

## 并行多特征提取网络的红外图像增强方法

庞忠祥 刘勰 刘桂华 龚浪军 周晗 罗洪伟

### Parallel multifeature extracting network for infrared image enhancement

Pang Zhongxiang, Liu Xie, Liu Guihua, Gong Yinjun, Zhou Han, Luo Hongwei

在线阅读 View online: <https://doi.org/10.3788/IRLA20210957>

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 基于多形态红外特征与深度学习的实时驾驶员疲劳检测

Real-time driver fatigue detection based on morphology infrared features and deep learning

红外与激光工程. 2018, 47(2): 203009 <https://doi.org/10.3788/IRLA201847.0203009>

#### 一种改进的红外图像自适应增强方法

An improved infrared image adaptive enhancement method

红外与激光工程. 2021, 50(11): 20210086 <https://doi.org/10.3788/IRLA20210086>

#### 多输入融合对抗网络的水下图像增强

Multi-input fusion adversarial network for underwater image enhancement

红外与激光工程. 2020, 49(5): 20200015 <https://doi.org/10.3788/IRLA20200015>

#### 深度学习的MPCANet火灾图像识别模型设计

Design of MPCANet fire image recognition model for deep learning

红外与激光工程. 2018, 47(2): 203006 <https://doi.org/10.3788/IRLA201847.0203006>

#### 基于深度学习的序列图像深度估计技术

Depth estimation technique of sequence image based on deep learning

红外与激光工程. 2019, 48(S2): 134 <https://doi.org/10.3788/IRLA201948.S226002>

#### 基于临近时空帧间信息的空间目标图像增强方法

Image enhancement for space object based on information between adjacent spatial-temporal frames

红外与激光工程. 2019, 48(S1): 193 <https://doi.org/10.3788/IRLA201948.S128004>

## 并行多特征提取网络的红外图像增强方法

庞忠祥<sup>1</sup>, 刘 颀<sup>2</sup>, 刘桂华<sup>1</sup>, 龚浪军<sup>1</sup>, 周 晗<sup>2</sup>, 罗洪伟<sup>2</sup>

(1. 西南科技大学 信息工程学院, 四川 绵阳 621000;  
2. 深圳市朗驰欣创科技股份有限公司, 广东 深圳 518000)

**摘要:** 为解决低质量红外图像细节模糊、对比度低等问题, 提出了并行多特征提取网络的红外图像增强方法, 设计了结构特征映射网络和双尺度特征提取网络。结构特征映射网络用于建立全局结构特征权重, 以保持原始图像的空间结构信息。双尺度特征提取网络采用多尺度卷积层和融合多空洞卷积的注意力, 增强网络对上下文信息的关注度, 提升网络对感兴趣区域的特征提取能力, 同时学习不同尺度的特征信息, 完成双尺度间信息的交换, 生成目标增强映射, 实现目标区域细节纹理自适应增强。实验证明, 所提方法能有效提高对比度, 避免过增强, 丰富图像细节纹理, 减少伪影和光晕现象, 在 BSD200 数据集上的 PSNR 与 SSIM 较典型的传统方法和深度学习方法分别提升了约 37.35%、2.1% 与 25.94%、3.15%, 在真实红外数据集上分别提升了约 30.62%、1.04% 与 24.83%、2.08%, 且对不同对比度因子的低质量图像, 文中方法也具有较好的增强效果。

**关键词:** 红外图像; 图像增强; 深度学习; 空洞卷积; 注意力机制

**中图分类号:** TP391 **文献标志码:** A **DOI:** 10.3788/IRLA20210957

## Parallel multifeature extracting network for infrared image enhancement

Pang Zhongxiang<sup>1</sup>, Liu Xie<sup>2</sup>, Liu Guihua<sup>1</sup>, Gong Yinjun<sup>1</sup>, Zhou Han<sup>2</sup>, Luo Hongwei<sup>2</sup>

(1. School of Information Engineering, Southwest University of Science and Technology, Mianyang 621000, China;  
2. Shenzhen Launch Digital Technology Co., Ltd, Shenzhen 518000, China)

**Abstract:** To solve the problems of fuzzy details and low contrast of low-quality infrared images, a parallel multifeature extraction network for infrared image enhancement is proposed, and a structural feature mapping network and a two-scale feature extraction network are designed. The structural feature mapping network is used to establish the global structural feature weight to maintain the spatial structure information of the original images. The two-scale feature extraction network using multiscale convolutional layers and the attention mechanism fused dilated convolutions is applied to enhance the attention on contextual information, improve the feature extraction capability for regions of interest, and simultaneously learn feature information of different scales, complete the exchange of information of the two scales, and then generate a target enhancement map to achieve adaptive enhancement of detailed texture of target areas. Experiments have proven that the proposed method can effectively improve contrast, avoid overenhancement, enrich image details and textures, and reduce artifacts and halos. Compared with typical traditional methods and deep learning methods, the PSNR and SSIM on the

收稿日期:2021-12-13; 修订日期:2022-01-13

基金项目:国家自然科学基金(11602292);四川省科技支撑计划(2021YFG0380)

作者简介:庞忠祥,男,硕士生,主要从事深度学习、图像处理以及计算机视觉等方面的研究。

导师简介:刘桂华,女,教授,博士生导师,博士,研究方向为机器人场景智能感知、图像处理、机器视觉以及 FPGA 集成电路设计等。

BSD200 dataset are increased by approximately 37.35%, 2.1% and 25.94%, 3.15%, and increased by approximately 30.62%, 1.04% and 24.83%, 2.08% on real infrared images. The proposed method also has good generalization performance on low-quality images with different contrast factors as well.

**Key words:** infrared image; image enhancement; deep learning; dilated convolution; attention mechanism

## 0 引言

红外图像是仅反映目标物体红外辐射能量的灰度图像,其受环境干扰较小,已在野外侦察、航空航天及居家看护等军事和民生领域发挥着不可替代的作用<sup>[1]</sup>。然而,红外波段的辐射波长比可见光长,导致红外图像的空间分辨率比可见光低,图像细节信息不丰富<sup>[2]</sup>。此外,受红外成像器件本身的缺陷和外部环境的影响,红外图像通常呈现低对比度,目标边缘不清晰和人眼视觉效果不佳等缺点,很难完成目标定位识别、人体姿态估计等机器视觉任务<sup>[3]</sup>。因此,为了得到适合人眼观察或机器识别的高质量红外图像,有必要对红外图像增强,提高图像对比度、丰富细节特征,区分背景和目标,从而提高上述任务的效率和精度<sup>[4]</sup>。

深度学习流行前,针对红外图像增强任务,主要采用基于灰度变换的直方图均衡化 (Histogram Equalization, HE)<sup>[5]</sup>和基于物理模型的 Retinex 算法<sup>[6]</sup>。HE 在低照度图像增强任务上取得了良好的效果。然而,针对低对比度红外图像增强,HE 通常会加大红外图像的各种噪声,局部区域呈现过增强,产生非常差的结果<sup>[7]</sup>。为了解决这个问题,出现了许多基于直方图均衡化的变体,如 DPHE<sup>[8]</sup>、CLAHE<sup>[9]</sup>等。这些方法虽能够在一定程度上提高对比度和抑制噪声,但会产生光晕现象,并造成边缘模糊,降低人眼视觉效果。模仿人眼视觉系统的 Retinex 方法在处理红外图像时,能更进一步地保留细节信息,丰富图像纹理,然而其依赖参数选择,模型泛化能力差,不能自适应地优化图像。

深度学习广泛应用于计算机视觉领域后,Choi 等人<sup>[3]</sup>受 SRCNN 启发,首次设计了一个相对浅的卷积神经网络 TEN 用于热图像增强。Lee 等人<sup>[10]</sup>提出了 TIECNN 用于红外图像增强,它结合亮度域和残差学习,以提高网络性能和收敛速度。Kuang 等人<sup>[11]</sup>在卷积神经网络结构中加入生成对抗网络,提出了 IE-GAN 用于单帧红外图像增强,能有效抑制背景噪声,

并增强图像对比度和细节,但需要设计相对复杂的损失函数。He 等人<sup>[12]</sup>提出了一种具有多个感受野 (CDN\_MRF) 的深度级联网络架构,以解决具有大比例因子的单帧红外图像超分辨率问题。虽然上述基于 CNN 的方法对红外图像增强做出了贡献,但这些方法在增强对比度的同时会加重图像伪影,造成目标边缘模糊及产生光晕,不能充分展现图像的边缘和纹理。由此,提出了端到端学习的并行多特征提取网络红外图像增强方法解决以上问题。一方面,设计了结构特征权重映射块,用于生成全局特征权重,以保留原始图像的空间结构特征;另一方面,构造了双尺度特征提取块对不同尺度的特征图进行深度特征提取,学习图像的多特征信息,捕获细节和纹理。最后,解码模块对已提取的特征和初始权重进行融合,提升对比度,丰富细节纹理,生成高质量的增强红外图像。

## 1 并行多特征提取网络

### 1.1 并行多特征提取网络

并行多特征提取网络的整体框架如图 1 所示,由 3 条不同尺度的卷积路径组成,分别为 Path1(128×128)、Path2(64×64)和 Path3(32×32)。Path1 为结构特征权重映射块,直接对原始输入图像进行操作,构建全局特征权重。两种不同尺度的特征提取路径 Path2、Path3 构成的双尺度特征提取块,学习深层的纹理细节,完成多尺度特征提取、融合,捕获图像中需要增强的目标信息。解码器 (Decoder) 整合多路径特征信息,生成高质量的红外图像。

### 1.2 结构特征权重映射块

为保持原始图像的整体结构,避免图像局部区域过增强,设计了结构特征权重映射块 (Structural Feature Weight, SFW),以学习低质量红外图像的全局信息,生成全局结构特征映射。如图 1 中 Path1 所示,该路由 4 个卷积块 (Conv-BN-PReLU)、全局平均池化 (Global Average Pooling, GAP) 和 Mish 激活函数组成。表 1 所示为文中提出的结构特征权重映射块参



制背景,进而提高目标在图像中的表现度。图 3 所示为注意力模块的实现流程,首先前层输入经 GAP 后,得到多通道全局平均信息;再经过 Conv、LeakyReLU 和 Sigmoid 操作后,与前层输入相乘,输出注意力加权特征图  $\hat{O}$ ,  $\hat{O}$  可表示为公式 (4):

$$\hat{O} = \hat{A} \otimes S(\text{Conv}(L(\text{Conv}(Y_{GAP}(\hat{A})))))) \quad (4)$$

式中:  $\hat{A}$  表示输入特征图;  $\otimes$  表示元素点乘;  $S$  代表 Sigmoid 激活函数,用来将权重压缩至 0~1;  $L$  代表 LeakyReLU 激活函数。




图 3 注意力模块

Fig.3 Architecture of attention block

此外,扩大卷积感受野有助于网络提取更多的信息,目前空洞卷积技术在扩大感受野方面具有广泛的应用,在图像去噪、图像增强等任务上有很好的效果<sup>[14]</sup>。使用扩张因子为  $f(f=2)$  和扩张卷积层数为  $N$  的空洞卷积,其感受野  $R_f$  可以表示为公式 (5):

$$R_f = (4N + 1) \times (4N + 1) \quad (5)$$

Path3 采用  $f=2, N=3$  的空洞卷积块,  $R_f$  大小为  $13 \times 13$ , 相当于普通的 6 层卷积, 这样既增加了网络对特征图上下文信息的关注度, 还压缩了复杂的计算量。为避免网络加深而导致模型训练困难、梯度消失或爆炸的问题, 在双尺度特征提取块中加入了多级残差结构。如图 1 所示, 分别将下采样得到的双尺度特征信息通过元素相加的方式与下层特性信息融合, 多级残差结构充分利用前层所提取的特征, 使正向传播的特征得以保留, 有益于网络的收敛。最后, Path3 所

提取的高维特征信息经 deconv 上采样后与 Path2 提取到的特征相加, 实现双尺度多特征的融合。由此, 双尺度特征提取网络块的整体参数设置如表 2 所示。融合结果  $P_{23} \in \mathbb{R}^{96 \times 64 \times 64}$  可由公式 (6) 表示:

$$P_{23} = \hat{E} + \hat{U} \quad (6)$$

式中:  $\hat{E} \in \mathbb{R}^{96 \times 64 \times 64}$  为 Path2 提取的特征;  $\hat{U} \in \mathbb{R}^{96 \times 64 \times 64}$  为 Path3 提取的特征。

表 2 双尺度特征提取块参数

Tab.2 Parameters of TSFEB

Path	Type	$K$	$s$	$p$	$c$
2_1	Conv	3	2	1	48
2_2	Conv	1	1	0	32
2_3	MS-FE	/	/	/	62
2_4	MS-FE	/	/	/	96
2_5	Conv	3	1	1	96
3_1	Conv	4	4	0	96
3_2	Conv	1	1	0	64
3_3	AB	/	/	/	64
3_4	Conv	3	1	2	64
3_5	Conv	3	1	2	64
3_6	Conv	3	1	2	64
3_7	AB	/	/	/	64
3_8	deconv	4	2	1	96

### 1.4 解码块

如图 4 所示的解码块用于恢复高质量的红外图像。首先, 融合的双尺度特征图  $P_{23}$  经卷积和反卷积操作后, 特征图扩张为  $128 \times 128$ , 实现特征升维。其次, 将结构特征权重  $F_o$  点乘各像素点, 以保持原始图像的结构特征, 避免局部区域过增强。最后, 特征图经通道压缩卷积生成高质量的增强图像。




图 4 解码块结构

Fig.4 Architecture of decoder block

### 1.5 损失函数

红外图像可分解为图像空间结构权重和目标增强特征的乘积,其客观评价指标主要为峰值信噪比 (PSNR) 和结构相似性 (SSIM),通常采用均绝对误差 (Mean Absolute Error, MAE)、均方差 (Mean Square Error, MSE) 或 MSE 与感知损失、生成对抗损失相结合等作为损失函数,以取得有意义的评价结果。考虑计算量、时间成本等因素,文中选择 MSE 对重构图像和标签图像的各个像素点计算,损失函数可表示为公式 (7):

$$\begin{aligned}
 L_{MSE} &= \frac{1}{H \times W} \sum_{j=1}^H \sum_{i=1}^W \|O(i, j) - I(i, j)\|_2^2 = \\
 &= \frac{1}{H \times W} \|\check{G} \cdot \check{A} - G \cdot E\|_2^2 = \\
 &= \frac{1}{H \times W} \|(\check{G}, G) \cdot (\check{A}, E)\|_2^2 = \\
 &= \frac{1}{H \times W} \|\check{R} \cdot \hat{R}\|_2^2
 \end{aligned} \tag{7}$$

式中:  $O(i, j)$  与  $I(i, j)$  分别表示重构图像和标签高质量图像;  $H$  和  $W$  为图像的高度和宽度;  $\check{G}$  表示网络结构

特征权重;  $G$  表示理想特征权重;  $\hat{E}$  和  $E$  分别表示网络增强映射和理想增强映射;  $\hat{R}$  表示  $\check{G}$  和  $G$  的差值,  $\check{R}$  表示  $\hat{E}$  和  $E$  的差值。

## 2 实验验证

### 2.1 数据集建立

由于缺乏大规模多场景高低质量红外图像对,而低对比度化的灰度图像表现出相似的红外图像特性,如与红外图像有相近的均值和方差,且整体图像不够清晰,图像中目标与背景边界模糊,现有经典方法普遍对预处理后的可见光图像进行训练。文中实验从目标检测数据集 ImageNet<sup>[15]</sup> 中随机选择部分图像,经滑窗裁剪的方式,生成 85 347 张  $128 \times 128$  大小的图像块用于训练。首先,对这些图像块进行灰度化 (Grayscale) 处理,获得高质量灰度图片;其次,采用对比度因子  $\alpha \in [0.5, 0.51]$  范围的随机对比度函数对高质量灰度图像低对比度化,获得相应的低质量灰度图片。部分训练样本如图 5 所示,第一行为高质量标签图像,第二行为低质量输入图像。



图 5 部分训练样本对

Fig.5 Part of the training sample pairs

为验证所设计网络的性能质量和视觉效果,使用 BSD200<sup>[16]</sup>、TNO<sup>[17]</sup> 和 OTCBVS<sup>[18]</sup> 数据集进行评价。常用于图像分割、图像超分辨等任务的公共数据集 BSD200 经灰度化,低对比度化处理后,用于图像质量的客观评价。

TNO 和 OTCBVS 真实红外图像数据集缺乏对应

的低质量图像,因此采用低对比度化的数据作为相应的低质量图像,以实现真实红外图像的客观评价和视觉效果对比。测试数据均调整为  $256 \times 256$  分辨率。

### 2.2 参数设置

文中网络是在运行环境为 Ubuntu 20.04 操作系统和 Pytorch1.5.1 框架上搭建的。实验所用台式机使

用了 1 块 Inter Xeon E5-2620 v4 CPU 和 1 块 Nvidia TITAN XP 12 G GPU。批次大小为 64, 网络优化器选择 Adam, 初始学习率为  $1e-3$ , 采用余弦学习率衰减策略, 经 300 个 epoch 后, 学习率降至  $1e-6$ 。

### 2.3 评价指标

对于图像增强任务, 通常采用峰值信噪比 (PSNR) 和结构相似性 (SSIM) 定量评价网络模型的性能。PSNR 是基于对应像素点之间的误差, 其值越大, 表示图像质量越好。PSNR 计算方法如公式 (8) 所示:

$$PSNR = 10 \times \lg \left( \frac{(2^b - 1)^2}{MSE} \right) \quad (8)$$

式中:  $b$  为 8; MSE 计算如公式 (2)。结构相似性 (SSIM) 是衡量 2 幅图片相似度的指标, SSIM 值越接近 1, 表

示 2 张图片越相似, 输出图片更吻合真实标签图片, 其计算公式如公式 (9) 所示:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_x\sigma_y + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (9)$$

式中:  $\mu_x$  和  $\mu_y$  分别为原始高增益图像和输出图像的平均灰度值;  $\sigma_x$  和  $\sigma_y$  为标准差;  $C_1$  和  $C_2$  为常数。

### 2.4 实验与分析

文中方法以平均 PSNR 和平均 SSIM 作为客观评价指标, 与红外图像增强的典型传统方法 HE<sup>[5]</sup>、CLAHE<sup>[9]</sup>、SSR<sup>[6]</sup>、MSR<sup>[6]</sup> 和深度学习方法 TEN<sup>[3]</sup>、TIECNN<sup>[10]</sup> 及 IE-GAN<sup>[11]</sup> 进行定量比较, 对比度因子  $\alpha \in [0.5, 0.51]$ , BSD200 数据集实验结果如表 3 和图 6 所示。

表 3  $\alpha \in [0.5, 0.51]$  条件下 BSD200 数据集测试结果

Tab.3 Test result on BSD200 with  $\alpha \in [0.5, 0.51]$

Method	HE	CLAHE	SSR	MSR	TEN	TIECNN	IE-GAN	Proposed
PSNR	15.95	22.19	16.51	17.57	25.07	24.60	26.23	35.42
SSIM	0.72	0.93	0.88	0.90	0.82	0.80	0.92	0.95

从表 3 数据可知, 文中方法在 BSD200 数据集上取得了最佳的 PSNR 和 SSIM, 较基于灰度变化的 CLAHE 方法分别提升了 13.23 dB 和 0.02; 较基于 Retinex 理论的 MSR 分别提升了 17.85 dB 和 0.07; 较基于对抗生成网络的 IE-GAN 分别提升了 9.19 dB 和 0.03。文中方法较 CLAHE 和 IE-GAN 分别提升了约 37.35%、2.1% 和 25.94%、3.15%。从图 6 可知, 文中网络在减小重构图像伪影、天空光晕等方面显著优于传统方法和其他深度学习算法, 在提升企鹅、人像和建筑物等具体目标对比度的同时, 文中方法避免了局部区域过增强, 能清晰地区分目标和背景, 重构效果接近高质量图像, 实现低质量图像有效增强。

图 7 和表 4 展示了文中算法与其他方法在真实红外图像数据集上进行了增强的视觉效果对比及客观指标对比。图 7 中第 1、3 行为不同方法的增强结果, 第 2、4 行为局部放大图, 最后 1 列为高质量红外图像。与其他方法相比, 文中方法能准确关注需要增强的目标区域, 避免图像过增强, 显著提升了图像整体对比度和纹理细节信息, 同时降低了增强区域的图像

伪影, 使目标边缘更加清楚, 图像整体更加平滑, 具有更佳的视觉效果。文中方法较基于灰度变化的 CLAHE 方法分别提升了 10.94 dB 和 0.01; 较基于 Retinex 理论的 MSR 分别提升了 17.36 dB 和 0.03; 较基于 SRCNN 的 TEN 网络分别提升了 9.95 dB 和 0.07; 较基于对抗生成网络的 IE-GAN 方法分别提升了 8.87 dB 和 0.02; 较 CLAHE 和 IE-GAN 分别提升了约 30.62%、1.04% 和 24.83%、2.08%。

由于不同场景下的红外图像灰度变化具有随机性, 进一步研究了文中方法在不同对比度因子条件下的图像增强。具体做法是仅将  $[0.5, 0.51]$  的对比度范围动态调整为  $[0.1, 0.11]$ ,  $[0.2, 0.21]$ ,  $[0.3, 0.31]$  及  $[0.4, 0.41]$ , 其他参数设置不变, 验证提出的方法对不同场景的增强性能。图 8 和表 5 展示了灰度图像经不同对比度因子 ( $\alpha$ ) 范围作用后的增强效果。图中第一行为输入的低质量图像, 第二行为重构的增强图像。从图中可以直观看出, 即使在极低对比度条件下, 如图 8(a) 所示, 低质量的灰度图像经网络学习后既能显著地提升对比度, 增强图像中感兴趣的区域, 还保留了目标区




图 6  $\alpha \in [0.5, 0.51]$ 条件下 BSD200 图像增强效果  
 Fig.6 Image enhancement on BSD200 with  $\alpha \in [0.5, 0.51]$

表 4  $\alpha \in [0.5, 0.51]$  条件下真实红外图像增强效果

Tab.4 Test result on real infrared images with  $\alpha \in [0.5, 0.51]$

Method	HE	CLAHE	SSR	MSR	TEN	TIECNN	IE-GAN	Proposed
PSNR	13.06	24.78	15.89	18.36	25.77	23.25	26.85	35.72
SSIM	0.53	0.95	0.89	0.93	0.89	0.88	0.94	0.96

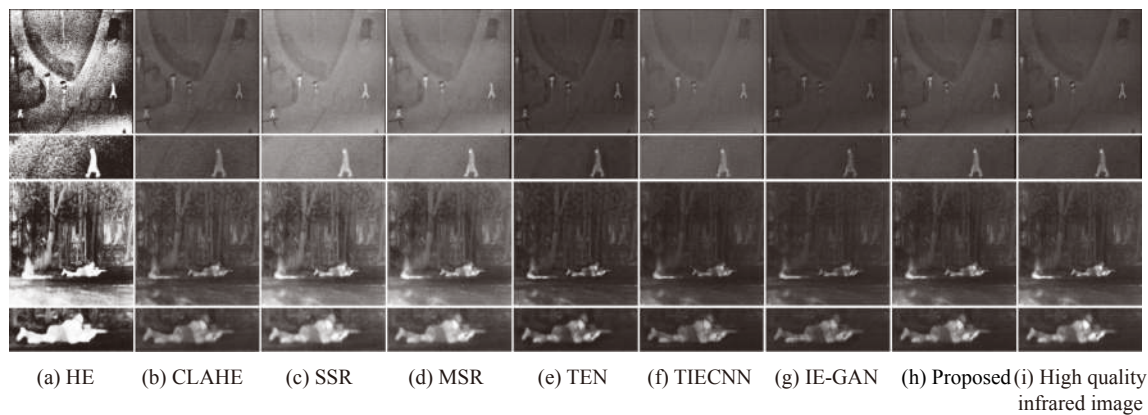


图 7  $\alpha \in [0.5, 0.51]$ 条件下真实红外图像测试结果  
 Fig.7 Test result on real infrared images with  $\alpha \in [0.5, 0.51]$

表 5 在不同 $\alpha$ 作用下文中方法在 BSD200 数据集的 PSNR 和 SSIM

Tab.5 PSNR and SSIM on BSD200 with different  $\alpha$  using proposed method

$\alpha$	[0.1, 0.11]	[0.2, 0.21]	[0.3, 0.31]	[0.4, 0.41]
PSNR	30.5762	31.0370	28.1290	32.0594
SSIM	0.8343	0.8867	0.9074	0.9058



域的纹理细节,有效抑制了边缘处的伪影。表 4 列出了不同 $\alpha$ 条件下的平均 PSNR 和平均 SSIM,文中方法对于不同的 $\alpha$ 也能保持较高的 PSNR 和 SSIM,实现低质量图像的有效增强。

为验证各模块对网络性能的影响,文中进行了消融实验。首先验证不同特征提取路径的增强效果,其次验证多尺度特征提取对网络模型的影响,实验结果如表 6 所示,最后 1 列为平均推理速度 (s)。实验表明,不同特征提取路径表现出近似的增强效果,仅在结构特征权重映射块 (SFW) 作用下,PSNR 与 SSIM

分别为 27.35 dB、0.92;仅在双尺度特征提取块 (TSFEB) 作用下,PSNR 与 SSIM 分别为 29.15 dB、0.90。未结合多尺度特征提取的 Path2 路径测试结果分别为 25.26 dB、0.83,相较于标准 Path2,PSNR 与 SSIM 分别降低了 1.77 dB、0.04,推理速度提升了 0.05 s。仅 Path3 模块作用下,PSNR 与 SSIM 分别为 24.58 dB、0.92。最后两列比较了多尺度特征提取对整体网络的影响,增加多尺度特征提取层后,标准方法在 PSNR 和 SSIM 上分别提升了约 12.51%、2.10%,推理速度仅延迟了 0.04 s。



图 8 在不同 $\alpha$ 作用下文中方法在 BSD200 数据集的图像增强效果

Fig.8 Image enhancement effect on BSD200 with different  $\alpha$  using proposed method

表 6 消融实验

Tab.6 Ablation experiments

Method	PSNR	SSIM	Time/s
Path1(SFW)	27.35	0.92	0.05
Path2 without MS-feature extraction	25.26	0.83	0.09
Path2	27.03	0.87	0.14
Path3	24.58	0.92	0.14
TSFEB	29.15	0.90	0.21
SFW + TSFEB without MS-feature extraction	30.99	0.93	0.22
SFW + TSFEB	35.42	0.95	0.26

### 3 结 论

针对低质量红外图像增强任务,文中提出了一种

并行多路径网络的红外图像增强方法。将红外图像分解为空间结构特征和目标增强特征,提出了结构特征权重映射网络和双尺度特征提取网络,分别学习图

像特征结构和需要增强的感兴趣区域。在双尺度特征提取网络中采用多尺度卷积层,增强多尺度间的信息交换,将空洞卷积融入注意力中,强调对上下文信息的理解,既自适应地学习感兴趣区域,还扩大了网络感受野。为了降低网络的训练难度,引入了残差学习结构。实验表明,文中方法的 PSNR 和 SSIM 较典型的传统方法和深度学习方法有明显提升,经  $\alpha \in [0.5, 0.51]$  低对比度化后,在 BSD200 数据集上,较 CLAHE 和 IE-GAN 分别提升了约 37.35%、2.1% 与 25.94%、3.15%,在真实红外图像上,较 CLAHE 和 IE-GAN 分别提升了约 30.62%、1.04% 和 24.83%、2.08%,且文中方法对于不同对比度因子的低质量图像也能实现有效增强。

#### 参考文献:

- [1] Zuo C, Yang X, Zhang J, et al. Super-resolution enhancement of infrared images using a lightweight dense residual network [J]. *Infrared Technology*, 2021, 43(3): 251-257. (in Chinese)
- [2] Li P, Liu Y, Xu A. Infrared image enhancement using dense residual network with multi-scale coupling [J]. *Journal of Electronic Measurement and Instrumentation*, 2021, 35(7): 148-155. (in Chinese)
- [3] Choi Y, Kim N, Hwang S, et al. Thermal image enhancement using convolutional neural network[C]//2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2016.
- [4] Wang D, Shen T, Sun B, et al. Infrared image enhancement algorithm based on atmospheric gray factor [J]. *Laser and Infrared*, 2019, 49(9): 1135-1140. (in Chinese)
- [5] Li M, Zhou R, Tian Z. A thermal infrared image enhancement method based on histogram [J]. *Infrared Technology*, 2020, 42(9): 880-885. (in Chinese)
- [6] Li J, Li S, Duan X, et al. Infrared image enhancement based on retinex and probability nonlocal means filtering [J]. *Acta Photonica Sinica*, 2020, 49(4): 0410003. (in Chinese)
- [7] Cao H, Liu N, Xu J, et al. Infrared image adaptive inverse histogram enhancement technology [J]. *Infrared and Laser Engineering*, 2020, 49(4): 0426003. (in Chinese)
- [8] Li S, Jin W, Li L, et al. An improved contrast enhancement algorithm for infrared images based on adaptive double plateaus histogram equalization [J]. *Infrared Physics & Technology*, 2018, 90: 164-174.
- [9] Liang X, Tian Y, Yan S, et al. A real-time infrared image enhancement algorithm based on improved CLAHE[C]//2018 International Conference on Image and Video Processing, and Artificial Intelligence, 2018: 10836.
- [10] Lee K, Lee J, Lee J, et al. Brightness-based convolutional neural network for thermal image enhancement [J]. *IEEE Access*, 2017, 5: 26867-26879.
- [11] Kuang X, Sui X, Liu Y, et al. Single infrared image enhancement using a deep convolutional neural network [J]. *Neurocomputing*, 2019, 332: 119-128.
- [12] 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*, 2019, 29(8): 2310-2322.
- [13] Wang X J, Ouyang W S. Multi-scale recurrent attention network for image motion deblurring [J]. *Infrared and Laser Engineering*, 2022, 51(6): 20210605. (in Chinese)
- [14] Tian C, Xu Y, Zuo W. Image denoising using deep CNN with batch renormalization [J]. *Neural Networks*, 2020, 121: 461-473.
- [15] Deng J, Dong W, Socher R, et al. Imagenet: A large-scale hierarchical image database[C]//2009 IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2009.
- [16] Martin D, Fowlkes C, Tal D, et al. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics [C]//Proceedings Eighth IEEE International Conference on Computer Vision. ICCV. IEEE, 2001, 2: 416-423.
- [17] Toet A. TNO image fusion dataset. figshare[DB/OL]. (2014) [2021-12-13]. <https://doi.org/10.6084/m9.figshare.1008029.v1>.
- [18] Davis J W, Keck M A. A two-stage template approach to person detection in thermal imagery[C]//2005 Seventh IEEE Workshops on Applications of Computer Vision (WACV/MOTION'05). IEEE, 2005, 1: 364-369.