中恢复出高分辨率图像的难度增加。因此,需要针对应用对算法进行优化。HE Z等人^[11]提出了具有多个感受场的级联深度网络,用于大规模红外图像超分辨率。ZOU Y等人^[12]提出基于跳跃连接的卷积神经网络的红外图像超分辨率网络,通过卷积层和反卷积层提取图像特征并重建红外图像。袁茜琳等人^[13]提出了一种基于深度卷积神经网络的红外图像超分辨率重建方法,改进了残差块,并结合了注意力机制。但这些方法没有充分关注到红外图像中的高频信息,对边缘模糊的处理效果并不理想。

对此,根据红外图像的特性,本文构建了一种基于梯度引导的超分辨率网络模型,充分利用LR红外图像中的梯度信息,实现高质量红外图像SR重建。本文的主要贡献可以总结为以下两个方面:一是构建了一个梯度图生成模块,此模块旨在增强网络学习到的梯度信息,更有利于恢复红外图像中的边缘与细节信息;二是构建了一种适合本文网络的损失函数,该损失函数在L1损失的基础上加入了梯度图损失,网络在训练过程中同时关注图像中的高频信息,使SR图像在细节上更加接近HR图像。

1 原理及网络结构

1.1 图像超分辨率重建原理

在获取红外图像时,原始场景的高分辨率图像会经历一系列的降质退化过程,例如原始场景和探测器之间的相对运动,光学系统衍射、像差以及离焦等造成的模糊,红外探测器阵列的降采样以及各种噪声的干扰等。高分辨率图像的退化过程可以通过式(1)来进行表示:

$$I_{LR} = DBI_{HR} + n \quad (1)$$

式中: D 表示下采样; B 表示模糊干扰; n 表示加性噪声; I_{LR} 表示低分辨率图像; I_{HR} 表示高分辨率图像。图像退化过程中的模糊干扰会使图像对比度变差以及清晰度变低,下采样会造成图像细节的损失,噪声会使图像的质量变差。

图像的超分辨率重建实际上是图像退化的逆过程^[14]。基于深度学习的超分辨率方法是通过学

习 LR 与 HR 之间的映射关系, 训练网络模型, 通过此网络模型对 LR 进行超分辨率重建获得 SR 图像。为了处理图像重建中的模糊干扰和噪声, 可将数据集中的高分辨率图像进行模糊、添加噪声和下采样等处理, 生成对应的低分辨率图像, 从而使得训练出来的网络模型能更好地处理模糊干扰和噪声。针对下采样, 则是在网络中添加上采样

模块, 增加图像分辨率。

1.2 网络结构

本文提出的网络整体结构如图 1 所示, 主要分为 4 个模块: 浅层特征提取 (shallow feature extraction) 模块、深层特征提取 (deep feature extraction) 模块^[15]、梯度图生成 (gradient map generation, GMG) 模块和重建 (reconstruction) 模块。




图 1 红外图像超分辨率重建网络结构

Fig. 1 Structure diagram of infrared image super-resolution reconstruction network

浅层特征提取: 该模块包含一个 3×3 卷积层和一个 GELU (Gaussian error linear units) 激活函数, 对输入的 LR 红外图像进行初步特征提取, 捕捉图像中的基本纹理和边缘信息, 为后续的特征提取和重建过程提供基础^[16]。此模块可以通过式 (2) 表示:

$$F_{SF} = E_{SF}(I_{LR}) \quad (2)$$

式中: F_{SF} 为浅层特征提取出的特征图; E_{SF} 表示浅层特征提取模块; I_{LR} 为输入的低分辨率红外图像。

深层特征提取: 在浅层特征提取的基础上, 网络进一步通过多个相同的残差块 (residual block, RB)^[17] 进行深层特征提取。残差块能够学习到输入与输出之间的残差映射, 而不是直接学习映射本身, 这使得网络可以更有效地捕捉到红外图像的高频细节, 从而在超分辨率重建中恢复更精细的纹理和细节。并且, 残差块的设计允许网络在不同层之间传递信息, 这有助于网络更好地学习到图像的多层次特征, 提升超分辨率重建的灵活性和准确性。如图 1(b) 所示, 本文采用的 RB 移除了不适合 SR 这种低级计算机视觉任务的批量归一化 (batch normalization, BN) 层来减少计算资源损耗。并且, 移除 BN 层可以增加网络模型的表现

力。此模块可以通过下列表达式来表示:

$$F_i = E_{RB}(F_{i-1}), i \in \{1, 2, \dots, n\} \quad (3)$$

$$F_{DF} = F_n \quad (4)$$

式中: F_i 表示第 i 个 RB 提取的特征图; E_{RB} 表示 RB 特征提取; F_{DF} 表示深度特征提取模块最终提取出的特征图。

梯度图生成: 如图 1(c) 所示, 由两个卷积层加两个 GELU 激活函数组成。此模块将提取出红外图像中的梯度信息, 将提取出来的梯度信息与提取出来的深度特征进行融合, 使最终生成的高分辨率图像的细节更加清晰。为了更直观地观察梯度图中的细节信息, 对图 1 中生成的梯度图进行了灰度反转。GELU 激活函数通过引入非线性变换增强了网络模型的表达能力, 同时, 作为一个平滑函数, GELU 拥有连续的导数, 避免了梯度截断问题, 确保了梯度的稳定传播, 特别是在 0 附近比 ReLU 更加平滑, 这有助于训练过程中的快速收敛。此外, GELU 的输出在输入接近 0 时呈现出类似高斯分布的特性, 这不仅提升了模型的泛化能力, 还使得网络能够更好地适应不同的数据分布。此模块可以通过式 (5) 表示:

$$M = G_{GM}(F_{DF}) \quad (5)$$

式中: M 表示生成的梯度图; G_{GM} 表示梯度图生成

模块; F_{DF} 表示之前深度特征提取模块所提取出的特征图。

重建: 此模块由一个上采样层和一个卷积层组成, 由图1可以看出, 生成的深度特征图与生成的梯度图融合后, 经过一个卷积层与浅层特征相加得到最终的特征图, 重建模块将特征图中的特征信息进行融合和上采样, 得到最终的高分辨率红外图像。此模块可以通过式(6)表示:

$$I_{SR} = R_{UP}(F_{final}) \quad (6)$$

式中: I_{SR} 表示生成的高分辨率红外图像; R_{UP} 表示重建模块; F_{final} 表示输入给重建模块的特征图。

综上所述, 本文所提出的基于梯度引导的轻量化红外图像超分辨率网络利用低分辨率图像中的梯度信息, 将梯度图与特征图融合, 生成边缘更清晰锐利的高分辨率图像。

1.3 损失函数

本文的损失函数由两部分损失加权组成。其中, 一部分是网络生成的 SR 图像与 HR 图像之间的平均绝对值误差。另一部分是梯度图损失, Sobel 算子在计算边缘时, 同时考虑了像素点上下、左右邻点灰度加权差, 对噪声具有平滑作用, 能很好地消除噪声的影响, 因此通过 Sobel 滤波器提取 HR 图像的梯度图作为真实值, 网络中 GMG 模块生成的梯度图作为预测值, 将预测值与真实值之间的平均绝对值误差作为梯度图损失。

本文损失函数可以通过式(7)表示:

$$L_t = L_1 + \alpha L_G \quad (7)$$

式中: L_t 表示本文网络训练所采用的损失函数; L_1 表示 SR 图像与 HR 图像之间的平均绝对值误差; L_G 表示梯度图损失; 依据本文消融实验结果, α 取 0.01。运用本文损失函数进行网络训练, 可使 SR 图像中的边缘更加清晰, 对比度更高。

2 实验结果与分析

2.1 实验说明

实验中采用 2 个数据集进行对比实验, 数据集 1 来自文献[18]中介绍的数据集, 该数据集用于第 1 次和第 2 次热图像超分辨率(thermal image super-resolution, TISR)挑战。该数据集由 3 台不同的热像仪在不同照明条件(即白天、黑夜、室内、室外)、分辨率(120×160 像素、240×320 像素、480×640 像素)和对象类型(即汽车、人物、植被、建筑物)下使用 3 台不同的热像仪采集的热图像组

成。取其中 851 张作为训练集, 100 张作为验证集, 50 张作为测试集。

数据集 2 为自采集数据集, 使用烟台艾睿光电科技有限公司的 LGC6122 非制冷红外相机进行采集, 图片大小为 640×512 像素, 取其中 900 张作为训练集, 100 张作为验证集, 100 张作为测试集。图2是采集到的部分图像展示。



图2 数据集 2 的部分图像

Fig. 2 Part of images from dataset 2

所有模型都在 PyTorch 框架中实现, 使用单个 NVIDIA GeForce RTX 3050 GPU 进行训练。本文网络模型训练的损失函数采用上文中提出的 L_t 损失, 初始学习率设置为 0.0001, 每 2×10^5 次反向传播迭代减少一半, 采用 Adam 作为优化器, batch size 设置为 16, epoch 为 500。

在本文中, 我们使用峰值信噪比(peak signal-to-noise ratio, PSNR)^[19]和结构相似性(structural similarity index, SSIM)^[20]作为评价指标。PSNR 和 SSIM 的值越高, 表明生成的 SR 图像与参考的高分辨率图像的相似度越高。此外, 所有实验结果都是每个测试数据集中所有图像的平均值。

2.2 对比实验

先采用数据集 1 进行对比实验, 其中对比的可见光图像领域超分辨率方法包括 SRCNN、FSRCNN、IMDN、BSRN、MSID、OmniSR、SAFMN, 对比的红外图像领域超分辨率方法为文献[13]和文献[16]中的方法, 但其并不是轻量化模型, 因此对其网络进行一定的简化。实验结果如表1所示, 通过与现有超分辨率方法比较, 表明本文方法在 PSNR 和 SSIM 上均展现出优秀的性能。综合所有指标, 本文方法在红外图像超分辨率重建中明显优于其他超分辨率方法。

表 1 对比实验结果(数据集 1)
Table 1 Results of comparative experiment (dataset 1)

Method	Scale	PSNR	SSIM	Params/K	FLOPs/G
SRCNN	×2	30.23	0.8243	57.3	17.57
FSRCNN		34.62	0.8734	12.8	2.02
IMDN		35.00	0.8948	694.4	52.95
MSID		34.10	0.8648	375.5	27.34
BSRN		35.56	0.9096	331.6	24.02
Omni-SR		35.65	0.9082	771.7	57.48
SAFMN		37.19	0.9373	226.7	17.16
YUAN		38.96	0.9627	81.1	6.25
SHI		39.46	0.9675	255.1	21.83
Ours		39.76	0.9699	111.4	8.54
SRCNN	×4	29.73	0.7086	57.3	17.57
FSRCNN		31.10	0.7336	12.8	1.55
IMDN		33.07	0.7937	715.2	13.64
MSID		31.73	0.6834	393.6	7.18
BSRN		33.16	0.8086	352.4	6.40
Omni-SR		33.26	0.8043	792.5	14.77
SAFMN		33.42	0.7864	238.4	4.51
YUAN		35.62	0.8974	81.1	6.25
SHI		35.90	0.9047	255.1	30.92
Ours		35.91	0.9051	111.3	8.54

在主观评价层面,本文方法所生成的超分辨率图像质量明显优于其他方法,图像中人物轮廓更加清晰,辨识度更高,失真与伪影更小,如

图 3 与图 4。此外,与其他方法相比,本文方法生成的图像边缘更加锐利,对比度更高,如图 5 与图 6。




图 3 场景 1 下不同超分辨率方法结果对比(尺度因子为 2)

Fig. 3 Comparison of results for different super-resolution methods under scenario 1 (with scale factor of 2)




图 4 场景 2 下不同超分辨率方法结果对比(尺度因子为 4)

Fig. 4 Comparison of results for different super-resolution methods under scenario 2 (with scale factor of 4)




图5 场景3下不同超分辨率方法结果对比(尺度因子为2)

Fig. 5 Comparison of results for different super-resolution methods under scenario 3 (with scale factor of 2)




图6 场景4下不同超分辨率方法结果对比(尺度因子为4)

Fig. 6 Comparison of results for different super-resolution methods under scenario 4 (with scale factor of 4)

综上所述,在客观与主观评价层面,本文方法在红外图像超分辨率重建领域中展现出更好的性能,相较其他超分辨率方法,所生成的图像更适合用于目标识别与检测等高级计算机视觉任务。

为验证本文方法的泛化性,再采用数据集2进行对比,对比方法选择为BSRN、SAFMN、YUAN、SHI。表2为实验结果,图7和图8为对比结果,可以看出,在不同的数据集下,本文方法依旧优于其他方法。

表2 对比实验结果(数据集2)

Table 2 Results of comparative experiment (dataset 2)

Methods	Scale	PSNR	SSIM	Params/K	FLOPs/G
BSRN	×2	33.65	0.7640	331.6	24.02
SAFMN		34.61	0.8301	226.7	17.16
YUAN		35.18	0.8562	81.1	6.25
SHI		35.57	0.8725	255.1	21.83
Ours		35.45	0.8726	111.4	8.54
BSRN	×4	33.95	0.7675	352.4	6.40
SAFMN		32.99	0.7182	238.4	4.51
YUAN		33.96	0.7714	81.1	6.25
SHI		34.03	0.7813	255.1	30.92
Ours		34.05	0.7762	111.3	8.54



图7 场景5下不同超分辨率方法结果对比(尺度因子为2)
Fig. 7 Comparison of results for different super-resolution methods under scenario 5 (with scale factor of 2)




图8 场景6下不同超分辨率方法结果对比(尺度因子为4)
Fig. 8 Comparison of results for different super-resolution methods under scenario 6 (with scale factor of 4)

2.3 消融实验

为验证本文方法中 GMG 模块、残差块组、损失函数中 α 的有效性, 设定了 6 种测试模型, 采用数据集 1 进行消融实验。

从表 3 的实验结果中可以看出, RB 数目和 α

相同时, 含有 GMG 模块的模型明显优于无 GMG 模块的模型; 其他条件相同时, RB 数目越多, 实验结果越好; 相同其他条件下, α 在 0.01 时网络性能更优。从图 9 可以看出, 包含 GMG 模块的M₂模型生成的图像边缘失真程度更小, 更接近高分辨率红外图像。

表 3 各模型的客观评价指标比较
Table 3 Comparison of objective evaluation metrics for various models

Methods	Scale	GMG	RB	α	PSNR	SSIM
M ₁	×2		5	0.01	36.77	0.9325
M ₂		√	5	0.01	39.13	0.9655
M ₃		√	5	0.1	38.72	0.9619
M ₄		√	5	0.001	39.04	0.9637
M ₅		√	10	0.01	39.31	0.9665
M ₆		√	15	0.01	39.76	0.9699




图 9 同场景下M₁模型与M₂模型结果对比
Fig. 9 Comparison of M₁ model and M₂ results under the same scenario

3 结论

本文提出了一种基于梯度引导的轻量化红外图像超分辨率重建网络, 该网络添加了梯度图生成模块, 在深层特征提取后融合梯度图, 再进行重建, 使网络充分学习低分辨率红外图像中的高频信息, 生成的高分辨率图像细节更加清晰, 边缘更锐利, 对比度更高。与其他方法对比, 本文方法在客观与主观评价两个方面均展现出更高的性能。

参考文献:

[1] BAKER S, KANADE T. Limits on super resolution and how to break them[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2002, 24(9): 1167-1183.

[2] DONG C, LOY C C, HE K, et al. Image super-resolution using deep convolutional networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2016, 38(2): 295-307.

[3] DONG C, LOY C C, TANG X, et al. Accelerating the su-

per-resolution convolutional neural network[C]// European Conference on Computer Vision. Berlin: Springer, 2016: 391-407.

[4] KIM J, LEE J K, LEE K M, et al. Accurate image super-resolution using very deep convolutional networks[C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). New York: IEEE, 2016: 1646-1654.

[5] LEDIG C, THEIS L, HUSZAR F, et al. Photo-realistic single image super-resolution using a generative adversarial network[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). New York: IEEE, 2017: 105-114.

[6] HUI Z, GAO X, YANG Y, et al. Lightweight image super-resolution with information multi-distillation network[C]//Proceedings of the 27th ACM International Conference on Multimedia. New York: ACM ,2019: 2024-2032.

[7] LI Z, LIU Y, CHEN X, et al. Blueprint separable residual network for efficient image super-resolution[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans: IEEE, 2022: 833-843.

[8] HU Y, HUANG Y, ZHANG K. Multi-scale information distillation network for efficient image super-resolution[J]. Knowledge-Based Systems, 2023, 275: 110718.

[9] WANG H, CHEN X, NI B, et al. Omni aggregation networks for lightweight image super-resolution[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver: IEEE, 2023:

- 22378-22387.
- [10] SUN L, DONG J, TANG J, et al. Spatially-adaptive feature modulation for efficient image super-resolution[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Paris: IEEE, 2023: 13190-13199.
- [11] HE Z, TANG S, YANG J, et al. Cascaded deep networks with multiple receptive fields for infrared image super-resolution[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2018, 29(8): 2310-2322.
- [12] ZOU Y, ZHANG L, LIU C, et al. Super-resolution reconstruction of infrared images based on a convolutional neural network with skip connections[J]. *Optics and Lasers in Engineering*, 2021, 146: 106717.
- [13] 袁茜琳, 张宝辉, 张倩, 等. 基于深度卷积神经网络的红外图像超分辨率重建技术[J]. *红外技术*, 2023, 45(5): 498-505.
- YUAN Xilin, ZHANG Baohui, ZHANG Qian, et al. Infrared images with super-resolution based on deep convolutional neural network[J]. *Infrared Technology*, 2023, 45(5): 498-505.
- [14] 白皓, 白廷柱. 基于深度残差神经网络的红外图像超分辨率重构算法[J]. *红外技术*, 2024, 46(2): 176-182.
- BAI Hao, BAI Tingzhu. Infrared image super-resolution reconstruction algorithm based on deep residual neural network[J]. *Infrared Technology*, 2024, 46(2): 176-182.
- [15] 蒋梦洁, 钱文华, 徐丹, 等. 残差密集结构的东巴画渐进式重建[J]. *中国图象图形学报*, 2022, 27(4): 1084-1096.
- JIANG Mengjie, QIAN Wenhua, XU Dan, et al. Gradual model reconstruction of Dongba painting based on residual dense structure[J]. *Journal of Image and Graphics*, 2022, 27(4): 1084-1096.
- [16] 师奕峰, 陈楠, 朱芳, 等. 面向真实场景的单帧红外图像超分辨率重建[J]. *红外技术*, 2024, 46(4): 427-436.
- SHI Yifeng, CHEN Nan, ZHU Fang, et al. Single-frame infrared image super-resolution reconstruction for real scenes[J]. *Infrared Technology*, 2024, 46(4): 427-436.
- [17] 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. Honolulu: IEEE, 2017: 136-144.
- [18] RIVADENEIRA R E, SAPP A D, VINTIMILLA B X. Thermal image super-resolution: a novel architecture and dataset[C]//VISIGRAPP (4: VISAPP). Valletta: Springer, 2020: 111-119.
- [19] SHEIKH H R, SABIR M F, BOVIK A C. A statistical evaluation of recent full reference image quality assessment algorithms[J]. *IEEE Transactions on Image Processing*, 2006, 15(11): 3440-3451.
- [20] WANG Z, BOVIK A C, SHEIKH H R, et al. Image quality assessment: from error visibility to structural similarity[J]. *IEEE Transactions on Image Processing*, 2004, 13(4): 600-612.