

基于边窗的共现变分保边平滑算法

吴仪芳^{1,2,3}, 高 银^{2,3}, 李 俊^{1,2,3}

(1. 福建师范大学 计算机与网络空间安全学院, 福州 350117;

2. 中国科学院 福建物质结构研究所, 福州 350108;

3. 中国科学院 海西研究院泉州装备制造研究中心, 泉州 362200)

摘要: 针对图像平滑过程中边缘模糊及小尺度结构丢失的问题, 提出了一种基于边窗的共现变分保边平滑算法; 该算法通过共现滤波方法, 利用其核心思想共现矩阵的特性, 能够为结构区域与纹理区域的梯度差异提供更准确的衡量, 进一步提高相对权重的差异; 提出一种改进的边窗高斯滤波器, 结合方向一致性原理, 设计了新的边窗选择机制, 能够更全面地选择合适的边窗; 首次将改进的边窗高斯滤波与全局优化框架结合, 在结构区域的边缘处表现出更强的引导, 更倾向于抑制纹理; 经实验验证, 所提算法在平滑效果、边缘保留以及小尺度结构保持方面优于经典算法与先进算法, 具备较强鲁棒性和优越性; 此外, 所提算法在 SSIM 和 GMSD 指标上均取得最优值 0.994 45 和 0.001 032 4, 在 PSNR 和 SCOOT 指标上取得次优值 40.244 8 和 0.776 45。

关键词: 图像平滑; 边窗高斯滤波; 共现滤波; 变分模型; 边缘与结构保持

Co-occurrence Variational Edge-preserving Image Smoothing Algorithm Based on Side Windows

WU Yifang^{1,2,3}, GAO Yin^{2,3}, LI Jun^{1,2,3}

(1. College of Computer and Cyber Security, Fujian Normal University, Fuzhou 350117, China;

2. Fujian Institute of Research on the Structure of Matter, CAS, Fuzhou 350108, China;

3. Quanzhou Institute of Equipment Manufacturing, Haixi Insitute, CAS, Quanzhou 362200, China)

Abstract: Aiming at the issues of edge blurring and small-scale structure loss during image smoothing, a co-occurrence variational edge-preserving image smoothing algorithm based on side windows is proposed; The algorithm adopts a co-occurrence filtering method and the characteristics of the co-occurrence matrix, which is its core idea, to provide more accurate measure for gradient difference between structural region and textural region, and further improves the difference of relative weights; An improved side window Gaussian filter is proposed. Combined with the principle of directional consistency, a novel side window selection mechanism is designed, which can select suitable side windows more comprehensively; The improved side window Gaussian filter is combined with the global optimization framework for the first time, which exhibits stronger guidance at the edge of structural region and is more inclined to suppress the texture; Experimental verification shows that the proposed algorithm is superior to classical algorithms and advanced algorithms in the smoothing effect, edge preservation and small-scale structure preservation, and has strong robustness and superiority; In addition, the proposed algorithm achieves the optimal values of 0.994 45 and 0.001 032 4 in structural similarity index (SSIM) and gradient magnitude similarity deviation (GMSD) metrics, and the suboptimal values of 40.244 8 and 0.776 45 in peak signal-to-noise ratio (PSNR) and structure co-occurrence texture (SCOOT) metrics.

Keywords: image smoothing; side window Gaussian filter; co-occurrence filtering; total variation model; edge/structure-preserving

收稿日期:2025-01-16; 修回日期:2025-02-13。

基金项目:国家自然科学基金(62001452);福建省科技计划项目(2023T3040)。

作者简介:吴仪芳(1999-),女,硕士研究生。

通讯作者:李 俊(1979-),男,博士,研究员。

引用格式:吴仪芳,高 银,李 俊.基于边窗的共现变分保边平滑算法[J].计算机测量与控制,2025,33(6):278-287.

0 引言

图像平滑作为图像处理领域中的重要基础问题,旨在去除纹理,同时保留结构和边缘,提高图像的可解释性和可处理性。得益于这些特性,图像平滑技术广泛应用于图像细节增强^[1]、图像去雾、HDR色调映射、压缩伪影去除^[2]、边缘检测^[3]等各种领域。然而,诸如遥感图像处理和医疗图像处理等此类任务对平滑图像质量的要求较高^[4],平滑领域中关于保留清晰边缘及小尺度结构的研究成为当前的一大挑战。

主流的图像平滑方法可分为传统方法和基于深度学习的方法。根据平滑过程中的处理范围,传统方法又可分为基于局部滤波的方法和基于全局优化的方法。

基于局部滤波的方法又称为基于核的方法,其基本思想是利用定义的滤波核对邻域窗口内的像素进行加权,得到新的滤波结果。双边滤波器(BF, bilateral filter)^[5]是早期最具代表性的局部滤波方法。该方法通过结合像素的空间邻近度和像素值相似度来进行加权平均,提高边缘保持能力,但无法有效判别高对比度纹理,且计算量较大。对此,联合双边滤波器(JBF, joint bilateral filter)^[6]引入导向图计算权重,对纹理进行抑制。加速双边滤波^[7-9]的算法也相继被提出。由于这些方法采用的参考信息较为局限,仍然不能较好地分离结构与纹理,易导致平滑区域内色块杂乱。因此,许多学者基于高斯滤波提供的信息进行改进,提出许多代表性工作,包括引导滤波(GIF, guided image filter)^[10]、加权引导滤波器(WGIF, weighted guided image filter)^[11]、滚动引导滤波器(RGF, rolling guided filter)^[12]、迭代自引导图像滤波(ISGIF, iterative self-guided image filter)^[13]等一系列基于引导的滤波器。此外,各向异性扩散滤波器(anisotropic diffusion filter)^[14]、局部拉普拉斯金字塔(LLF, local laplacian filter)^[15]、树滤波(TF, tree filter)^[16]等局部滤波方法基于不同的理论基础被提出。近年来,文献[17]提出边窗滤波(SWF, side window filter),该技术将窗口的侧面或角落与正在处理的像素对齐,可以显著提升边缘保持能力,并有效防止伪影现象。在此基础上,边窗框架相继被引入局部滤波方法,边窗引导滤波(SWGF, side window guided filter)^[18]、边窗加权中值图像滤波(SWWMIF, side window weighted median image filter)^[19]、基于加权边窗的梯度引导图像滤波(WSG-GIF, weighted side-window based gradient guided image filter)^[20]等边窗与局部滤波相结合的算法相继被提出,成为目前的研究热点之一。这些改进的局部滤波方法虽在平滑图像质量上有较大提升,但受限于局部滤波自身思想的限制,往往仅利用局部信息,容易导致梯度反

转、光晕伪影等现象,并难以较好地分辨复杂纹理场景中的结构与纹理。

针对局部滤波方法的局限,基于全局优化的方法被提出。全局优化方法通过构建一个目标函数,对其进行迭代优化得到最终解。该目标函数通常包含数据保真项和正则化项。数据保真项要求求解结果与原始输入之间的差异尽可能小,正则化项则通过定义约束来惩罚纹理,实现平滑。正则化项可基于不同的数学原理和物理意义来定义。根据 L_1 、 L_2 、 L_3 这3种不同的范数,文献[21]提出 L_0 梯度最小化,通过控制非零梯度的数量来实现纹理去除。文献[22]提出 L_1 图像保边平滑,生成了近乎分段常数的图像,具有稀疏结构。文献[23]提出加权最小二乘(WLS, weighted least square)。在此基础上,基于范数的改进滤波器相继被提出。文献[24]提出尺度感知引导滤波器,通过结合 L_0 范数与 H^{-1} 范数来保持结构。文献[25]基于全局 L_1 稀疏分解和可变参数的框架,提出了一种能够自适应处理不同结构与纹理的平滑方法。文献[26]提出一种新的基于全局优化的迭代最小二乘(ILS, iterative least squares)来保持边缘。此外,经典的全变分模型能够滤除不规则纹理,是近年来的一大研究热点。为了获得更好的平滑质量与效率,文献[27]提出经典的相对全变分(RTV, relative total variation),有效提升了结构与纹理的分离能力。在此基础上,许多学者基于变分的思想提出相应的变体。文献[28]提出了一种基于邻域的修正相对全变分(mRTV, modified relative total variation),能够有效去除纹理。随后,文献[29]在mRTV模型的基础上提出双尺度切换辅助DASM进行结构与纹理的区分。最近,文献[30]提出一种尺度感知双边全变分(BTV, bilateral total variation)以更好地区分弱边缘结构和小结构。基于全局优化的方法利用全局信息确保在整幅图像内的平滑一致性,该特性有助于有效避免梯度反转与光晕伪影等现象。

随着深度学习的发展,基于深度学习的方法被引入到图像平滑领域。2015年,文献[31]结合梯度域信息进行网络训练,提出一种基于卷积神经网络(CNN, convolutional neural network)的保边滤波算子,能够近似已提出的滤波算子,从而快速实现相似的平滑。随后,文献[32]提出一种新的递归滤波方法,该方法引入混合神经网络模型,融合了循环神经网络(RNN, recurrent neural network)和CNN,具备较小的模型规模以及较快的平滑速度。此外,文献[33]采用双分支结构模拟联合图像滤波器。文献[34]将ResNet和VDCNN作为基准网络,设计了一个新颖的损失函数进行训练,并创新性地构建了一个专注于评估边缘保留图像平滑方法的大规模基准。然而,上述有监督学习方法

依赖于大量的数据集。基于深度学习的方法目前不存在统一的地面真值图像 (GT, ground truth)。当前图像平滑领域中提出的 GT 数据集大多是由学者自行利用传统滤波算法生成的结果, 或利用合成纹理图像及其对应 GT 所构建, 限制了深度学习方法在平滑任务中的训练效果, 导致得到的平滑效果不佳, 或平滑场景单一, 无法应对复杂纹理场景的平滑。近年来, 基于无监督的学习或半监督的学习方法是一个新的研究方向。文献 [35] 提出了一个无监督的学习框架, 本质上是通过深度学习解决传统优化问题。2020 年, 文献 [36] 提出了一种半监督的方法, 利用有限的标记数据和大量的无标记数据来训练生成对抗网络 (GAN, generative adversarial network), 这是半监督学习在纹理平滑中的首次应用。2024 年, 文献 [37] 提出了一种迭代无监督的深度双边纹理滤波网络, 该网络引入双边纹理损失函数来训练模型。文献 [38] 提出了一种基于深度无监督学习的 L_0 正则化优化问题的高效解决方案。上述方法虽然能够解决数据依赖的问题, 但训练完后往往只能产生一种平滑效果, 平滑效果难以灵活调整, 泛用性较差, 复杂纹理场景下易出现平滑不足的情况。

在复杂纹理场景的图像平滑中, 仍然存在边缘模糊、小尺度结构丢失的现象。本文通过大量的实验分析发现, 这些问题的根本原因在于结构区域的边缘在迭代平滑中逐渐损失。因此, 引入导向性结构设计以保持结构区域的边缘具有重要意义。在全局优化框架的基础上, 本文提出了一种基于边窗的共现变分保边平滑算法, 主要贡献如下:

1) 提出一种新的正则化项, 称之为共现变分, 利用共现滤波与共现矩阵的特性, 进一步提升对结构与纹理的区分。

2) 提出一种改进的边窗高斯滤波器, 并将其首次与全局优化框架结合, 实现在结构区域内边缘的导向, 在优化过程中不断引导平滑。

3) 主客观实验证明了该算法的优越性, 能够有效解决边缘模糊、小尺度结构丢失的问题, 实现高质量的图像平滑。

1 相对全变分模型与边窗滤波原理

在图像平滑领域, 相对全变分 (RTV) 和边窗滤波 (SWF) 是两种经典的方法, 并得到广泛关注。相对全变分利用相对权重有效区分结构与纹理, 实现有效的纹理平滑。而边窗滤波技术作为一种可嵌入的滤波框架, 能够保证位于边缘的像素的滤波结果最接近初始值, 从而达到良好的边缘保留性能。因此, 在本章中, 将详细介绍两种方法的基本原理, 作为后续研究的基础。

1.1 相对全变分

全局优化函数通常由数据保真度项和正则化项两个不同的部分组成:

$$E(S) = E_{\text{data}}(S) + \lambda_{\text{reg}} E_{\text{reg}}(S) \quad (1)$$

式中, λ_{reg} 为正则化项的权值。S 是平滑后的图像。数据保真度项 E_{data} 保证平滑后的图像 S 与原始输入图像 I 在一定程度上相似。正则化项 E_{reg} 指导平滑过程, 在保留图像结构和边缘的同时抑制纹理。相对全变分是几种典型的正则化项之一。

给定输入图像 I, 得到 RTV 平滑后的输出图像 S 作为目标函数的最优值:

$$\arg \min_S \sum_p \|S_p - I_p\|_2^2 + \lambda_r \cdot \left(\left\| \frac{D_x(p)}{L_x(p) + \epsilon} \right\|_1 + \left\| \frac{D_y(p)}{L_y(p) + \epsilon} \right\|_1 \right) \quad (2)$$

式中, $\|\cdot\|_2$ 为 L_2 范数, $\|\cdot\|_1$ 为 L_1 范数。为了避免被 0 整除, ϵ 是一个极小正值。 D_x 和 D_y 是 x 和 y 方向上的加窗总变分 (WTV)。类似地, L_x 和 L_y 是窗口固有变分 (WIV)。在 x 方向上, WTV 和 WIV 可表示为:

$$\begin{cases} D_x(p) = \sum_{q \in \Omega(p)} G_{p,q} * |(\nabla_x S)_q| \\ L_x(p) = \left| \sum_{q \in \Omega(p)} G_{p,q} * (\nabla_x S)_q \right| \end{cases} \quad (3)$$

同理, 可知 y 方向的 WTV 和 WIV:

$$\begin{cases} D_y(p) = \sum_{q \in \Omega(p)} G_{p,q} * |(\nabla_y S)_q| \\ L_y(p) = \left| \sum_{q \in \Omega(p)} G_{p,q} * (\nabla_y S)_q \right| \end{cases} \quad (4)$$

式中, q 是以 p 为中心的邻域 Ω 中的一个像素。 $G_{p,q}$ 是一个权函数, 也是一个标准差为 σ 的高斯滤波器, 定义如下:

$$G_{p,q}(x, y) = \exp \left[-\frac{(x_p - x_q)^2 + (y_p - y_q)^2}{2\sigma^2} \right] \quad (5)$$

式中, (x, y) 为核的中心。

RTV 可以有效地分解图像中的结构和纹理, 而不必指定纹理是规则的还是对称的, 从而提高了结构与纹理分离的质量。然而, 该方法区分结构区域内弱边缘和显著纹理区域内边缘的能力有限, 无法进一步区分相似尺度和形状的纹理与结构。

1.2 边窗滤波技术

边窗滤波技术^[17]认为导致许多滤波算法模糊边缘的根本原因之一在于将窗口中心与正在处理的像素对齐。基于这一见解, 提出边窗滤波技术, 该技术假设图像中的每个像素 p 都可能位于边缘上, 并且 p 所在的局部窗口可以位于 p 的任何一侧。因此, 重新定义的局部窗口仅将其一侧或角落与正在处理的像素对齐, 称之为边窗, 具体如图 1 所示。

图 1 构建了 8 个边窗, 分别为左边窗 (L, left)、右边窗 (R, right)、上边窗 (U, up)、下边窗 (D,

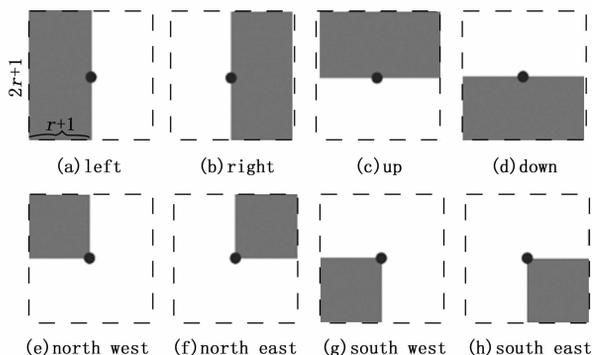


图1 八个边窗的示意图

down)、西北边窗 (NW, northwest)、东北边窗 (NE, northeast)、西南边窗 (SW, southwest)、东南边窗 (SE, southeast)。其中, 虚线方形窗口为滤波过程中采用的局部窗口, r 是窗口半径, 每个窗口中的暗区则是所定义的边窗, 黑点表示对应边窗正在处理的像素。可知, L、R、U、D 边窗的大小为传统窗口的一半, 而 NW、NE、SW、SE 边窗的大小为传统窗口的四分之一。本文中, 将所有边窗索引的集合记为 $sw = \{L, R, U, D, NW, NE, SW, SE\}$ 。

通过在以上定义的每个边窗中应用滤波核 F , 能够得到 8 个输出, 表示为:

$$I_{sw}^n = F(I), n \in sw \quad (6)$$

为了更好地保留边缘, 需要最小化边缘处输入与输出之间的距离。因此, 该技术选择与输入强度之间具备最小 L_2 距离的边窗作为最终输出:

$$I'_{sw} = I_{sw}^{\text{label}} \quad (7)$$

$$\text{label} = \arg \min_n \|I'_{sw} - I\|_2^2, n \in sw \quad (8)$$

式中, I'_{sw} 是边窗滤波的输出。式 (7) 和式 (8) 被称为边窗滤波技术。

2 基于边窗的共现变分保边平滑算法

针对复杂纹理平滑中边缘模糊、小尺度结构丢失的问题, 本文提出一种新的图像保边平滑算法。首先, 利用共现滤波的嵌入, 构造一种新的共现变分正则化项, 进一步扩大结构区域与纹理区域之间的权重差异, 更有效地抑制纹理。其次, 结合方向一致性原理, 设计新的边窗选择机制。在此基础上提出一种改进的边窗高斯滤波器, 并首次引入至优化框架中, 能够有效避免因像素点位于滤波窗口中心而导致的边缘模糊, 更好地保持结构区域的边缘强度, 从而增强与纹理区域的像素强度区分度。本文总结了所提算法的总体框架, 具体如算法 1 所示。

算法 1

输入: 输入图像 I , 平滑程度因子 λ , 平滑范围因子 σ , 迭代总次数 K

初始化: $S^0 \leftarrow I$

1) 通过公式 (19) 和 (20) 计算 u 和 w ;

2) 通过公式 (22) 和 (23) 求解线性方程组;

3) 若满足 $k > K$, 则停止迭代, 否则, 令 $k = k + 1$, 继续 1) 和 2);

输出: 输出图像 S

2.1 基于边窗的共现变分模型

根据式 (9) 和式 (10), 为了实现更优的平滑效果, 使纹理与结构的分离更彻底, 将共现滤波嵌入相对全变分中, 提出共现变分的概念, 其定义如下:

$$\begin{cases} CoD_{x,y}(p) = \sum_{q \in \Omega(p)} G_{p,q} * |[\nabla_{x,y} f(S)]_q| \\ CoL_{x,y}(p) = \sum_{q \in \Omega(p)} G_{p,q} * |\nabla_{x,y} f(S)_q| \end{cases} \quad (9)$$

式中, $f(\cdot) = \varphi_{S-\text{Mean}}[\varphi_{CoF}(\cdot)]$ 表示边窗均值滤波与共现滤波。边窗均值滤波能够抑制孤立纹理残留, 降低纹理强度。共现滤波的定义如下:

$$\varphi_{CoF}(I) = \frac{\sum_{q \in \Omega(p)} G_{p,q} \cdot \mathbf{M}(I_p, I_q) \cdot I_q}{\sum_{q \in \Omega(p)} G_{p,q} \cdot \mathbf{M}(I_p, I_q)} \quad (10)$$

式中, \mathbf{M} 是一个大小为 256×256 的矩阵, 基于共现矩阵所定义^[39]。

所提出的共现变分的优势在于充分利用了共现矩阵的统计特性和 RTV 的局部梯度优化特性, 提供了更明确的纹理判别依据, 实现了对纹理和结构的有效分离。

在此基础上, 受到边窗滤波技术的启发, 提出以下改进的边窗高斯滤波器:

$$G'_{p,q} = G_{p,q}^{\text{label}} \quad (11)$$

式中,

$$\text{label} = \arg \min_n |G_{p,q}^n \cdot f(S)_p - f(S)_p| + \beta \cdot |d_k - \theta(x, y)| \quad (12)$$

式中,

$$G_{p,q}^n(x, y) = \exp\left[-\frac{(x_p^n - x_q^n)^2 + (y_p^n - y_q^n)^2}{2\sigma^2}\right], n \in sw \quad (13)$$

$$d_k = \frac{2\pi(k-1)}{N}, D = \{d_k \mid k = 1, 2, \dots, N\} \quad (14)$$

$$\theta(x, y) = \arctan\left[\frac{\partial x(x, y)}{\partial y(x, y)}\right] \quad (15)$$

式中, d_k 表示离散方向。 $\theta(x, y)$ 表示像素点 (x, y) 的梯度方向。 $N = 8$ 表示存在 8 个离散方向。

高斯滤波器仅采用传统的窗口滤波方式, 即将输入像素放置于邻域窗口的中心。这种方式将导致边缘像素和非边缘像素值的混淆, 使得边缘像素变相地被平滑, 结构区内的边缘梯度损失。而边窗高斯滤波器通过设置八种边窗, 并将输入像素放置于邻域窗口的一侧或角落, 避免了与其余部分的非边缘像素进行混合, 几乎能够完全地保持边缘强度。最终, 边窗高斯滤波器仅根据所计算的 8 个边窗的强度相似性 $|G_{p,q}^n \cdot f(S)_p - f(S)_p|$

来选择最为合适的边窗。

改进的边窗高斯滤波器根据 $|G_{p,q}^n \cdot f(S)_p - f(S)_p|$ 和 $|d_k - \theta(x, y)|$ 分别计算强度相似性与方向一致性进行目标像素点的窗口选择。通过引入方向一致性测度 $|d_k - \theta(x, y)|$, 计算梯度方向和离散方向的距离。这种方式能够综合考虑像素值与离散方向投影值的偏差, 以及梯度方向一致性的偏差, 最终采用加权的方式选择最优方向的边窗, 即选择使式 (12) 为最小值的一个边窗记为 label, 将其代入式 (11) 计算对应的边窗高斯滤波值。

将共现变分与改进的边窗高斯滤波器结合, 提出一种基于边窗的共现变分保边平滑算法, 其最终的模型构造如下:

$$\arg \min_S \sum_p \|S_p - I_p\|_2^2 + \lambda \cdot \left(\left\| \frac{CoD'_x(p)}{CoL'_x(p) + \epsilon} \right\|_1 + \left\| \frac{CoD'_y(p)}{CoL'_y(p) + \epsilon} \right\|_1 \right) \quad (16)$$

其中:

$$\begin{cases} CoD'_{x,y}(p) = \sum_{q \in \Omega(p)} G'_{p,q} * |\nabla_{x,y} f(S)|_q \\ CoL'_{x,y}(p) = \left| \sum_{q \in \Omega(p)} G'_{p,q} * \nabla_{x,y} f(S) \right|_q \end{cases} \quad (17)$$

2.2 模型求解

式 (16) 中, L_1 范数导致直接求解困难, 且计算复杂度较高。为了解决该问题, 基于目标函数和二次惩罚项的线性优化, 共现变分正则化项能够进行以下近似, 被分解为二次项和非线性项:

$$\begin{aligned} \sum_p \left\| \frac{CoD'_{x,y}(p)}{CoL'_{x,y}(p) + \epsilon} \right\|_1 &= \\ \sum_q \left\{ \frac{\sum_{p \in \Omega(q)} G'_{p,q}}{\left| \sum_{q \in \Omega(p)} G_{p,q} * |\nabla_{x,y} f(S)|_q \right| + \epsilon} \right\} & \\ \|\nabla_{x,y} f(S)\|_q \approx \sum_q \left(\frac{\sum_{p \in \Omega(q)} G'_{p,q}}{CoL'_{x,y}(p) + \epsilon} \right) \cdot & \\ \frac{1}{\left| \nabla_{x,y} f(S) \right|_q + \epsilon_s} \|\nabla_{x,y} f(S)\|_q^2 &= \\ \sum_q u_{x,y} w_{x,y} \|\nabla_{x,y} f(S)\|_q^2 & \end{aligned} \quad (18)$$

式中, ϵ_s 是一个小的正数, 根据经验设置为 $\epsilon_s = 0.001$ 以避免分母为零。 $\|\nabla_{x,y} f(S)\|_q^2$ 和 $u_{x,y} w_{x,y}$ 分别为分解后的二次项和非线性部分, 即:

$$u_{x,y} = \sum_{p \in \Omega(q)} \frac{G'_{p,q}}{CoL'_{x,y}(p) + \epsilon} \quad (19)$$

$$w_{x,y} = \frac{1}{\left| \nabla_{x,y} f(S) \right|_q + \epsilon_s} \quad (20)$$

通过引入变量 $u_{x,y}$ 和 $w_{x,y}$, 式 (16) 可以重写为:

$$\arg \min_S \sum_q \|S - I\|_2^2 + \lambda \cdot u_{x,y} w_{x,y} \|\nabla_{x,y} f(S)\|_q^2 \quad (21)$$

实际求解中分为 x 水平方向和 y 垂直方向求解, 将

重写后的全局优化框架用矩阵形式表示:

$$\arg \min_S (S - I)^T (S - I) + \lambda \cdot (S_x^T D_x^T U_x W_x D_x S + S_y^T D_y^T U_y W_y D_y S) \quad (22)$$

式中, D_x 和 D_y 是具有前向差分的离散梯度算子的 Toeplitz 矩阵。 $U_{x,y}$ 和 $W_{x,y}$ 是包含权重 $u_{x,y}$ 和 $w_{x,y}$ 的对角矩阵。通过将式 (22) 中关于的导数设置为 0, 可得:

$$(S - I) + \lambda \cdot (D_x^T U_x W_x D_x + D_y^T U_y W_y D_y) S = 0 \quad (23)$$

优化框架可转化为求解一系列线性方程组, 得到优化结果:

$$S = (I + \lambda L)^{-1} I \quad (24)$$

式中, I 是单位矩阵, $L = D_x^T U_x W_x D_x + D_y^T U_y W_y D_y$ 是稀疏五点定拉普拉斯矩阵。算法采用迭代优化策略得到最终的平滑图像:

$$S^t = (I + \lambda L^{t-1})^{-1} I^{t-1} \quad (25)$$

式中, S^t 表示第 t 次迭代的平滑结果。在迭代初始时, $S^0 = I$ 。此外, 在迭代过程中 $L^{t-1} = D_x^T U_x^{t-1} W_x^{-1} D_x + D_y^T U_y^{t-1} W_y^{-1} D_y$ 。

本研究采用预条件共轭梯度 (PCG, preconditioned conjugate gradient) 技术进行求解。

3 实验结果与分析

为验证本文算法的平滑效果, 通过定性分析和定量分析对以下 5 种经典的平滑方法进行比较: 边窗滤波器 (SWF, side window filter)^[17]、相对全变分 (RTV, relative total variation)^[27]、基于 BF 模型的增强相对全变分 (ERTVBF, enhance relative total variation with BF model)^[40]、半稀疏平滑滤波器 (SSF, semi-sparsity smoothing filter)^[41]、多尺度全局感知网络 (MGPN, multi-scale global perception network)^[42]。为了比较的公平性, 将对比较算法的参数设置为相似且统一的平滑水平。本文实验运行的硬件平台为 Intel® Xeon® CPU E52630 v3 @2.40GHz 和 32 GB 内存的电脑。

3.1 参数设置

本文算法主要需要设置 3 个参数, 分别为平滑强度因子 λ 、平滑范围因子 σ 和迭代总次数 K 。

平滑程度因子 λ 控制数据保真项和正则化项之间的权衡以调节平滑强度。为了更好地进行比较, 其他参数固定为 $\sigma = 3, K = 6$ 。比较结果如图 2 所示, λ 越大, 平滑强度越高, 纹理去除的效果更明显, 但过大可能导致图像趋于过度平滑。根据经验, λ 在算法中的取值范围应为 $[0.001, 0.1]$, 能平衡平滑强度与细节保留。当 λ 取值越大时, 收敛越快, 但将牺牲平滑结果的质量; λ 值越小时, 收敛速度越慢, 但有助于更好的细节保留。因此, λ 的选择也影响收敛速度与平滑效果之间的权衡。



图 2 不同 λ 的平滑效果

平滑范围因子 σ 控制改进高斯滤波的窗口大小。在其他参数固定为 $\lambda = 0.007, K = 6$ 的情况下, 将 σ 分别设置为 2, 3, 4, 具体效果如图 3 所示。可知, σ 越大, 滤波器窗口越大, 滤波范围越大。此时, 更多纹理被去除, 但也会导致边缘模糊和小尺度结构丢失。较小的 σ 则与之相反, 能够使边缘更加清晰, 保留更多小尺度结构, 但同样也保留了更多纹理。 σ 在后续实验中基本固定, 取值在区间 $[2, 5]$ 内。其中, 较小的 σ 可能导致平滑效果较弱, 需要更多的迭代才能达到收敛状态。

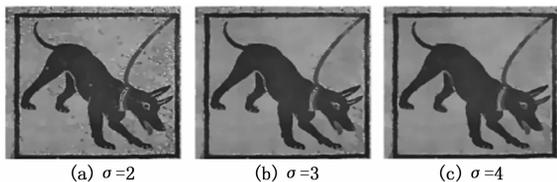


图 3 不同 σ 的平滑效果

迭代总次数 K 表示经过 K 次优化, 得到最终的平滑结果。保持其他两个重要参数 $\lambda = 0.01, \sigma = 4$ 不变, 比较不同迭代次数 K 下平滑结果的差异。图 4 展示了对应的视觉效果比较。图中可知, 在收敛之前, 随着 K 的增加, 平滑程度也随之提升; 在收敛之后, 额外的迭代次数几乎无法再提升平滑程度。根据经验, 当 K 达到某个值时, 目标函数趋于收敛, 足以获得高质量的平滑结果。在实验中, K 可设置在区间 $[3, 15]$ 内。 K 是控制算法收敛的关键参数。适当的迭代次数能够帮助算法更好地收敛, 而过多的迭代则可能浪费计算资源, 且在收敛之后再增加迭代次数几乎不再有助于改善结果。

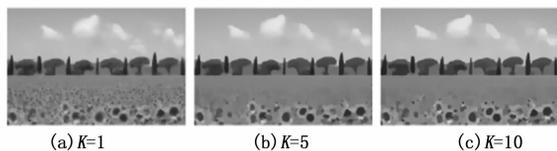


图 4 不同 K 的平滑效果

3.2 基线算法对比实验

为验证基于边窗的优化框架的优越性, 本文将其与相对全变分 (RTV) 和边窗滤波 (SWF) 这两种基线算法进行对比, 结果如图 5 所示。从图 5 中可以明显看出, SWF 能够较好地保留清晰边缘, 但其平滑效

果略显不足, 仍存在明显的纹理残留, 平坦度不足。RTV 能够较好地去除纹理并保留结构, 但纹理与边缘结构的区分度不足, 仍有孤立纹理残留。提出的基于边窗的共现变分在平滑区域内保持了足够的平坦度, 能够准确去除所有纹理, 并保持清晰的结构区域边缘, 从而实现了高质量的纹理平滑, 取得优秀的边缘与结构保持效果。

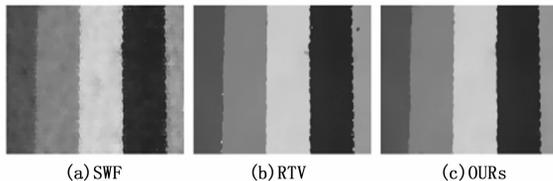


图 5 所提算法与基线算法的效果对比

3.3 定性分析

为进一步证明本文算法的有效性, 本小节通过主观实验对其进行定性评估, 将所提出的算法与上述 5 种先进的平滑算法进行比较。这些算法在经典图像上进行了测试, 包含非周期性纹理图像和周期性纹理图像, 比较结果如图 6~9 所示。

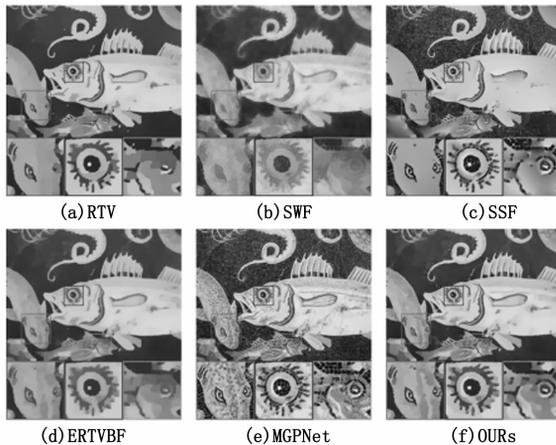


图 6 不同算法的平滑结果比较



图 7 不同算法的平滑结果比较

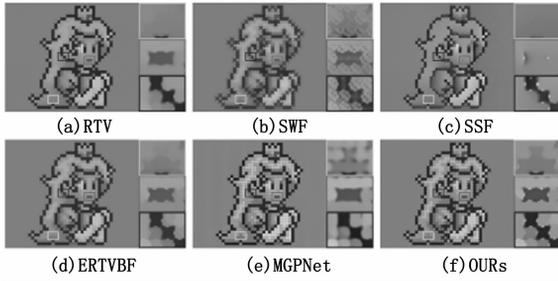


图 8 不同算法的平滑结果比较



图 9 不同算法的平滑结果比较

在非周期性纹理图像中,结合图 6 和图 7 (a)~(f) 的局部放大框可知,SWF 能够去除纹理,保留结构和边缘,但在纹理去除与边缘结构保留之间权衡不佳。RTV 能够较为准确地区分结构与纹理,实现有效平滑,但在该复杂纹理场景中仍然存在小尺度结构丢失的问题。SSF 具备初步的纹理与结构区分能力,但无法识别大范围的高对比度纹理,导致大量纹理被保留。ERTVBF 能够较好地去除纹理,保留较多的小尺度结构,然而边缘梯度损失较大,存在边缘模糊的问题。MGPNet 无法区分复杂纹理场景中的纹理与结构,在该类图像中几乎无法实现有效平滑。相比之下,所提出的算法能够有效平滑,同时保持清晰的边缘,并保留小尺度结构。此外,在对比的算法中,所提出的算法保留了最为完整的结构,在结构区域中的边缘损失强度最小,展示了卓越的纹理平滑效果。

在周期性纹理图像中,结合图 8 和图 9 (a)~(f) 的局部放大框可知,SWF 保边效果较好,但结构区域内边缘处易残留纹理。RTV 能够有效去除纹理,平滑程度高,极少残留纹理,但仍存在一定程度的边缘模糊,并且嘴巴之类的小尺度结构丢失或变形。SSF 对结构和纹理的区分能力不佳,残留许多孤立纹理,小尺度结构如嘴巴等被平滑去除。ERTVBF 能较好地保持结构,但边缘存在轻微模糊现象,并且小尺度结构仍保留不佳。MGPNet 能够较好地去除周期性纹理,但仍有纹理被误判为结构而得到保留,例如脸部与手部的孤立纹

理。所提出的算法在结构保留与纹理去除之间取得较好的权衡,无明显的孤立纹理残留,小尺度结构的形状保留得最为完整,并且边缘仍旧保持清晰。

综上所述,通过对周期性纹理图像与非周期性纹理图像的主观实验可以看出,在结构和纹理判别方面,本文算法表现最佳,能够准确分离复杂纹理场景中的结构与纹理,最大程度地保留小尺度结构。在边缘保持方面,本文算法保持了最为清晰的边缘,结构区域内的边缘强度损失最小,有助于结构的保留。此外,边缘处的纹理处理能力也较为优秀,保边的同时能够几乎去除纹理,边缘附近极少存在纹理残留。本文算法可以在不同类型的图像中取得高质量的平滑结果。

3.4 定量分析

在本节中,对所提出的算法进行了定量分析。本文采用峰值信噪比 (PSNR, peak signal-to-noise ratio)、结构相似度索引 (SSIM, structural similarity index)^[43]、梯度幅度相似性偏差 (GMSD, gradient magnitude similarity deviation)^[44] 和结构共生纹理 (SCOOT, structure co-occurrence texture)^[45] 感知指标这 4 个图像质量评估指标进行定量评估。其中,PSNR 通过均方误差定义,主要用于量化受有损压缩影响的图像和视频的重建质量,值越大表示处理图像与原始图像越接近,质量越高。SSIM 从亮度、对比度、结构三方面来衡量图像的失真程度及相似度,值越大表示结构相似度越高。GMSD 基于局部梯度幅值相似性来衡量局部图像质量,计算局部图像质量的标准差来衡量图像全局的质量。梯度幅值能反映结构信息,值越小表示图像相似度越高。SCOOT 可以获得人类感知,同时考虑块级别的空间结构和共生纹理统计,提供了一种综合考虑结构和纹理的统一评价。

基于上述 5 种对比算法与 4 种图像质量评估指标,进行了保边性能实验和合成纹理图像平滑实验,分别用于评价不同平滑方法的边缘保持能力和平滑质量。这两个实验基于不同的数据集进行,其中每种算法均采用固定的一组参数对数据集进行统一平滑,以保证对比的公平性。

1) 数据集:两个客观实验分别基于以下两个数据集所进行:RTV 发布的数据集和像素级非局部平滑 (PNLS, pixel-level non-local smoothing) 提出的南开平滑 (NKS, nankai smoothing) 数据集。每个数据集均包含 200 组图像。RTV 数据集由 RTV 提供,是图像平滑领域的经典数据集之一,广泛用于该领域的算法评估。该数据集通过提供复杂的纹理图像和相应的边缘图像,能够有效评估不同算法在纹理和边缘保留方面的能

力。其中, 每组图像都包含一张纹理图像和一张提供的边缘图像, 纹理图像包含各种复杂的纹理类型, 边缘图像则标注了纹理图像中的显著边缘信息。保边性能实验选择 RTV 数据集作为平滑对象, 可以有效测试不同算法在处理纹理和边缘信息时的表现, 特别是在多种纹理类型的挑战下。RTV 数据集的广泛应用和深厚背景使其成为图像平滑算法评估中的重要工具。NKS 数据集由 PNLs 提出, 包含人类、景观、动物等多种结构场景, 具有较高的分辨率, 适用于验证平滑算法在不同场景下的效果。其中, 每组图像都包含一张合成纹理图像和一张相应的真实图像, 合成纹理图像通过将复杂自然纹理与真实图像结合而生成, 真实图像本质上可理解为结构图像。合成纹理图像实验选择 NKS 数据集作为平滑对象, 主要用于测试多场景条件下的通用平滑质量, 尤其是在高分辨率图像下对不同结构场景的适应性。NKS 数据集的多样性和高分辨率特点使其成为理想的测试平台, 能够更全面地验证平滑算法的有效性与鲁棒性。

2) 保边性能实验: 在本实验中, 从 RTV 数据集中随机选择 20 组图像, 并采用上述算法进行平滑处理。平滑之后, 采用快速尺度自适应双边滤波 (FastSABF, fast scale adaptive bilateral filter) 中的边缘检测器从平滑图像中提取灰度边缘图像, 并通过双阈值二值化方法生成的二值边缘图像。采用 SSIM 与 GMSD 这两种评估指标用于评估 RTV 数据集所提供的边缘图像与获取的二值边缘图像之间的相似性。如表 1 所示, 粗体代表排名第一的方法, 下划线代表排名第二的方法。所提算法在 SSIM 和 GMSD 这两个指标中均取得了最优值, 验证了该算法具备最佳的边缘保持性能。

表 1 不同算法在保边性能实验中的评价指标对比

算法	SSIM \uparrow	GMSD \downarrow
RTV	0.987 16	0.001 254 1
SWF	0.992 51	<u>0.001 046 7</u>
SSF	0.980 36	0.001 453 8
ERTVBF	<u>0.994 43</u>	0.001 055 5
MGPNet	0.970 80	0.001 238 8
OURs	0.994 45	0.001 032 4

3) 合成纹理图像实验: 在本实验中, 从 NKS 数据集中随机选择 20 组图像, 并采用上述算法进行平滑处理。采用 PSNR 和 SCOOT 这两种评估指标用于评估算法的平滑质量。如表 2 所示, 粗体代表排名第一的方法, 下划线代表排名第二的方法。所提出的算法在 PSNR 和 SCOOT 这两种指标中均取得了次优值, 证明了该算法具备高质量的平滑性能, 并且鲁棒性较强, 展

现了在平滑质量和边缘结构保留之间的良好平衡, 具备较强的适应性和泛化能力。

表 2 不同算法在合成纹理图像实验中的评价指标对比

算法	PSNR \uparrow	SCOOT \uparrow
RTV	40.534 2	0.762 92
SWF	38.215 5	0.733 90
SSF	37.837 1	0.715 99
ERTVBF	38.799 1	0.755 26
MGPNet	40.180 0	0.796 01
OURs	<u>40.244 8</u>	<u>0.776 45</u>

综上所述, 通过保边性能实验和合成纹理图像实验, 以及相应的图像质量指标分析和对比, 可知本文所提出的算法在不同纹理场景下均能取得高质量的图像平滑结果, 并具备较强的鲁棒性。同时, 能够保持清晰的边缘, 从而提升结构相似性。

4 结束语

本文提出了一种基于边窗的共现变分保边图像平滑算法, 该算法能够有效平滑复杂纹理, 保持边缘清晰, 保留小尺度结构, 实现高质量的边缘与结构保持平滑。首先, 利用共现滤波的嵌入, 提出一种新颖的共现变分正则化项, 扩大结构区域与纹理区域之间的梯度差异, 以进一步扩大二者之间的权重差异。其次, 提出一种改进的边窗高斯滤波器, 结合方向一致性原理, 设计了新的边窗选择机制, 能够更为全面地选择目标像素所对应合适的边窗。最终, 首次将边窗高斯滤波与全局优化框架结合, 能够避免传统滤波窗口中心与处理像素对齐所导致的边缘模糊, 使得平滑模型在结构区域的边缘处表现出更强的导向性, 更倾向于抑制纹理。同时, 本文提出该优化框架的求解方法。此外, 在定性分析和定量分析中, 实验和结果均表明, 本文所提出的算法具备有效性、优越性与鲁棒性。未来的研究将着重于加速现有算法, 同时保持平滑效果的高质量。针对视频平滑处理领域, 未来工作将进一步探索如何将该方法应用于动态场景, 以适应视频中复杂的时间和空间变化。此外, 为提升算法的实用性和效率, 后续研究还将聚焦于增强算法的适应性, 以支持更多样化的纹理场景和动态内容的处理。

参考文献:

- [1] ZHANG W, ZHUANG P, SUN H H, et al. Underwater image enhancement via minimal color loss and locally adaptive contrast enhancement [J]. IEEE Transactions on Image Processing, 2022, 31: 3997–4010.
- [2] ZHU G, LV X, JIANG L, et al. Nonconvex regularization

- for convex image smoothing [J]. *Signal Processing*, 2023, 205: 108862.
- [3] KUMAWAT A, PANDA S. A robust edge detection algorithm based on feature-based image registration (FBIR) using improved canny with fuzzy logic (ICWFL) [J]. *Vis. Comput.*, 2022, 38 (11): 3681–3702.
- [4] 周巍巍, 高 银, 吴仪芳, 等. 局部高斯均差变分保边图像平滑算法 [J]. *电子测量与仪器学报*, 2024, 38 (4): 94–107.
- [5] TOMASI C, MANDUCHI R. Bilateral filtering for gray and color images [C] // *Sixth International Conference on Computer Vision (IEEE Cat. No. 98CH36271)*, 1998: 839–846.
- [6] KOPF J, COHEN M F, LISCHINSKI D, et al. Joint bilateral upsampling [J]. *ACM Trans. Graph.*, 2007, 26 (3): 96.
- [7] DURAND F, DORSEY J. Fast bilateral filtering for the display of high-dynamic-range images [J]. *ACM Trans. Graph.*, 2002, 21 (3): 257–266.
- [8] PORIKLI F. Constant time $O(1)$ bilateral filtering [C] // *2008 IEEE Conference on Computer Vision and Pattern Recognition*, Anchorage, AK, USA, 2008: 1–8.
- [9] YANG Q, TAN K H, AHUJA N. Real-time $O(1)$ bilateral filtering [C] // *2009 IEEE Conference on Computer Vision and Pattern Recognition*, Miami, FL, USA, 2009: 557–564.
- [10] HE K, SUN J, TANG X. Guided image filtering [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35 (6): 1397–1409.
- [11] LI Z, ZHENG J, ZHU Z, et al. Weighted guided image filtering [J]. *IEEE Transactions on Image Processing*, 2015, 24 (1): 120–129.
- [12] ZHANG Q, SHEN X, XU L, et al. Rolling guidance filter [C] // *Computer Vision-ECCV2014*. Cham: Springer International Publishing, 2014: 815–830.
- [13] HE L, XIE Y, XIE S, et al. Iterative self-guided image filtering [J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2024, 34 (8): 7537–7549.
- [14] PERONA P, MALIK J. Scale-space and edge detection using anisotropic diffusion [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1990, 12 (7): 629–639.
- [15] PARIS S, HASINOFF S W, KAUTZ J. Local Laplacian filters: edge-aware image processing with a Laplacian pyramid [J]. *ACM Trans. Graph.*, 2015, 34 (3): 81–91.
- [16] BAO L, SONG Y, YANG Q, et al. Tree filtering: Efficient structure-preserving smoothing with a minimum spanning tree [J]. *IEEE Transactions on Image Processing*, 2014, 23 (2): 555–569.
- [17] YIN H, GONG Y, QIU G. Side window filtering [C] // *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2019: 8750–8758.
- [18] YIN H, GONG Y, AND QIU G. Side window guided filtering [J]. *Signal Process.* 2019, 165: 315–330.
- [19] SHU L, DU H. Side window weighted median image filtering [C] // *Proceedings of the 2020 5th International Conference on Multimedia Systems and Signal Processing (ICMSSP '20)*. New York, NY, USA: Association for Computing Machinery, 2020: 26–30.
- [20] YUAN W, MENG C, BAI X. Weighted side-window based gradient guided image filtering [J]. *Pattern Recognition*, 2024, 146: 110006.
- [21] XU L, LU C, XU Y, et al. Image smoothing via l_0 gradient minimization [J]. *ACM Trans. Graph.*, 2011, 30 (6): 1–12.
- [22] BI S, HAN X, YU Y. An l_1 image transform for edge-preserving smoothing and scene level intrinsic decomposition [J]. *ACM Trans. Graph.*, 2015, 34 (4): 1–12.
- [23] FARBMAN Z, FATTAL R, LISCHINSKI D, et al. Edge-preserving decompositions for multi-scale tone and detail manipulation [J]. *ACM Trans. Graph.*, 2008, 27 (3): 1–10.
- [24] CAO W, WU S, LIU Z, et al. Scale-aware guided and structure-preserved texture filter [J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 1–5.
- [25] MA X, LI X, ZHOU Y, et al. Image smoothing based on global sparsity decomposition and a variable parameter [J]. *Comp. Visual Media*, 2021, 7: 483–497.
- [26] LIU W, ZHANG P, HUANG X, et al. Real-time image smoothing via iterative least squares [J]. *ACM Trans. Graph.*, 2020, 39 (3): 1–24.
- [27] XU L, YAN Q, XIA Y, et al. Structure extraction from texture via relative total variation [J]. *ACM Trans. Graph.*, 2012, 31 (6): 1–10.
- [28] CHO H, LEE H, KANG H, et al. Bilateral texture filtering [J]. *ACM Trans. Graph.*, 2014, 33 (4): 1–8.
- [29] SONG C, XIAO C, LI X, et al. Structure-preserving texture filtering for adaptive image smoothing [J]. *Journal of Visual Languages & Computing*, 2018, 45: 17–23.
- [30] HE L, XIE Y, XIE S, et al. Structure-preserving texture smoothing via scale-Aware bilateral total variation [J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2023, 33 (4): 1493–1506.
- [31] XU L, REN J S J, YAN Q, et al. Deep edge-aware filters [C] // *Proceedings of the 32nd International Conference on International Conference on Machine Learning (ICML'*

