

# 基于局部分形维数最大化的单幅图像细节增强

江鹤<sup>1</sup> 乙夫迪<sup>1</sup> 郑州<sup>1</sup> 顾豪<sup>1</sup> 寇旗旗<sup>2</sup> 程德强<sup>1</sup>

**摘要** 随着人们对图像画质要求的不断提高, 各类图像细节增强技术不断涌现. 然而, 基于局部滤波器速度较快, 但其细节增强效果往往有限; 全局滤波器效果突出, 但计算开销较大; 深度学习方法高度依赖人工标注数据, 且其缺乏可解释性; 基于残差学习的策略则容易陷入局部最优, 难以充分挖掘潜在的全局最优特征. 针对上述挑战, 提出一种基于局部分形维数最大化的图像细节增强算法. 研究发现, 图像的分形维数在一定程度上能够有效刻画图像纹理结构, 其空间分布呈现出一定规律: 边缘区域通常具有较高的分形维数, 纹理区域次之, 平坦区域则最低. 基于上述特性, 构建图像纹理特征与分形维数之间的映射关系, 并进一步探讨分形维数与图像细节层之间的内在关联机制. 该方法在保持整体结构一致性的前提下, 通过提升局部分形维数, 实现图像细节的有效增强, 进而为图像增强提供一种具有理论依据的新思路. 大量实验结果表明, 该方法在主观视觉感受和客观评价指标上具有竞争力的表现. 如在 BSDS200 数据集上进行四倍增强因子的测试中, 所提方法在峰值信噪比和结构相似度指标上相较于当前流行方法 QWLS 分别提升 5.20 dB 和 0.145 6, 充分展示了其在图像细节增强任务中的优势与算法强大的泛化特性.

**关键词** 单幅图像细节增强; 分形维数; 分形长度; 可解释性; 图像纹理

**引用格式** 江鹤, 乙夫迪, 郑州, 顾豪, 寇旗旗, 程德强. 基于局部分形维数最大化的单幅图像细节增强. 自动化学报, 2026, 52(3): 525-540

**DOI** 10.16383/j.aas.c250368 **CSTR** 32138.14.j.aas.c250368

## Single Image Detail Enhancement Based on Local Fractal Dimension Maximization

JIANG He<sup>1</sup> YI Fu-Di<sup>1</sup> ZHENG Zhou<sup>1</sup> GU Hao<sup>1</sup> KOU Qi-Qi<sup>2</sup> CHENG De-Qiang<sup>1</sup>

**Abstract** With the increasing demand for higher image quality, various image detail enhancement techniques have continuously emerged. However, local filter-based methods, while fast, often provide only limited detail enhancement; global filter-based methods yield stronger enhancement but incur large computational costs; deep learning-based methods rely heavily on manually annotated data and lack interpretability; and residual learning-based strategies tend to fall into local optima, making it difficult to fully mine potential global-optimal features. To address these challenges, an image detail enhancement algorithm based on local fractal dimension maximization is proposed. The study finds that the fractal dimension of an image can effectively characterize its texture structure to a certain extent, and its spatial distribution exhibits a certain pattern: Edge regions generally have the highest fractal dimension, textured regions follow, and smooth regions the lowest. Based on this characteristic, a mapping between image texture features and fractal dimension is established, and the intrinsic correlation mechanism between fractal dimension and image detail layers is further investigated. Under the premise of maintaining overall structural consistency, the proposed method achieves effective detail enhancement by increasing local fractal dimensions, thereby providing a theoretically grounded new approach to image enhancement. Extensive experimental results show that the method is competitive in both subjective visual perception and objective evaluation metrics. For example, in  $\times 4$  enhancement tests on the BSDS200 dataset, the proposed method improves peak signal to noise ratio and structural similarity by 5.20 dB and 0.145 6 over the currently popular QWLS method, thereby demonstrating its advantages and strong generalization capability in image detail enhancement tasks.

**Keywords** single image detail enhancement; fractal dimension; fractal length; interpretability; image texture

**Citation** Jiang He, Yi Fu-Di, Zheng Zhou, Gu Hao, Kou Qi-Qi, Cheng De-Qiang. Single image detail enhancement based on local fractal dimension maximization. *Acta Automatica Sinica*, 2026, 52(3): 525-540

收稿日期 2025-08-01 录用日期 2025-11-29

Manuscript received August 1, 2025; accepted November 29, 2025

国家自然科学基金(52304182, 52204177), 深地科学与工程云龙湖实验室项目(104024005), 国家重点研发计划(2023YFC2907600, 2021YFC2902701, 2021YFC2902702) 资助

Supported by National Natural Science Foundation of China (52304182, 52204177), Yunlong Lake Laboratory of Deep Underground Science and Engineering Project (104024005), and National Key Research and Development Program of China (2023

YFC2907600, 2021YFC2902701, 2021YFC2902702)

本文责任编辑 林宙辰

Recommended by Associate Editor LIN Zhou-Chen

1. 中国矿业大学信息与控制工程学院 徐州 221116 2. 中国矿业大学计算机科学与技术学院 徐州 221116

1. School of Information and Control Engineering, China University of Mining and Technology, Xuzhou 221116 2. School of Computer Science and Technology, China University of Mining and Technology, Xuzhou 221116

数字图像在医疗影像、安全监控和计算摄影等领域得到广泛应用,其质量直接影响后续分析与决策的准确性<sup>[1-4]</sup>。然而,由于受到多种因素的制约,实际获取的图像往往存在细节模糊的问题。因此,提升图像清晰度与细节表现的图像细节增强技术已成为研究热点。

需要明确的是,图像增强和图像细节增强是两种不同类型的算法。图像增强算法涵盖多个方向,如低光照下的图像增强<sup>[5-7]</sup>、去雾处理<sup>[8-10]</sup>以及去雨处理<sup>[11]</sup>等。在这些任务中,通常需要修正原始图像的不合理部分,这往往伴随着信息熵的变化。相比之下,图像细节增强的核心目标是在保持原始图像整体结构不变的前提下,将其分解为平滑层与细节层,放大细节层以强化整体视觉感知。由于该过程不依赖外部数据,也不会生成新内容,因此信息熵基本保持稳定。目前,主流的图像细节增强技术主要可分为四大类:基于局部滤波器的方法、基于全局滤波器的方法、基于深度学习的方法以及基于残差学习的方法。

基于局部滤波器的方法主要依赖于像素邻域间的空间距离与亮度相似性进行加权平滑,在边缘保持与计算效率之间取得良好的平衡,适合低算力设备或实时应用场景。均值滤波、中值滤波和双边滤波是基于局部滤波器的早期代表性技术。均值滤波会导致图像边缘模糊;中值滤波在处理细节丰富区域时容易造成纹理破坏;而双边滤波则具有更好的连续性控制,但存在梯度反转的问题。引导滤波(guided image filter, GIF)<sup>[12]</sup>进一步提出基于局部线性回归的结构建模框架,但其仍然面临光晕伪影的问题。为改善此类现象, Li 等<sup>[13]</sup>提出加权引导滤波(weighted guided image filter, WGIF), Kou 等<sup>[14]</sup>则提出梯度域引导滤波(gradient-domain guided image filter, GGIF)。他们通过引入与边缘相关的加权策略来缓解光晕伪影问题,但二者在参数稳定性方面表现不足,对正则化参数依赖较强,当该参数取值较大时,光晕现象反而可能更加明显。Lu 等<sup>[15]</sup>进一步提出高效引导滤波,通过增强线性模型中方差信号的表达能力,实现图像结构的精准传递与对比度增强。然而,该方法在参数的场景自适应性上面临一定挑战。

基于全局滤波器的方法通过构建全局优化目标函数,并结合图像的先验知识进行数学建模,从而实现细节层的提取。加权最小二乘法(weighted least squares, WLS)<sup>[16]</sup>、 $L_0$  梯度最小化法<sup>[17]</sup>和总变差正则化法<sup>[18]</sup>能够有效地分离图像中的平滑层与细节层,但在处理复杂纹理时表现出能力不足,且在处理高分辨率图像时效率较低。相较于 WLS<sup>[16]</sup>,

迭代最小二乘法(iterative least square, ILS)<sup>[19]</sup>进一步提升性能和效率。准加权最小二乘法(quasi weighted least squares, QWLS)<sup>[20]</sup>将二维图像的像素重新串联为一维向量,仅保留关键邻接关系,从而压缩原本庞大的二维权重矩阵,有效解决 WLS<sup>[16]</sup>求解相应线性系统所需时间过长的问题。然而,在处理极端高频细节时,其简化结构可能导致局部细节的损失。近期,陈超洋等<sup>[21]</sup>提出一种基于相对总变差统计线的快速增强方法,该方法结合图像的纹理信息以实现颜色校正。然而,该算法主要针对水下图像,泛化能力仍显不足。

近年来,随着神经网络的发展,基于深度学习的图像细节增强方法获得广泛关注。Xu 等<sup>[22]</sup>提出的深度边缘感知滤波器利用卷积神经网络(convolutional neural network, CNN)逼近多种传统滤波器,在结构保持与加速性能上取得突破,但对噪声环境仍敏感。Liu 等<sup>[23]</sup>提出的递归网络(recursive neural network, RNN),通过结合 CNN 提升处理效率。Fan 等<sup>[24]</sup>开发了在同一架构下处理反射移除与图像平滑的网络模型,展现了良好的泛化性。Yang 等<sup>[25]</sup>通过结合无监督学习来增强对复杂输入的鲁棒性。Zhang 等<sup>[26]</sup>将局部拉普拉斯金字塔与神经网络结合以增强边缘控制。Qi 等<sup>[27]</sup>提出基于柯西正则化的双生成自监督机制,提高纹理分离精度。然而,这种方法通常需要较长的前期训练时间,并且依赖于人工标记。此外,模型缺乏严格的理论依据,其可解释性相对较差。

基于残差学习的细节增强算法初步提取粗颗粒的残差特征,并通过搜索潜在空间来更新这些残差特征,从而获得图像细节层。Kim 等<sup>[28]</sup>最早提出基于残差学习的方法,但该方法仅适用于广角镜头。Tao 等<sup>[29]</sup>则引入一种零阶反转滤波器(zero-order reverse filter, ZF),能够快速获取近似的残差。然而,低阶滤波器在拟合高阶图像纹理特征方面存在一定局限性。Jiang 等<sup>[30]</sup>提出一种基于本位残差同质性(in-place residual homogeneity, IPRH)的方法,通过局部搜索匹配实现高质量的细节强化。尽管该方法提升了细节精度,但由于采用贪心搜索策略,其面临陷入局部最优解的风险。

尽管图像细节增强技术已取得一定进展,但现有方法在细节增强效果、运行效率、泛化能力和模型可解释性等方面仍难以兼顾。局部滤波方法对图像结构的建模能力有限,难以满足纹理复杂或高动态范围图像的增强需求,同时存在超参数依赖与增强一致性问题。全局滤波模型普遍依赖于求解复杂的优化方程,计算成本较高,因而难以应用于实时系统中。虽然深度学习方法在细节恢复和视觉质量

上有所突破,但也面临训练成本高、数据依赖重以及可解释性差的问题.此外,残差学习策略常常受限于无法实现全局最优特征的捕捉.因此,在保持图像整体信息结构稳定的前提下,实现细节层特征的精准提取与高效增强仍然是当前图像细节增强领域的一项关键挑战.鉴于此,本研究提出一种基于局部分形维数最大化(local fractal dimension maximization, LFDM)的图像细节增强算法.该算法通过对图像进行分形分析,以最大化局部分形维数而突出图像中的纹理细节与结构特征.实验结果表明,LFDM 在多个典型数据集上表现出色,不仅展现了强鲁棒性和可解释性,还具备一定的高效性,展现出其在图像细节增强任务中的广泛应用潜力.

### 1 研究动机

分形维数作为衡量图像纹理复杂度和细节丰富度的重要指标,能够反映不同区域的特征差异<sup>[31-33]</sup>.如图 1 所示,本研究选取 Set14<sup>[34]</sup> 中的名为 monarch 的图像,并对其点进行采样,范围涵盖平坦区域(绿色)、纹理区域(浅蓝色)和边缘区域(深蓝

色),每类区域均包含三个采样点.随后提取各采样点的分形特征进行分形分析.针对各区域采样点,本研究在对数尺度上进行线性拟合,表达式及误差见图 1.结果显示:平坦区域、纹理区域和边缘区域的分形维数分别为 2.025、2.035 和 2.040,表明平坦区域的分形维数最低、纹理区域居中、边缘区域则有最高的分形维数.此外,各拟合直线的均方根误差介于 0.02 至 0.06 之间,拟合精度可接受,进一步验证了分形维数与图像纹理复杂度之间存在线性关系.

由上述结果可以设想,通过对图像分形维数的调控来实现对图像细节层的有效增强.具体而言,分别对 monarch 图像的部分像素(即蝴蝶所在区域)施加局部分形维数最小化、中值化及最大化操作,以初步观察各策略对图像细节表现的影响.结果如图 2 所示,经过局部分形维数最大化处理的图像在纹理区域展现出更加清晰锐利的结构特征,由此验证了该策略在细节增强方面的潜力.

基于上述分析,本研究提出一种基于局部分形维数最大化的图像细节增强方法.该方法通过提升

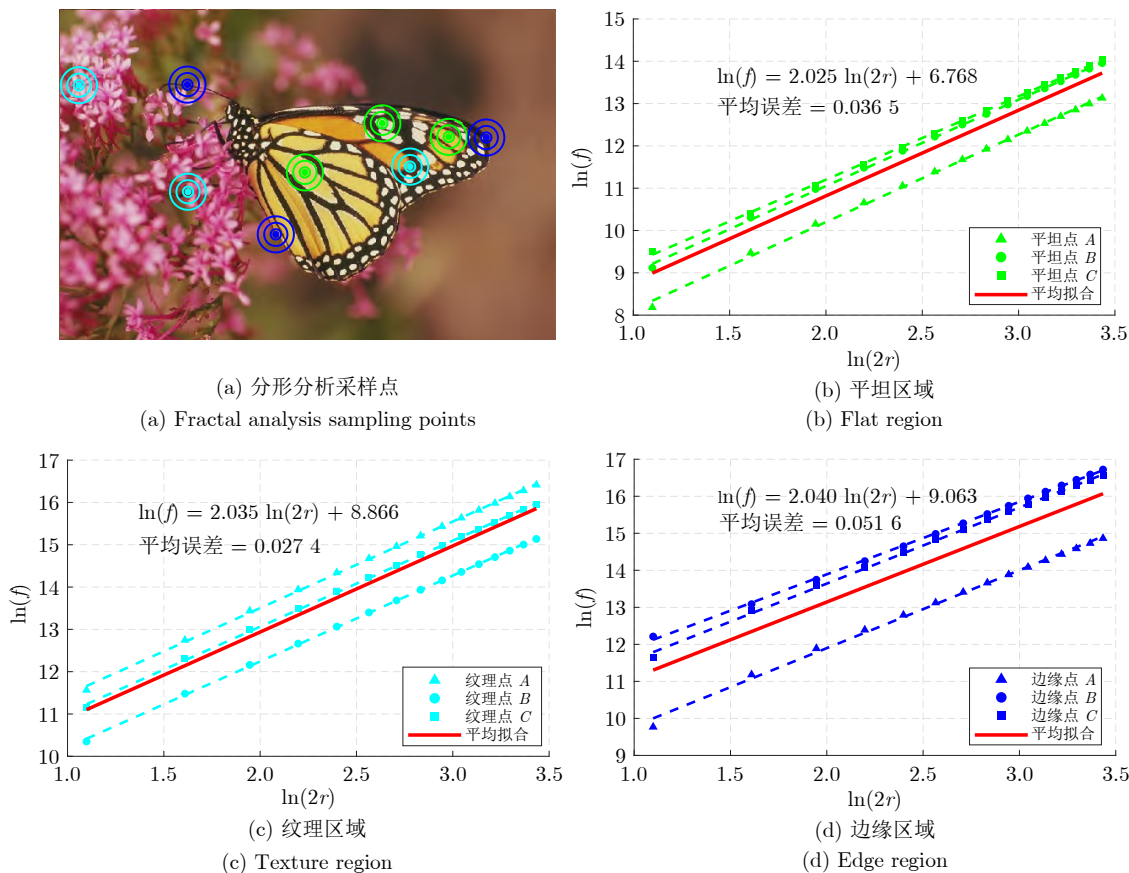


图 1 单幅图像分形点采样及线性回归分析

Fig.1 Fractal point sampling and linear regression analysis of single image

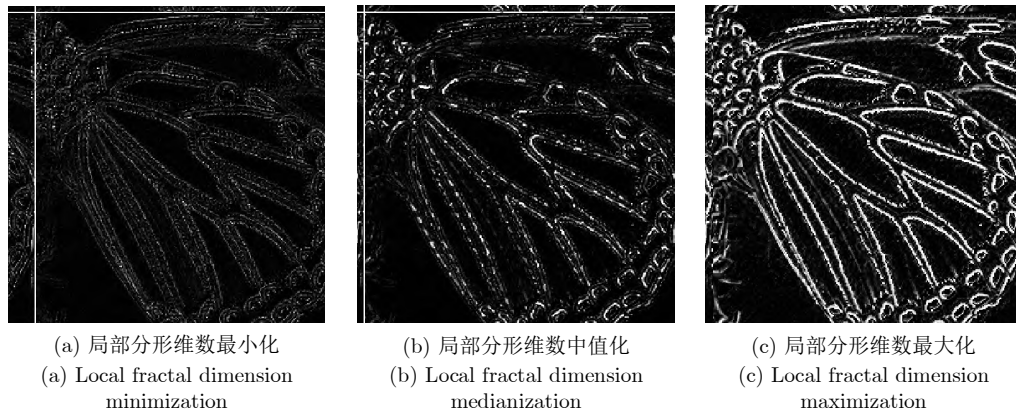


图 2 分形维数的大小与图像纹理的关系

Fig.2 The relationship between the size of fractal dimension and image texture

图像局部区域的分形维数,有效增强细节表现力,并在结构上保持与感知质量之间的良好平衡.

## 2 研究方法

如果将图像的像素点视为一个分形集<sup>[35]</sup>,那么其梯度就可看作该分形集的一个度量<sup>[32, 36]</sup>.基于此度量,本研究利用分形维数和分形长度来表征图像纹理的复杂度.通过将局部的分形维数取区域最大值,得到细节增强后图像的预期测度,最后将细节层与原始图像线性叠加得到细节增强图像.算法分为梯度计算、分形分析和细节增强三部分,流程图如图 3 所示,其中  $\oplus$  和  $\ominus$  为元素加法和元素减法.

### 2.1 梯度计算

梯度计算用差分法实现,利用式 (1) 和式 (2) 计算原始图像  $\mathbf{H}$  在水平方向和垂直方向上的差分  $\nabla_x \mathbf{H}$  和  $\nabla_y \mathbf{H}$ ,根据式 (3) 计算得到它的梯度幅值函数  $g_r(\mathbf{H})$ ,为后续进行分形分析做准备.

$$\nabla_x \mathbf{H} = \sum_{i,j} \mathbf{H}_{(i+1)j} - \mathbf{H}_{ij} \quad (1)$$

$$\nabla_y \mathbf{H} = \sum_{i,j} \mathbf{H}_{i(j+1)} - \mathbf{H}_{ij} \quad (2)$$

$$g_r(\mathbf{H}) = \sqrt{(\nabla_x \mathbf{H})^2 + (\nabla_y \mathbf{H})^2} \quad (3)$$

### 2.2 分形分析

分形是一种由简单规则经递归迭代构建而成的复杂几何结构,展现出尺度不变的自相似性.传统的几何测度仅适用于整数维空间,为解决传统欧氏几何在描述不规则复杂结构时面临的困境,波兰数学家贝努瓦·曼德尔布罗特提出基于豪斯道夫测度的维数<sup>[37]</sup>.

这一理论为理解和分析分形维数提供了新的视角与工具<sup>[38]</sup>.对于给定集合  $\mathcal{F}$  和维数参数  $d \geq 0$ ,其豪斯道夫测度  $\mathcal{H}^d(\mathcal{F})$  可定义为

$$\mathcal{H}^d(\mathcal{F}) = \liminf_{\delta \rightarrow 0} \left\{ \sum_{i=1}^{\infty} (2r_i)^d \mid r_i < \delta \right\} \quad (4)$$

式中,  $\mathcal{F} \subset \bigcup_{i=1}^{\infty} B(o_i, r_i)$ ,  $B(o_i, r_i)$  是以点  $o_i$  为中心、半径为  $r_i$  的开球,这些开球的并集覆盖了  $\mathcal{F}$ ,且每一个开球半径均小于尺度覆盖上限  $\delta$ .

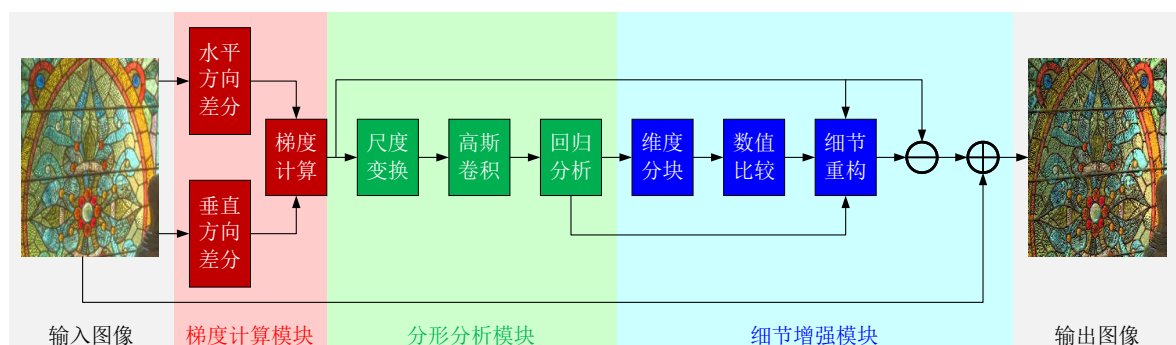


图 3 局部分形维数最大化方法的流程图

Fig.3 Flowchart of the local fractal dimension maximization method

**定义 1.** 幂次法则是分形理论的一个重要性质, 指对于一个分形  $\mathcal{F}$ , 若按比例因子  $\tau$  ( $0 < \tau < 1$ ) 进行缩放后, 理论上应当得到  $N$  个与原分形  $\mathcal{F}$  相似的子结构. 式 (5) 给出幂次法则的数学表达式, 其中,  $\alpha$  称为分形维数,  $C$  为常数<sup>[31]</sup>.

$$N \cdot \tau^\alpha = C \quad (5)$$

换言之, 如果一个分形在每次迭代中被划分为  $N$  个与整体相似的子结构, 并且每个子结构的缩放因子为  $\tau$ , 那么分形维数应满足  $\alpha = -\ln N / \ln \tau$ .

**定义 2.** 分形维数具有双李普希兹不变性. 如式 (6) 所示, 映射  $\mathcal{M}$  是定义在分形集  $\mathcal{G}$  上双李普希兹变换, 当且仅当  $\mathbf{y}, \mathbf{z} \in \mathcal{G}$ , 存在常数  $0 < \mu_1 \leq \mu_2 < \infty$ , 使得对于所有  $\mathbf{y}, \mathbf{z}$  均满足<sup>[32]</sup>:

$$\mu_1 \|\mathbf{y} - \mathbf{z}\|_2 \leq \|\mathcal{M}(\mathbf{y}) - \mathcal{M}(\mathbf{z})\|_2 \leq \mu_2 \|\mathbf{y} - \mathbf{z}\|_2 \quad (6)$$

这一条件限制了双李普希兹变换在空间中对距离缩放的上下限, 确保既不会过度压缩也不会过度拉伸距离, 从而维持几何对象的空间特征本质.

在一般情况下, 常见的几何变换均可归类为双李普希兹变换, 而图像细节增强则属于局部范围内的仿射变换. 在局部区域中, 常数  $\mu_1 = \mu_2 = n$ ,  $n$  是尺度缩放因子.

**推论 1.** 设函数  $f(x)$  定义在分形集  $\mathcal{A}$  上且  $x \in \mathcal{A}$ , 点  $x$  处的分形维数与分形长度分别为  $\alpha(x)$  与  $\mathcal{S}(x)$ . 若定义尺度缩放变换  $T(x) = nx$ , 则点  $T(x)$  处的分形维数  $\alpha_T(x)$  与分形长度  $\mathcal{S}_T(x)$  如式 (7) 所示, 其证明见附录 A.

$$\alpha_T(x) = \alpha(x), \quad \mathcal{S}_T(x) = \mathcal{S}(x) - \alpha(x) \ln n \quad (7)$$

对图像进行分形分析时, 将每个像素点视为一个分形集, 而整幅图像中所有像素点的集合则被视作一组分形集的并集. 在此基础上, 图像的梯度可以被看作是该分形集的一种度量, 那么利用图像梯度作为度量所定义的测度空间中, 任意点  $x$  对应的密度函数  $\rho(x)$  如式 (8) 所示, 其中  $r$  表示开球的半径<sup>[37]</sup>. 式 (9) 和式 (10) 中,  $G_b(x)$  是一个标准差为  $\sigma$ 、半径为  $b$  的高斯核, 而  $f(g_r(x))$  则表示利用图像梯度作为度量计算得到的测度值.

$$\rho(x) = \lim_{r \rightarrow 0} \frac{f(g_r(x))}{(2r)^\alpha} \quad (8)$$

$$G_b(x) = \frac{1}{\sqrt{2\pi}b\sigma} e^{-\frac{x^2}{b^2\sigma^2}} \quad (9)$$

$$f(g_r(x)) = \int_{-\infty}^{+\infty} G_b(z) \cdot g_r(x-z) dz \quad (10)$$

对于像素均匀分布的自然图像, 改写式 (8) 可得式 (11), 其中,  $\alpha(x)$  表示该像素点处的分形维数,

而  $\mathcal{S}(x)$  则表示该像素点处的分形长度<sup>[31]</sup>.

$$\alpha(x) = \lim_{r \rightarrow 0} \frac{\ln f(g_r(x)) - \mathcal{S}(x)}{\ln(2r)} \quad (11)$$

由于极限运算存在一定的局限性, 因此需要对式 (12) 进行最小化, 以获得  $\alpha(x)$  和  $\mathcal{S}(x)$ , 即线性回归拟合的直线斜率和截距.

$$\sum_{r, f(g_r(x))} \|\ln f(g_r(x)) - \alpha(x) \ln(2r) - \mathcal{S}(x)\|_2 \quad (12)$$

### 2.3 细节增强

依据传统图形分解理论, 一幅图像  $\mathbf{H}$  可以分解为平滑层  $\mathbf{J}$  和细节层  $\mathbf{K}$  的线性和<sup>[12-14]</sup>, 即  $\mathbf{H} = \mathbf{J} + \mathbf{K}$ . 通过放大细节层, 将其线性叠加到原始图像上以实现图像细节增强, 如式 (13) 所示,  $\mathbf{H}'$  表示细节增强后的图像,  $\beta$  为增强因子.

$$\mathbf{H}' = \mathbf{H} + \beta \cdot \mathbf{K} \quad (13)$$

由于式 (11) 的普遍存在性, 对于细节增强后的图像, 理论上同样满足此关系, 即式 (14). 其中,  $f'(g_r(x))$  表示细节增强图像中像素点  $x$  处的测度值,  $\alpha'(x)$  和  $\mathcal{S}'(x)$  为相应的分形维数和分形长度.

$$\ln(f'(g_r(x))) = \alpha'(x) \ln(2r) + \mathcal{S}'(x) \quad (14)$$

进一步推导可得式 (15):

$$\frac{\ln f(g_r(x)) - \mathcal{S}(x)}{\alpha(x)} = \frac{\ln f'(g_r(x)) - \mathcal{S}'(x)}{\alpha'(x)} \quad (15)$$

由于本研究的任务是进行图像细节增强, 不涉及图像分辨率的变化, 因此缩放因子  $n = 1$ , 将其代入推论 1 的式 (7), 并结合本研究进行局部分形维数最大化处理, 即可得到式 (16). 其中, 局部区域  $\mathcal{X}_i$  表示维数矩阵中第  $i$  个块. 进一步可以得到增强图像的  $f'(g_r(x))$ , 如式 (17) 所示.

$$\alpha'(x) = \max_{x \in \mathcal{X}_i} \alpha(x), \quad \mathcal{S}'(x) = \mathcal{S}(x) \quad (16)$$

$$f'(g_r(x)) = f(g_r(x))^{\frac{\alpha'(x)}{\alpha(x)}} \cdot e^{\left(1 - \frac{\alpha'(x)}{\alpha(x)}\right) \cdot \mathcal{S}(x)} \quad (17)$$

本研究中, 将局部分形维数最大化后的信号测度值与输入信号测度值作差后视为细节层, 随后乘以一个增强因子  $\beta$  并叠加到原始信号上, 最后遍历整幅图像  $\mathbf{x}$ , 得到细节增强后的图像  $\mathbf{H}'$ , 如式 (18) 所示. 算法伪代码如算法 1 所示.

$$\mathbf{H}' = \mathbf{H} + \beta(f'(g_r(\mathbf{x})) - f(g_r(\mathbf{x}))) \quad (18)$$

#### 算法 1. 基于局部分形维数最大化的图像细节增强算法

1: 读取输入图像  $\mathbf{H}$ , 设置高斯卷积核半径  $b$ 、最大尺

度系数  $f_r$  以及增强因子  $\beta$ ;

- 2: 各通道逐像素差分, 得到  $\nabla_x \mathbf{H}$  和  $\nabla_y \mathbf{H}$ ;
- 3: 根据式 (3) 计算梯度幅值  $g_r(\mathbf{H})$ ;
- 4: 对  $b$  进行尺度变换, 并根据式 (10) 对  $g_r(\mathbf{H})$  进行高斯卷积处理;
- 5: 逐图像块进行线性回归分析, 通过最小化式 (12) 得到分形维数  $\alpha(x)$  与分形长度  $\mathcal{S}(x)$ ;
- 6: 根据式 (16), 最大化各图像块的  $\alpha(x)$ , 得  $\alpha'(x)$ ;
- 7: 根据式 (17) 重构纹理细节, 即

$$f'(g_r(x)) = f(g_r(x)) \frac{\alpha'(x)}{\alpha(x)} \cdot e^{(1 - \frac{\alpha'(x)}{\alpha(x)}) \cdot \mathcal{S}(x)}$$

- 8: 遍历图像  $\mathbf{x}$ , 根据式 (18) 进行细节增强, 得到输出图像  $\mathbf{H}'$ :

$$\mathbf{H}' = \mathbf{H} + \beta (f'(g_r(\mathbf{x})) - f(g_r(\mathbf{x})))$$

### 3 实验分析

#### 3.1 数据集

本实验选用 3 个具有代表性的自然图像数据集, 包括 RealSRSet<sup>[39]</sup>、BSDS200<sup>[40]</sup> 和 T91<sup>[41]</sup>. RealSRSet<sup>[39]</sup> 是一个真实世界的场景数据集, 包含来自不同实际环境中的高质量图像; BSDS200<sup>[40]</sup> 和 T91<sup>[41]</sup> 数据集所包含的图像具有丰富的纹理变化和复杂结构. 它们在国际上广泛应用于纹理分析和图像处理研究, 且各具特色, 能够为实验提供多样的图像内容和复杂的纹理特征, 以全面评估算法在不同图像类型下的表现.

#### 3.2 实验参数设置

实验在 MATLAB R2023b 上完成, 所提算法的主要参数设置如下: 最大尺度系数为 15, 分形维数矩阵分块半径为 2. 上述参数数值选择通过大量图像测试确定, 以实现细节增强效果与性能间的平衡.

本研究选取多种细节增强算法进行对比, 涵盖基于局部滤波器、全局滤波器、残差学习和深度学习的方法, 包括 WLS<sup>[16]</sup>、GIF<sup>[12]</sup>、WGIF<sup>[13]</sup>、GGIF<sup>[14]</sup>、ZF<sup>[29]</sup>、BFLS (bilateral filter in least squares)<sup>[42]</sup>、ILS<sup>[19]</sup>、DIP (deep image prior)<sup>[43]</sup>、IPRH<sup>[30]</sup>、TH (truncated huber)<sup>[44]</sup>、DeepFSPIS (deep flexible structure preserving image smoothing)<sup>[45]</sup>、CS-GIS (contrastive semantic-guided image smoothing)<sup>[46]</sup>、PTF (pyramid texture filtering)<sup>[47]</sup>、MG-PNet (multiscale global perception network)<sup>[48]</sup>、QWLS<sup>[20]</sup>、PMN (paired real data meet noise model)<sup>[49]</sup>、ALSP (ambient light similarity prior)<sup>[50]</sup>、

LLF-LUT++ (local Laplacian filter-look-up table++)<sup>[51]</sup> 和 NCC-PLM (new color channel driven physical lighting model)<sup>[52]</sup>. 上述对比方法代码均可通过 GitHub 平台免费获取, 实验过程中均采用其默认参数设置以保证结果的可复现性和公平性.

#### 3.3 客观指标对比

为客观地评估图像质量, 本研究选用常用的峰值信噪比 (peak signal to noise ratio, PSNR) 和结构相似度 (structure similarity, SSIM) 作为评价标准, 式 (19) 和式 (20) 为其计算方式. PSNR 用于量化像素层面的误差, 其值越大, 图像间的差异越小; SSIM 则衡量图像之间的结构一致性, 其取值范围为 0 到 1, 值越接近 1, 图像间在结构上越相似.

$$PSNR = 10 \times \lg \left( \frac{MAX^2}{MSE} \right) \quad (19)$$

$$SSIM = \frac{(2\mu_x\mu_y + a_1)(2\delta_{xy} + a_2)}{(\mu_x^2 + \mu_y^2 + a_1)(\delta_x^2 + \delta_y^2 + a_2)} \quad (20)$$

其中,  $MAX$  表示图像中像素的最大值,  $MSE$  则代表图像的均方误差.  $\mu_x$  和  $\mu_y$  分别为输入图像和结果图像的亮度均值,  $\delta_x$  和  $\delta_y$  是输入图像与结果图像的标准差,  $\delta_{xy}$  为两者之间的协方差. 参数  $a_1$  和  $a_2$  是两个非常小的正数, 其主要作用是防止分母为零.

在 RealSRSet<sup>[39]</sup>、BSDS200<sup>[40]</sup> 以及 T91<sup>[41]</sup> 三个数据集上, 以两倍及四倍增强因子进行测试, 结果如表 1 所示. 从实验结果可以看出, 本研究所提算法在 PSNR 和 SSIM 指标上均表现出较高的数值水平, 如在 BSDS200 数据集上进行四倍增强因子的测试中, 所提方法在 PSNR 和 SSIM 上相较于当前流行方法 QWLS 分别提升了 5.20 dB 和 0.145 6, 整体性能多数位于最优水平. 这说明与其他对比算法相比, 所提方法在多数测试图像上取得更优的细节保真度和结构一致性, 体现出良好的泛化能力.

#### 3.4 MOS 测试

MOS (mean opinion score) 测试是一种主观图像质量评估方法, 它通过被试者的主观评分反映图像质量的视觉感知. 本实验共邀请 30 名被试者, 其中男女比例相当, 年龄范围 20 ~ 45 岁, 非专业被试者占比为 50%, 以保证结果的客观性.

实验在照度为 350 lux 的室内进行. 所有图像均在一台分辨率为 1 920 × 1 080 像素、亮度为 300 cd/m<sup>2</sup>、对比度为 1 000 : 1 的显示器上呈现. 测试图像以随机顺序呈现, 展示时长为 5 s, 被试者在展示结束后 8 s 内完成评分. 评分采用 0 ~ 5 分等

表 1 增强因子为 2 和 4 时在基准数据集下的指标对比

Table 1 Comparison of indicators under the benchmark datasets when the enhancement factor of 2 and 4

模型	增强因子	RealSRSet <sup>[39]</sup>		BSDS200 <sup>[40]</sup>		T91 <sup>[41]</sup>	
		PSNR (dB)	SSIM	PSNR (dB)	SSIM	PSNR (dB)	SSIM
WLS <sup>[16]</sup>	×2	20.16	0.8235	17.74	0.7439	18.63	0.7693
GIF <sup>[12]</sup>		24.45	0.8908	23.89	0.8344	23.82	0.8444
WGIF <sup>[13]</sup>		25.66	0.8867	27.91	0.8816	24.85	0.8517
GGIF <sup>[14]</sup>		<u>27.35</u>	0.9256	27.41	0.8865	26.95	0.8955
ZF <sup>[29]</sup>		20.65	0.7731	22.56	0.7966	24.09	0.9237
BFLS <sup>[42]</sup>		22.51	0.8318	23.06	0.7965	21.63	0.7659
ILS <sup>[19]</sup>		26.16	0.8761	25.09	0.8313	23.48	0.8093
DIP <sup>[43]</sup>		23.00	0.7970	23.75	0.7657	25.87	0.8232
IPRH <sup>[30]</sup>		26.30	0.9147	24.97	0.8629	<u>28.48</u>	0.9102
TH <sup>[44]</sup>		20.70	0.7872	21.32	0.7620	21.43	0.7616
DeepFSPIS <sup>[45]</sup>		26.13	0.8640	27.05	0.8640	25.67	0.8260
CSGIS <sup>[46]</sup>		24.50	0.8340	25.32	0.8355	25.18	0.8216
PTF <sup>[47]</sup>		18.43	0.7365	19.12	0.7116	18.76	0.6939
MGPNet <sup>[48]</sup>		20.56	0.6953	23.38	0.8430	21.18	0.7489
QWLS <sup>[20]</sup>		24.54	0.8894	26.83	<u>0.9099</u>	27.50	0.9153
PMN <sup>[49]</sup>		26.87	0.8377	<u>29.53</u>	0.8820	27.85	0.8869
ALSP <sup>[50]</sup>		19.18	0.7324	17.15	0.6285	17.58	0.6899
LLF-LUT++ <sup>[51]</sup>		19.96	0.4715	20.16	0.5810	20.69	0.3256
NCC-PLM <sup>[52]</sup>		23.52	<u>0.9290</u>	22.86	0.9098	23.56	<u>0.9370</u>
LFDM (本文)		<b>29.46</b>	<b>0.9687</b>	<b>31.59</b>	<b>0.9754</b>	<b>32.52</b>	<b>0.9826</b>
WLS <sup>[16]</sup>	×4	—	—	—	—	—	—
GIF <sup>[12]</sup>		19.53	0.7638	18.71	0.6637	18.73	0.6862
WGIF <sup>[13]</sup>		20.87	0.7781	22.54	0.7517	19.77	0.7081
GGIF <sup>[14]</sup>		22.09	0.8294	21.90	0.7517	21.53	0.7699
ZF <sup>[29]</sup>		16.60	0.6038	18.07	0.6218	19.36	0.6081
BFLS <sup>[42]</sup>		18.70	0.6982	18.07	0.6174	16.95	0.5898
ILS <sup>[19]</sup>		21.10	0.7491	19.81	0.6636	18.49	0.6432
DIP <sup>[43]</sup>		19.69	0.6988	21.16	0.6860	22.71	0.7285
IPRH <sup>[30]</sup>		21.47	0.8039	20.14	0.7105	23.30	0.7782
TH <sup>[44]</sup>		16.72	0.6354	16.77	0.5786	16.91	0.5822
DeepFSPIS <sup>[45]</sup>		20.88	0.7220	21.59	0.7030	20.47	0.6510
CSGIS <sup>[46]</sup>		19.16	0.6651	19.82	0.6523	19.77	0.6344
PTF <sup>[47]</sup>		15.09	0.5777	15.17	0.5244	14.89	0.5080
MGPNet <sup>[48]</sup>		16.86	0.5422	19.47	0.7070	18.02	0.6018
QWLS <sup>[20]</sup>		20.27	0.7721	21.83	0.7906	22.88	0.7950
PMN <sup>[49]</sup>		21.37	0.6691	23.79	0.9095	22.27	0.7325
ALSP <sup>[50]</sup>		15.81	0.5469	14.11	0.4274	14.36	0.5076
LLF-LUT++ <sup>[51]</sup>		12.37	0.2977	13.58	0.3122	13.20	0.2407
NCC-PLM <sup>[52]</sup>		<u>24.43</u>	<b>0.9237</b>	<u>24.20</u>	<u>0.9100</u>	<u>23.46</u>	<u>0.9312</u>
LFDM (本文)		<b>25.12</b>	<u>0.9230</u>	<b>27.03</b>	<b>0.9362</b>	<b>27.81</b>	<b>0.9545</b>

注: 表中加粗字体表示最优值, 下划线表示次优值.

级制, 其中, 0 表示“非常差”, 5 表示“非常好”. 所得评分经去除极值后取平均作为最终 MOS 得分, 并

据此进行排名.

根据测试结果 (如表 2 所示), 本研究所提算法

(LFD) 在 RealSRSet<sup>[39]</sup>、BSDS200<sup>[40]</sup>、T91<sup>[41]</sup> 三个数据集上的表现均处于最优或次优位置, 证明了其在图像细节增强方面符合大多数人的视觉感受, 展现了其在图像细节增强任务中的有效性与稳定性。

表 2 MOS 测试前三名结果  
Table 2 Top three MOS testing results

数据集	增强因子	第 1 名	第 2 名	第 3 名
RealSRSet <sup>[39]</sup>		LFD (本文)	PMN <sup>[40]</sup>	WGIF <sup>[13]</sup>
BSDS200 <sup>[40]</sup>	×2	LFD (本文)	ZF <sup>[29]</sup>	NCC-PLM <sup>[52]</sup>
T91 <sup>[41]</sup>		WGIF <sup>[13]</sup>	LFD (本文)	PMN <sup>[40]</sup>
RealSRSet <sup>[39]</sup>		LFD (本文)	NCC-PLM <sup>[52]</sup>	GGIF <sup>[14]</sup>
BSDS200 <sup>[40]</sup>	×4	LFD (本文)	NCC-PLM <sup>[52]</sup>	PMN <sup>[40]</sup>
T91 <sup>[41]</sup>		LFD (本文)	NCC-PLM <sup>[52]</sup>	WGIF <sup>[13]</sup>

### 3.5 视觉感知分析

为呈现视觉效果, 本研究在图 4~6 (其中 GT (ground truth) 是真实图像) 中将所提算法与其他算法结果对比分析, 可得出结论: 1) 部分算法在图像细节增强过程中改变了原始图像的颜色. 如图 4, 经 TH<sup>[44]</sup>、ZF<sup>[29]</sup> 和 CSGIS<sup>[46]</sup> 处理后的图像黑色条纹间出现异常绿色; WGIF<sup>[13]</sup>、BFLS<sup>[42]</sup> 和 CSGIS<sup>[46]</sup> 的结果中灰白色背景出现异常紫色. 图 5 中, GIF<sup>[12]</sup>、WGIF<sup>[13]</sup>、BFLS<sup>[42]</sup> 和 TH<sup>[44]</sup> 处理后的黑色鸟喙部分均呈现蓝色. 图 6 中, BFLS<sup>[42]</sup>、TH<sup>[44]</sup> 以及 CSGIS<sup>[46]</sup> 等方法在处理蜥蜴腹部下方黄褐色石块时, 均出现了非自然的青色. 2) 过度增强现象较普遍. 如图 5, GIF<sup>[12]</sup>、WGIF<sup>[13]</sup>、BFLS<sup>[42]</sup>、TH<sup>[44]</sup>、DeepFSPIS<sup>[45]</sup>、CSGIS<sup>[46]</sup> 对绿色背景及模糊黑影增强过度. 如图 6, GIF<sup>[12]</sup>、WGIF<sup>[13]</sup>、BFLS<sup>[42]</sup> 以及 TH<sup>[44]</sup> 在处理图像时均存在整体亮度过度提升的问题, 尤其在蜥蜴表面斑纹与右下角石块区域较明显; DeepFSPIS<sup>[45]</sup> 在蜥蜴腹部的黄褐色区域出现不自然的过饱和现象。

此外, DeepFSPIS<sup>[45]</sup> 与 CSGIS<sup>[46]</sup> 在图 4~6 中的物体边缘处产生光晕伪影, 伴随明显的颜色失真. 相比之下, 本研究所提算法在增强图像细节的同时, 能够较为有效保持原始图像的色彩与结构信息. 在提升主观视觉质量的同时, 兼顾图像的保真性, 最终展现出更为优越的整体性能。

### 3.6 消融实验

#### 3.6.1 最大尺度系数的消融实验

为进一步评估最大尺度系数  $f_r$  对模型性能的影响, 本研究在 RealSRSet<sup>[39]</sup> 与 T91<sup>[41]</sup> 数据集上开展对比实验, 综合使用 PSNR 与 MOS 打分进行定量评估, 以增强实验结果说服力. 如图 7 所示, 随着  $f_r$  值的增加, 两个数据集的 PSNR 值整体呈递增趋势, 表明图像细节增强效果在客观指标上逐步提升. 然而, MOS 得分却随着  $r$  的增大持续下降, 尤其在其值为 15~20 之间急剧下降, 随后趋于平稳. 说明尽管图像在 PSNR 上有所改善, 但过大的尺度可能导致图像出现过度平滑或结构模糊, 进而影响视觉感知质量。

综合分析, 适中的最大尺度系数 (如  $f_r = 15$ ) 能在保持较高视觉质量的同时提供可接受的客观指标, 该实验结果为参数选取提供了实践依据。

#### 3.6.2 维数矩阵分块半径的消融实验

针对图像细节增强过程中可能存在块间像素值不连续问题, 本研究设计维数矩阵分块半径的消融实验, 其中分块半径值的变化范围为 2~6, 并在 RealSRSet<sup>[39]</sup> 与 T91<sup>[41]</sup> 数据集上进行综合评估。

实验结果如图 8 所示, 随着分块半径值的增加, 两个数据集的 PSNR 均呈下降趋势. 这一现象的根本原因在于, 分形维数用于刻画局部纹理特征, 当分块半径增大时, 块内纹理特征的相关性减弱, 导致最大化局部分形维数对局部纹理特征的代表能力

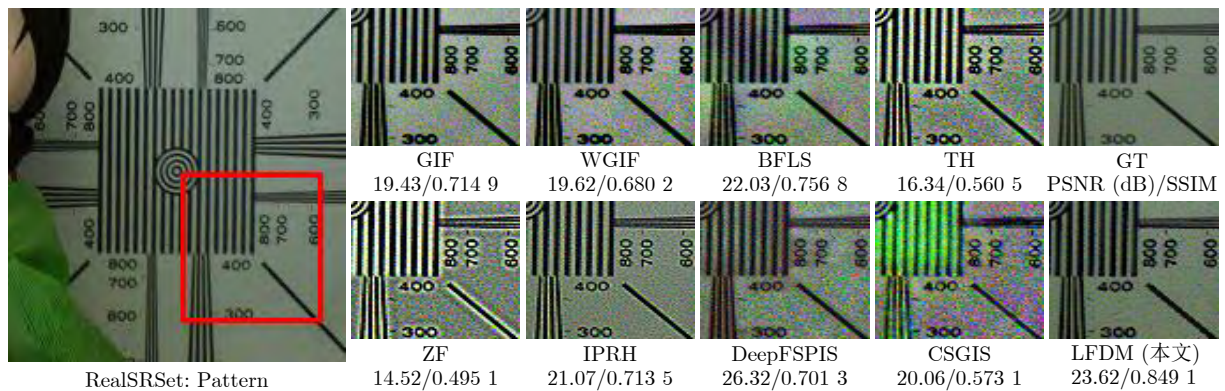


图 4 第 1 组视觉对比示意图

Fig. 4 The first group of visual comparison schematic diagram




图 5 第 2 组视觉对比示意图

Fig. 5 The second group of visual comparison schematic diagram

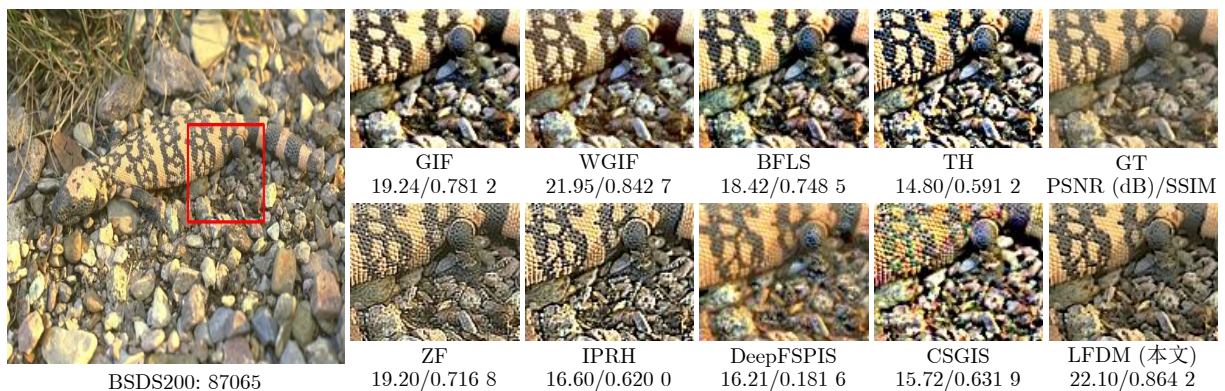


图 6 第 3 组视觉对比示意图

Fig. 6 The third group of visual comparison schematic diagram

下降, 进而使细节增强结果性能不佳. 由于相邻图像块之间的增强效果差异过大, 最终在图像中呈现出明显的分块现象. 综合分析, 当分块半径取最小值 2 时, 模型能够更准确地反映局部纹理特征并保持较好的块间连续性, 性能达到最优.

### 3.6.3 边缘检测算法的消融实验

为验证边缘检测模块对图像细节增强效果的影响, 本研究分别采用 Sobel、Prewitt、Canny 和差分法四种经典算法进行消融实验. 实验的主观对比图如图 9 所示 (第 1 行、第 2 行图片分别选自 RealSRSet<sup>[39]</sup>、T91<sup>[41]</sup>), 利用 Sobel 和 Prewitt 初步提取图像细节会导致边缘伪影的问题. 而 Canny 算法则可能改变图像色度, 出现异常像素块.

实验数据如表 3 所示, 本算法所采用的差分法在提取图像细节时取得最优性能. 其优势在于算法未引入任何预平滑或非极大值抑制步骤, 最大程度地保留了图像梯度变化.

### 3.6.4 关于滤波方法的消融实验

本研究对拉普拉斯滤波、圆形滤波、均值滤波

以及高斯滤波四种方法的效果进行消融实验. 实验结果如表 4 和图 10 所示.

结果显示, 拉普拉斯滤波可增强高频细节, 但会导致色度异常, 如 RealSRSet<sup>[39]</sup> 的 tiger 图片中, 老虎的皮毛被增强得过黑; 圆形滤波和均值滤波模糊了结构边界, 造成纹理信息损失, 导致细节增强效果不好; 在 T91<sup>[41]</sup> 的 t16 图片中, 采用拉普拉斯滤波、圆形滤波、均值滤波的细节增强图像树叶边缘均出现异常斑点. 相比之下, 高斯滤波在平滑高频噪声与保留分形结构方面取得良好平衡, 其标准差的自适应性为模型提供了跨尺度调节能力, 使其在后续分形维数计算中获得更精确的估计. 因此, 高斯滤波被确定为本研究分形分析模块中的滤波方法.

### 3.7 模型时间复杂度

时间复杂度是衡量模型效率的重要指标. 本研究模型包括梯度计算、分形分析、细节增强三部分.

设输入图像的尺寸为  $M \times N$ , 分形分析的最大尺度系数为  $f_r$ . 由前文计算可知, 梯度计算的时间

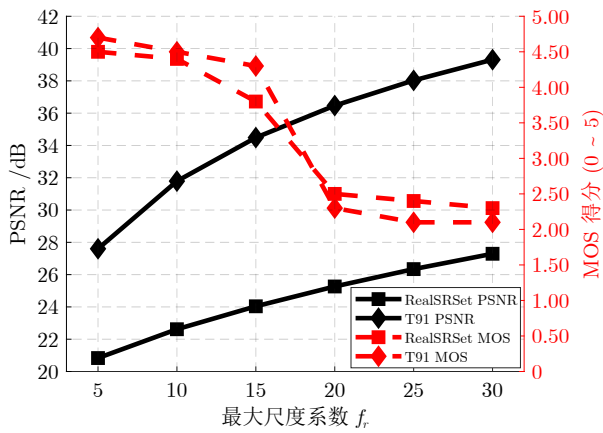


图7 最大尺度系数的消融实验

Fig.7 Ablation study on the maximum scale coefficient

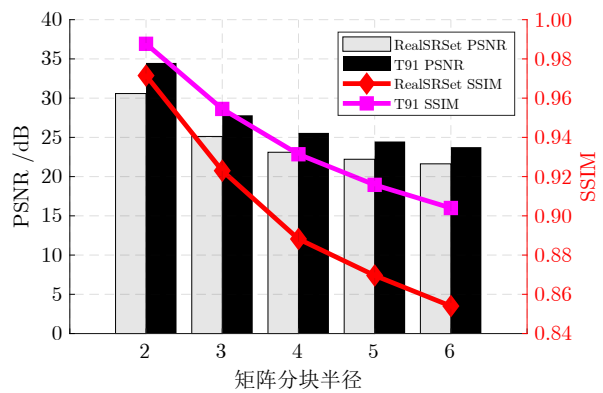


图8 维数矩阵分块半径的消融实验

Fig.8 Ablation study on dimension matrix block radius




图9 不同边缘检测算法的视觉效果对比

Fig.9 A comparison of visual effects of different edge detection algorithms

复杂度为  $O(M \times N)$ . 分形分析中对不同半径  $b$  生成高斯滤波器进行卷积运算, 卷积核大小为  $(1 + 2b)^2$ , 卷积的时间复杂度为  $O(M \times N(2b + 1)^2)$ . 因此该部分的总体时间复杂度为  $O(MN \sum_{i=1}^{f_r} (2b + 1)^2) = O(MN f_r^3)$ . 线性回归分析的时间复杂度为  $O(M \times N f_r)$ . 综上, 分形分析部分的总体时间复杂度为  $O(MN f_r^3)$ . 细节增强中对分形维数矩阵进行分块

表3 不同边缘检测算法在测试数据集上的性能比较  
Table 3 Performance comparison of various edge detection algorithms on the test datasets

边缘检测算法	RealSRSet <sup>[39]</sup>		T91 <sup>[41]</sup>	
	PSNR (dB)	SSIM	PSNR (dB)	SSIM
Sobel	18.99	0.7643	21.88	0.8544
Prewitt	20.86	0.8344	24.05	0.9025
Canny	21.69	0.7925	24.49	0.8773
差分法	<b>30.59</b>	<b>0.9715</b>	<b>34.49</b>	<b>0.9877</b>

表4 不同滤波方法在测试数据集上的性能比较  
Table 4 Performance comparison of various filtering methods on the test datasets

滤波方法	RealSRSet <sup>[39]</sup>		T91 <sup>[41]</sup>	
	PSNR (dB)	SSIM	PSNR (dB)	SSIM
拉普拉斯滤波	23.10	0.8412	25.26	0.9021
圆形滤波	21.30	0.8390	23.43	0.8970
均值滤波	23.77	0.9011	26.19	0.9397
高斯滤波	<b>30.59</b>	<b>0.9715</b>	<b>34.49</b>	<b>0.9877</b>

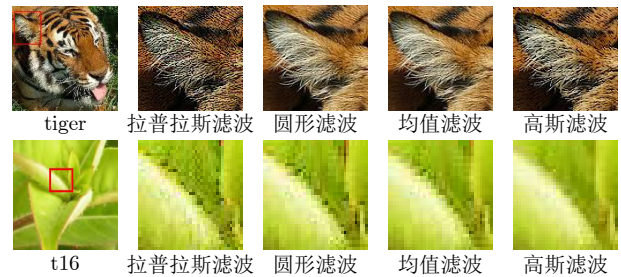


图10 不同滤波方法的视觉效果对比

Fig.10 A comparison of visual effects of different filtering methods

求最大值和像素级增强重构运算, 其时间复杂度为  $O(MN)$ .

综上, 所提算法的总体时间复杂度为  $O(M \times N f_r^3)$ .

### 3.8 运行速度对比

在各种图像细节增强任务中, 算法的效率与性能指标同等重要. 本研究测试了不同模型在 RealSRSet<sup>[39]</sup> 数据集上的平均运行速度, 如表 5 所示.

基于局部滤波器的算法运行迅速, 但细节提升有限; 基于全局滤波器的算法细节增强效果较好, 但优化方程复杂, 不利于边缘设备应用; 基于深度学习的算法运行速度快, 但数据依赖性强, 可解释性差. 相比之下, 本研究提出的 LFDM 算法无需训练, 模型可解释性强, 虽然计算时间略长, 但在 RealSRSet<sup>[39]</sup> 上 PSNR 取得 25.12 dB 的成绩, 展现

表 5 不同算法在 RealSRSet<sup>[39]</sup> 数据集上的平均运行时间及 PSNR 的性能比较

Table 5 Performance comparison of different algorithms on the RealSRSet<sup>[39]</sup> dataset in terms of average running time and PSNR

模型	时间 (s)	PSNR (dB)
GIF <sup>[12]</sup>	0.04	19.53
WGIF <sup>[13]</sup>	0.08	20.87
GGIF <sup>[14]</sup>	0.08	22.09
ZF <sup>[29]</sup>	0.04	16.60
BFLS <sup>[42]</sup>	0.52	18.70
ILS <sup>[19]</sup>	0.44	21.10
DIP <sup>[43]</sup>	4.01	19.69
IPRH <sup>[30]</sup>	0.03	21.47
TH <sup>[44]</sup>	0.39	16.72
DeepFSPIS <sup>[45]</sup>	0.52	20.88
CSGIS <sup>[46]</sup>	0.34	19.16
PTF <sup>[47]</sup>	7.64	15.09
MGPNet <sup>[48]</sup>	0.36	16.86
QWLS <sup>[20]</sup>	0.19	20.27
PMN <sup>[49]</sup>	0.26	21.37
ALSP <sup>[50]</sup>	0.04	15.81
LLF-LUT++ <sup>[51]</sup>	0.18	12.37
NCC-PLM <sup>[52]</sup>	0.07	24.43
LFDM (本文)	<b>1.39</b>	<b>25.12</b>

出综合性能的平衡。

### 3.9 噪声干扰对细节增强性能的影响评估

噪声是影响图像的因素之一。为评估细节增强算法在噪声环境中的适应性,本研究进行高斯噪声和椒盐噪声条件下的对比分析,如图 11~13 所示。实验发现,一些方法在噪声条件下表现不佳,在图 11 中,TH<sup>[44]</sup> 在芯片引脚处的图像质量明显下降;在图 12 中,GGIF<sup>[14]</sup>、BFLS<sup>[42]</sup> 与 TH<sup>[44]</sup> 均改变了图像的对比度。图 13 展示了在不同强度椒盐噪声下,




图 11 RealSRSet 数据集中 chip 图像在高斯噪声干扰下的细节增强结果对比图

Fig. 11 The comparison of detail enhancement results for the chip image with Gaussian noise interference in the RealSRSet dataset

本研究算法的实际效果。由图 13 可知,噪声强度越高,图像细节增强效果越差。




图 12 RealSRSet 数据集中 dped\_crop00061 图像在椒盐噪声下的细节增强结果对比图

Fig. 12 The comparison of detail enhancement results for the dped\_crop00061 image with salt-and-pepper noise interference in the RealSRSet dataset




图 13 BSDS200 数据集中 317080 图像在不同强度椒盐噪声下的细节增强结果对比图

Fig. 13 The comparison of detail enhancement results for the 317080 image under varying levels of salt-and-pepper noise interference in the BSDS200 dataset

综合来看,图像细节增强算法在面对多类型、多强度噪声时性能会下降,其本质原因在于,图像细节增强模型并非图像修复类模型,该类模型默认图像中的所有信息均为有效数据,因而对噪声成分缺乏辨识与抑制,导致其被无差别放大。

### 3.10 残差特征比较

为进一步验证所提方法在图像细节增强方面的有效性,本研究开展残差特征的可视化实验。通过计算细节增强结果与原始图像间的差异来构建热力图(如图 14 和图 15 所示),以评估不同算法的结构保持能力。

实验结果表明,所提算法生成的残差图整体偏蓝,说明增强图与原图在结构上高度一致。而图中其他算法残差图中出现较多红色高亮区域,如图 14 中,ILS<sup>[19]</sup>、CSGIS<sup>[46]</sup> 残差图整体结构混乱,未能有针对性地增强图像细节,而 WGIF<sup>[13]</sup>、ZF<sup>[29]</sup> 和 TH<sup>[44]</sup> 则在图像中引入过多无关信息。图 15 中, WGIF<sup>[13]</sup>、ILS<sup>[19]</sup>、TH<sup>[44]</sup> 和 CSGIS<sup>[46]</sup> 中原本应呈深蓝的背景区域却表现出显著亮块,说明其在细节层中引入较多非结构性信息。综上,LFDM 在细节增

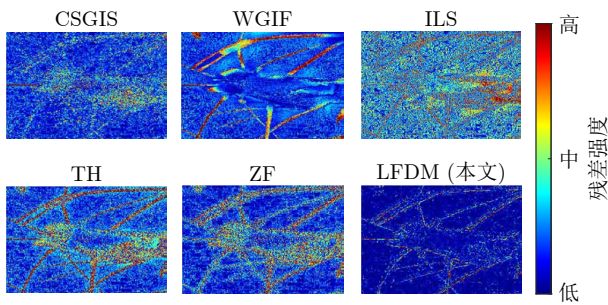


图 14 RealSRSet 数据集中不同方法的 painting 残差特征对比图

Fig. 14 Residual feature map comparison of different methods on the painting image from the RealSRSet dataset

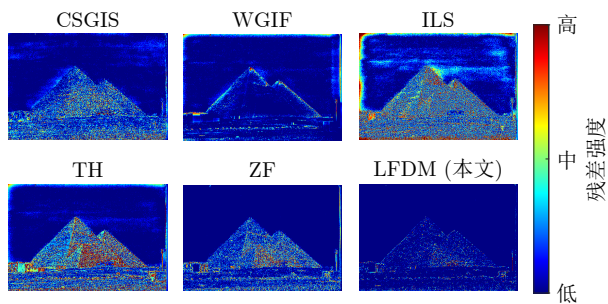


图 15 BSDS200 数据集中不同方法的 161062 残差特征对比图

Fig. 15 Residual feature map comparison of different methods on the 161062 image from the BSDS200 dataset

强过程中表现出更强的结构保持能力, 增强效果更加聚焦于图像的真实细节与本征特征.

### 3.11 强度曲线对比分析

强度曲线是一种常用的图像可视化分析手段, 通过绘制图像中随机选取的水平像素线的灰度分布, 可直观反映局部结构与细节变化.

由于图像边缘常对应灰度的突变区域, 强度曲线可用于评估算法的边缘保持能力与梯度信息保留效果. 如图 16 所示, 在 T91<sup>[41]</sup> 数据集中的 tt14 图像中随机抽取一条水平像素线进行对比实验. 结果表明, LFDM 在强度突变区域表现出更高的拟合精度, 其强度曲线与 GT 之间的趋势一致性优于其他对比算法. 基于该可视化结果, 可以进一步佐证本研究提算法在图像细节增强任务中展现出的优越的边缘保持能力.

### 3.12 不同方法的图像纹理特征对比分析

相较于传统的边缘与纹理度量模型 (如梯度能量、小波能量) 以及近年来广泛应用的深度学习模型, LFDM 在细节捕捉与纹理复杂度表征方面展现

出一定优势. 该方法通过多尺度卷积与回归分析的协同作用, 实现从像素级到区域级的连续尺度建模. 多尺度卷积能够自适应地捕获不同层次的局部特征, 有效克服传统梯度能量只能在单一尺度下度量边缘强度以及小波能量虽然具有多尺度分解能力但尺度分辨率有限、易忽略细微结构的不足. 在此基础上, 回归分析进一步通过对多尺度特征的拟合计算, 精确估计分形维数与分形长度, 从而在量化纹理复杂度的同时强化对弱纹理与细微结构的表征能力.

近年来, 深度学习方法虽然在图像细节增强任务中取得一定成果, 但需要大量人工标注数据, 且其模型性能高度依赖于训练集的多样性与准确性. 对于缺乏充分标签的真实场景或跨域任务, 这类基于监督的细节增强模型往往难以保持稳定的泛化性能. 相比之下, 本研究的分形策略不依赖人工标注数据, 通过对分形维数的自适应建模实现对图像内在纹理结构的刻画. 如图 17 所示, 与梯度能量<sup>[53]</sup>、小波能量<sup>[54]</sup> 以及深度学习算法 DeepFSPIS<sup>[45]</sup> 相比, LFDM 在处理 BSDS200<sup>[40]</sup> 数据集中编号为 56028 的图像时, 其细节和纹理特征更加清晰和细致.

具体而言, 梯度能量方法<sup>[53]</sup> 在强边缘处有强响应, 但在弱纹理区响应衰减; 小波能量方法<sup>[54]</sup> 易出现细节模糊或能量扩散现象; 深度学习方法 DeepFSPIS<sup>[45]</sup> 虽然具备全局特征提取能力, 但在弱边缘与细微纹理区域响应不稳定. 相比之下, 分形策略凭借优异的特征适应性, 能够更有效地捕捉图像细节和纹理, 为后续图像细节增强任务奠定基础.

### 3.13 算法适用性评估

为评估所提算法在不同应用场景下的适用性, 本文选取遥感图像与医学内窥镜图像进行分析 (图 18 和图 19). 图 18 的样本名为 062, 选自遥感数据集<sup>[55]</sup>; 图 19 的样本名为 seq24\_endocv22\_0043, 选自医学内窥镜数据集<sup>[56]</sup>.

从结果可以看出, 本文算法在特定场景下存在一定的局限性. 在遥感图像中, 对于较为空旷的区域, 算法依然具有细节增强能力. 例如, 在图 18 中, 蓝色矩形区域内的道路边缘及周围建筑边缘相比于 GT 更加清晰. 所谓“空旷区域”通常对应空间尺度较大的语义对象 (如道路或建筑), 这类区域在图像中具有相对较高的像素分辨率, 能够保留较充分的结构与纹理信息, 因此算法可在此类区域实现有效的细节恢复. 然而, 在图 18 中的红色矩形区域, 算法未能实现理想的细节增强. 该区域包含尺寸较小的语义目标 (如车辆), 其在成像时仅被少量像素表征, 因而可供利用的纹理信息有限. 由于原始分

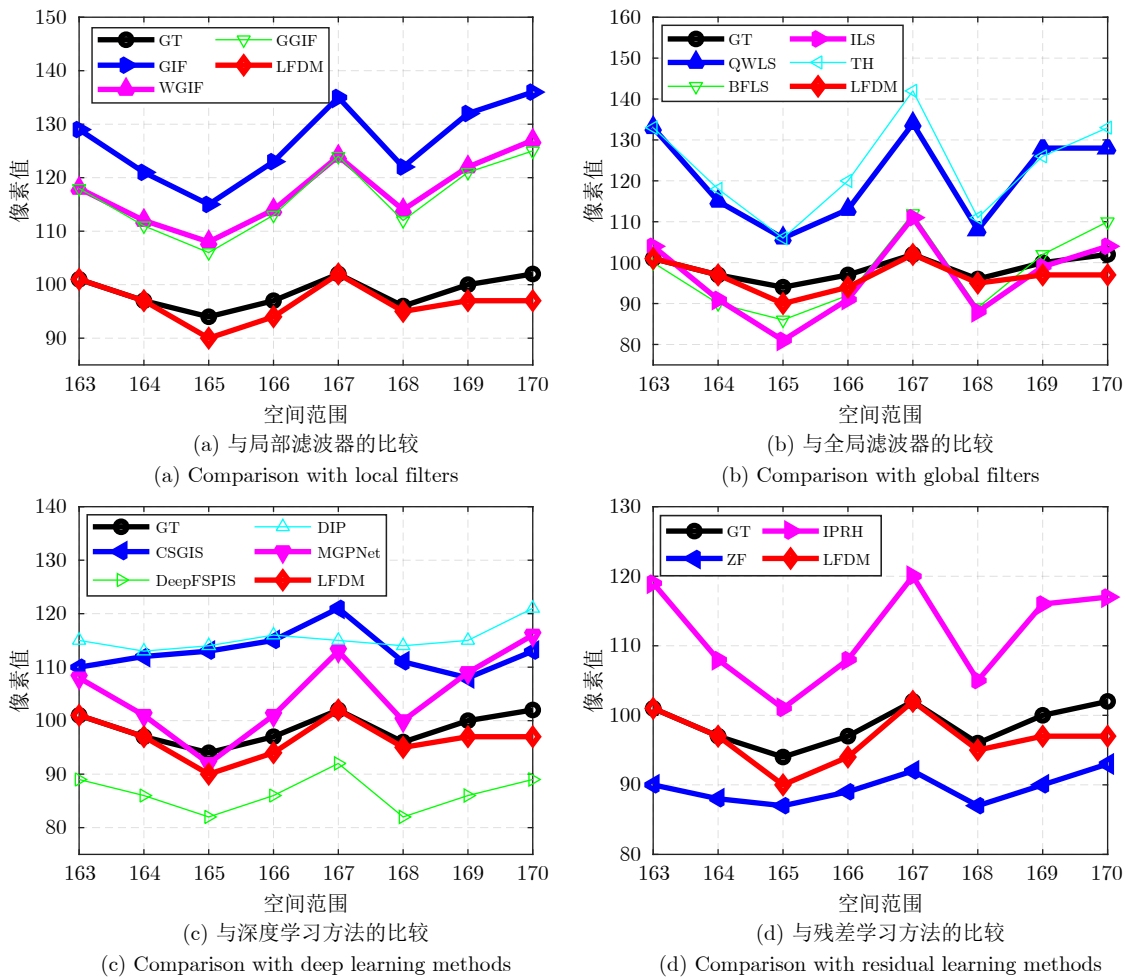


图 16 强度曲线

Fig.16 Intensity curves




图 17 不同特征度量方法在 BSDS200 数据集中的 56028 图像上获得的纹理与细节特征提取结果对比  
 Fig.17 Comparison of texture and detail feature extraction results of different feature measurement methods on image 56028 from the BSDS200 dataset

分辨率不足, 这些小尺度目标的边缘与结构特征在采样阶段已被严重压缩或丢失, 使得算法难以从有限的像素信息中提取真实细节. 此外, 此类区域还易受噪声的干扰. 由于细节增强算法默认将输入图像中的所有信号视为有效信息, 缺乏对噪声成分的认识



图 18 遥感图像场景下算法适用性评估

Fig.18 Evaluation of the algorithm applicability in remote sensing image scenarios

别与抑制机制, 因而将噪声误判为细节信号并进一步放大, 导致局部细节增强失败. 在医学内窥镜图像中, 本文算法在正常光照条件下对纹理区域依然能够发挥作用. 例如, 在图 19 中, 蓝色矩形框内肠道内壁薄膜上的血丝纹理得到有效的细节增强, 而红色矩形框内的低光照区域几乎没有发生变化. 这




图 19 医学内窥镜图像场景下算法适用性评估  
Fig.19 Evaluation of the algorithm applicability in endoscopic image scenarios

表明该算法在光照充足、细节明显的区域能够提升纹理可见性. 但在低光照区域, 由于成像信号本身蕴含的有效信息不足, 算法难以提取出有效的纹理特征, 因此细节增强效果相对有限.

#### 4 结束语

本研究提出一种基于局部分形维数最大化的单幅图像细节增强算法 (LFDM), 有效解决了现有算法性能受限、数据依赖性强、可解释性差等问题. 通过分析局部分形维数与图像纹理的映射关系, 构建数学模型, 最终提升图像的视觉表现力. 实验表明, 所提方法在多个公开数据集上表现出优秀的视觉效果与量化指标. 相较现有流行方法, LFDM 在细节恢复、边缘保持等方面具有一定优势, 展现出最大化局部分形维数在图像细节增强任务中的有效性与应用潜力.

然而, LFDM 仍存在一些局限性: 首先, 在强噪声条件下, 算法的性能会受到影响. 分形维数在刻画图像纹理复杂度的同时, 也对随机噪声表现出敏感响应, 使噪声区域在特征上与真实细节相似, 进而导致算法可能将噪声误识为结构信息并加以放大. 未来可从稳健分形估计与噪声感知建模两方面改进: 一是通过在分形分析过程中引入局部平滑机制; 二是结合轻量级去噪模块, 构建层次化增强框架, 以进一步提升算法在噪声环境下的泛化能力. 其次, 本方法的关键参数虽然通过大量消融实验确定了最优值, 但在不同应用场景下, 如遥感、医学场景中, 可能需要微调. 未来预期探索参数自适应策略, 例如通过计算每个块内分形维数的方差动态调整分块半径, 以在纹理复杂区域和平坦区域实现差异化细节增强; 类似地, 可根据图像整体或局部细节复杂度自适应调整最大尺度系数, 从而在保持增强效果的同时提升方法对不同图像类型的适应性. 最后, 算法的时间复杂度随图像尺寸与最大尺度系数的增大而快速增长, 成为运行时间的主要瓶颈.

未来工作可从以下两方面展开: 一方面通过引入快速卷积与局部自适应半径策略以降低卷积计算量; 另一方面探索基于矩阵分块的并行计算策略或 GPU 加速实现方法, 以降低整体计算开销, 以期进一步提升算法的速度.

#### 附录 A 推论 1 证明

**证明.** 对于点  $x$ , 有  $\ln f(g_r(x)) = \alpha(x) \ln(2r) + \mathcal{S}(x)$ . 由变换  $T(x) = nx$  和双李普希兹变换的性质可得:  $g_r(T(x)) = g_{r/n}(x)$ .

因此

$$\ln f(g_{r/n}(x)) = \alpha(x) \ln \frac{2r}{n} + \mathcal{S}(x) = \alpha(x) \ln(2r) + \mathcal{S}(x) - \alpha(x) \ln n$$

从而得到

$$\alpha_T(x) = \alpha(x), \quad \mathcal{S}_T(x) = \mathcal{S}(x) - \alpha(x) \ln n$$

□

#### 参考文献

- 1 Wang Yun-Tao, Zhao Lin, Liu Li-Man, Tao Wen-Bing. G-IDRN: A group-information distillation residual network for lightweight image super-resolution. *Acta Automatica Sinica*, 2024, **50**(10): 2063–2078  
(王云涛, 赵楠, 刘李漫, 陶文兵. 基于组-信息蒸馏残差网络的轻量级图像超分辨率重建. *自动化学报*, 2024, **50**(10): 2063–2078)
- 2 Li Yan, Ren Wen-Qi, Zhang Chang-Qing, Zhang Jin-Gang, Nie Yun-Feng. Super-resolution of endoscopic images based on real degradation estimation and high-frequency guidance. *Acta Automatica Sinica*, 2024, **50**(2): 334–347  
(李嫣, 任文琦, 张长青, 张金刚, 聂云峰. 基于真实退化估计与高频引导的内窥镜图像超分辨率重建. *自动化学报*, 2024, **50**(2): 334–347)
- 3 Liao Miao, Yang Rui-Xin, Zhao Yu-Qian, Di Shuan-Hu, Yang Zhen. Multi-organ segmentation from abdominal CT images based on CE TransNet. *Acta Automatica Sinica*, 2025, **51**(6): 1371–1387  
(廖苗, 杨睿新, 赵于前, 邸拴虎, 杨振. 基于 CE TransNet 的腹部 CT 图像多器官分割. *自动化学报*, 2025, **51**(6): 1371–1387)
- 4 Dong S W, Lu C H. Dynamically activated de-glaring and detail-recovery for low-light image enhancement directly on smart cameras. *IEEE Transactions on Emerging Topics in Computing*, 2024, **13**(1): 222–233
- 5 He Lei, Yi Zun-Hui, Xie Yong-Fang, Chen Chao-Yang, Lu Ming. Fast enhancement method for low light images guided by retinex prior. *Acta Automatica Sinica*, 2024, **50**(5): 1035–1046  
(何磊, 易遵辉, 谢永芳, 陈超洋, 卢明. 基于 Retinex 先验引导的低光照图像快速增强方法. *自动化学报*, 2024, **50**(5): 1035–1046)
- 6 Xie H, Qian K. Research on low-light image enhancement algorithm based on attention mechanism. *Journal of Advanced Computing Systems*, 2025, **5**(5): 1–14
- 7 Xu L T, Hu C H, Hu Y, Jing X Y, Cai Z Y, Lu X B. Upt-flow: Multi-scale transformer-guided normalizing flow for low-light image enhancement. *Pattern Recognition*, 2025, **158**: Article No. 111076
- 8 Luo Xiao-Tong, Yang Wen-Jin, Qu Yan-Yun, Xie Yuan. De-hazeforner: Nonhomogeneous image dehazing with collaborative global-local network. *Acta Automatica Sinica*, 2024, **50**(7): 1333–1344

- (罗小同, 杨汶锦, 曲延云, 谢源. 基于全局局部协同的非均匀图像去雾方法. *自动化学报*, 2024, **50**(7): 1333-1344)
- 9 Cui Y N, Wang Q, Li C P, Ren W Q, Knoll A. Eenet: An effective and efficient network for single image dehazing. *Pattern Recognition*, 2025, **158**: Article No. 111074
  - 10 Chen J Y, Ren W Q, Zhao H H, Xia Q B, Yang G B. You only need clear images: Self-supervised single image dehazing. *IEEE Transactions on Multimedia*, 2025, **27**: 5800-5814
  - 11 Ye Z H, Cho J H, Oh C J. Improving image de-raining using reference-guided transformers. In: Proceedings of the IEEE International Conference on Image Processing. Abu Dhabi, United Arab Emirates: IEEE, 2024. 1629-1634
  - 12 He K, Sun J, Tang X. Guided image filtering. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2012, **35**(6): 1397-1409
  - 13 Li Z, Zheng J, Zhu Z, Yao W, Wu S. Weighted guided image filtering. *IEEE Transactions on Image Processing*, 2014, **24**(1): 120-129
  - 14 Kou F, Chen W, Wen C, Li Z. Gradient domain guided image filtering. *IEEE Transactions on Image Processing*, 2015, **24**(11): 4528-4539
  - 15 Lu Z, Long B, Li K, Lu F. Effective guided image filtering for contrast enhancement. *IEEE Signal Processing Letters*, 2018, **25**(10): 1585-1589
  - 16 Rudin L I, Osher S, Fatemi E. Nonlinear total variation based noise removal algorithms. *Physica D: Nonlinear Phenomena*, 1992, **60**(1-4): 259-268
  - 17 Xu L, Lu C, Xu Y, Jia J. Image smoothing via 10 gradient minimization. In: Proceedings of the SIGGRAPH Asia Conference. Hong Kong, China: ACM, 2011. 1-12
  - 18 Li J, Han Y, Gao Y, Li Q, Wang S. An enhance relative total variation with bf model for edge-preserving image smoothing. *IEEE Transactions on Circuits and Systems for Video Technology*, 2023, **33**(10): 5420-5432
  - 19 Liu W, Zhang P, Huang X, Yang J, Shen C, Reid I. Real-time image smoothing via iterative least squares. *ACM Transactions on Graphics*, 2020, **39**(3): 1-24
  - 20 Liu W, Zhang P, Qin H, Huang X, Yang J, Ng M. Fast global image smoothing via quasi weighted least squares. *International Journal of Computer Vision*, 2024, **132**(12): 6039-6068
  - 21 Chen Chao-Yang, Hu Pan, He Lei, Yi Zun-Hui, Gui Wei-Hua. Fast enhancement method for underwater images based on relative total variation statistical line. *Acta Automatica Sinica*, 2025, **51**(8): 1869-1882  
(陈超洋, 胡盼, 何磊, 易遵辉, 桂卫华. 基于相对总变差统计线的水下图像快速增强方法. *自动化学报*, 2025, **51**(8): 1869-1882)
  - 22 Xu L, Ren J, Yan Q, Liao R, Jia J. Deep edge-aware filters. In: Proceedings of the International Conference on Machine Learning. Lille, France: PMLR, 2015. 1669-1678
  - 23 Liu S, Pan J, Yang M H. Learning recursive filters for low-level vision via a hybrid neural network. In: Proceedings of the European Conference on Computer Vision. Amsterdam, the Netherlands: Springer, 2016. 560-576
  - 24 Fan Q, Yang J, Hua G, Chen B, Wipf D. A generic deep architecture for single image reflection removal and image smoothing. In: Proceedings of the IEEE International Conference on Computer Vision. Venice, Italy: IEEE, 2017. 3238-3247
  - 25 Yang Y, Tang L, Yan T, Zeng L, Shen X, Zhan Y. Parameterized  $L_0$  image smoothing with unsupervised learning. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2024, **8**(2): 1938-1951
  - 26 Zhang F, Tian M, Li Z, Xu B, Lu Q, Gao C, et al. Lookup table meets local Laplacian filter: Pyramid reconstruction network for tone mapping. *Advances in Neural Information Processing Systems*, 2023, **36**: 57558-57569
  - 27 Qi H, Tan S, Luo X. Self-supervised dual generative networks for edge-preserving image smoothing. In: Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing. Seoul, South Korea: IEEE, 2024. 7215-7219
  - 28 Kim D, Park J, Jung J, Kim T, Paik J. Lens distortion correction and enhancement based on local self-similarity for high-quality consumer imaging systems. *IEEE Transactions on Consumer Electronics*, 2014, **60**(1): 18-22
  - 29 Tao X, Zhou C, Shen X, Wang J, Jia J. Zero-order reverse filtering. In: Proceedings of the IEEE International Conference on Computer Vision. Venice, Italy: IEEE, 2017. 222-230
  - 30 Jiang H, Asad M, Huang X, Yang J. Learning in-place residual homogeneity for single image detail enhancement. *Journal of Electronic Imaging*, 2020, **29**(4): Article No. 043016
  - 31 Varma M, Garg R. Locally invariant fractal features for statistical texture classification. In: Proceedings of the IEEE International Conference on Computer Vision. Rio de Janeiro, Brazil: IEEE, 2007. 1-8
  - 32 Xu Y, Ji H, Fermüller C. Viewpoint invariant texture description using fractal analysis. *International Journal of Computer Vision*, 2009, **83**(1): 85-100
  - 33 Pentland A P. Fractal-based description of natural scenes. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1984, **6**: 661-674
  - 34 Zeyde R, Elad M, Protter M. On single image scale-up using sparse-representations. In: Proceedings of the International Conference on Curves and Surfaces. Avignon, France: Springer, 2010. 711-730
  - 35 Xu Y, Ji H, Fermüller C. A projective invariant for textures. In: Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. New York, USA: IEEE, 2006. 1932-1939
  - 36 Xu Y, Quan Y, Ling H, Ji H. Dynamic texture classification using dynamic fractal analysis. In: Proceedings of the International Conference on Computer Vision. Barcelona, Spain: IEEE, 2011. 1219-1226
  - 37 Cannon J W. *The Fractal Geometry of Nature*. By Benoit B. Mandelbrot. *The American Mathematical Monthly*, 1984, **91**(9): 594-598
  - 38 Falconer K. *Fractal Geometry: Mathematical Foundations and Applications*. Hoboken: John Wiley & Sons, 2013.
  - 39 Zhang K, Liang J, van Gool L, Timofte R. Designing a practical degradation model for deep blind image super-resolution. In: Proceedings of the IEEE International Conference on Computer Vision. Montreal, Canada: IEEE, 2021. 4791-4800
  - 40 Arbelaez P, Maire M, Fowlkes C, Malik J. Contour detection and hierarchical image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2010, **33**(5): 898-916
  - 41 Dong C, Loy C C, He K, Tang X. Learning a deep convolutional network for image super-resolution. In: Proceedings of the European Conference on Computer Vision. Zurich, Switzerland: Springer, 2014. 184-199
  - 42 Liu W, Zhang P, Chen X, Shen C, Huang X, Yang J. Embedding bilateral filter in least squares for efficient edge-preserving image smoothing. *IEEE Transactions on Circuits and Systems for Video Technology*, 2018, **30**(1): 23-35
  - 43 Ulyanov D, Vedaldi A, Lempitsky V. Deep image prior. *International Journal of Computer Vision*, 2020, **128**(7): 1867-1888
  - 44 Liu W, Zhang P, Lei Y, Huang X, Yang J, Ng M. A generalized framework for edge-preserving and structure-preserving image smoothing. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, **44**(10): 6631-6648
  - 45 Li M, Fu Y, Li X, Guo X. Deep flexible structure preserving image smoothing. In: Proceedings of the ACM International Conference on Multimedia. Lisbon, Portugal: ACM, 2022. 1875-1883
  - 46 Wang J, Wang Y, Feng Y, Gong L, Yan X, Xie H, et al. Contrastive semantic-guided image smoothing network. In: Proceed-

- ings of the Computer Graphics Forum. London, UK: Wiley Online Library, 2022. 335–346
- 47 Zhang Q, Jiang H, Nie Y, Zheng W S. Pyramid texture filtering. *ACM Transactions on Graphics*, 2023, **42**(4): 1–11
- 48 He X, Quan Y, Xu Y, Xu R. Image smoothing via multiscale global perception. *IEEE Signal Processing Letters*, 2024, **31**: 411–415
- 49 Feng H, Wang L, Wang Y, Fan H, Huang H. Learnability enhancement for low-light raw image denoising: A data perspective. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2024, **46**(1): 370–387
- 50 He L, Yi Z, Liu J, Chen C, Lu M, Chen Z. Alsp+: Fast scene recovery via ambient light similarity prior. *IEEE Transactions on Image Processing*, 2025, **34**: 4470–4484
- 51 Zhang F, Deng H, Li Z, Li L, Xu B, Lu Q, et al. High-resolution photo enhancement in real-time: A Laplacian pyramid network. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2026, **48**(3): 2170–2185
- 52 Kucuk S, Severoglu N, Demir Y, Kaplan N H. New color channel driven physical lighting model for low-light image enhancement. *Digital Signal Processing*, 2025, **156**: Article No. 104757
- 53 Li X, Zhou F, Tan H, Zhang W, Zhao C. Multimodal medical image fusion based on joint bilateral filter and local gradient energy. *Information Sciences*, 2021, **569**: 302–325
- 54 Pun C M, Lee M C. Log-polar wavelet energy signatures for rotation and scale invariant texture classification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2003, **25**(5): 590–603
- 55 Cheng G, Han J, Zhou P, Guo L. Multi-class geospatial object detection and geographic image classification based on collection of part detectors. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2014, **98**: 119–132
- 56 Garcia-Vega A, Ochoa G, Espinosa R. Endoscopic real-synthetic over- and underexposed frames for image enhancement. *Mendeley Data*, DOI: 10.17632/3j3tmghw33.1



**江 鹤** 中国矿业大学信息与控制工程学院讲师。主要研究方向为图像复原与增强, 检测与识别。

E-mail: jianghe@cumt.edu.cn

**(JIANG He** Lecturer at the School of Information and Control Engineering, China University of Mining and Technology. His research interests include image restoration and enhancement, detection and recognition.)



**乙夫迪** 中国矿业大学信息与控制工程学院硕士研究生。主要研究方向为图像细节增强算法和图像超分辨率重建。

E-mail: yifudi@cumt.edu.cn

**(YI Fu-Di** Master student at the School of Information and Control Engineering, China University of Mining and Techno-

logy. His research interests include image detail enhancement algorithm and image super-resolution reconstruction.)



**郑 州** 中国矿业大学信息与控制工程学院硕士研究生。主要研究方向为图像细节增强算法和图像超分辨率重建。

E-mail: zhengzhou@cumt.edu.cn

**(ZHENG Zhou** Master student at the School of Information and Control Engineering, China University of Mining and Technology. His research interests include image detail enhancement algorithm and image super-resolution reconstruction.)



**顾 豪** 中国矿业大学信息与控制工程学院硕士研究生。主要研究方向为图像细节增强算法和图像超分辨率重建。E-mail: guhao@cumt.edu.cn

**(GU Hao** Master student at the School of Information and Control Engineering, China University of

Mining and Technology. His research interests include image detail enhancement algorithm and image super-resolution reconstruction.)



**寇旗旗** 中国矿业大学计算机科学与技术学院副教授。主要研究方向为图像超分辨率重建, 图像增强算法。

E-mail: kouqiqi@cumt.edu.cn

**(KOU Qi-Qi** Associate professor at the School of Computer Science and Technology, China University of Mining and Technology. His research interests include image super-resolution reconstruction and image enhancement algorithms.)



**程德强** 中国矿业大学信息与控制工程学院教授。主要研究方向为计算机视觉, 图像处理。本文通信作者。

E-mail: chengdq@cumt.edu.cn

**(CHENG De-Qiang** Professor at the School of Information and Control Engineering, China University of Mining and Technology. His research interests include computer vision and image processing. Corresponding author of this paper.)