

基于多尺度非线性扩散的泊松噪声移除算法研究

赵俊普¹ 张小波²

ZHAO Junpu ZHANG Xiaobo

摘要

针对医学、天文图像中泊松噪声污染的图像复原问题,传统去噪方法需手动设置参数,且去噪性能并不理想。而深度学习虽去噪性能好,但可解释性差。因此,结合传统非线性扩散去噪方法与深度学习技术的非线性反应扩散(trainable nonlinear reaction diffusion, TNRD)算法因其在去噪性能和可解释性上的优势而受到广泛关注。然而,由于泊松噪声与高斯噪声具有不同的统计特性,导致 TNRD 在进行泊松噪声去除时效果不佳,易引入伪影。为此,文章提出一种改进算法,先采用 Anscombe 变换将泊松噪声转为加性高斯噪声,再引入多尺度策略,用 TNRD 对不同分辨率含噪图像去噪并学习可训练权重,加权融合后经 Anscombe 精确无偏逆变换闭式近似转换得降噪图像。实验结果表明,该方法提升了去噪性能,并且减少了伪影,增强了模型对复杂噪声模式的适应性,相比一些先进的去噪方法实现了更优的性能。

关键词

泊松噪声; 图像去噪; Anscombe 变换; 多尺度非线性扩散

doi: 10.3969/j.issn.1672-9528.2025.04.005

0 引言

光子计数成像系统中的噪声通常服从泊松概率模型,而非高斯模型。传统去噪方法在处理泊松噪声时效果不佳。由于泊松噪声与光强存在紧密关联,极大增加了去噪过程的复杂度与挑战性^[1]。从数学角度分析,泊松噪声图像中各像素值被认为服从泊松分布^[2]。若 y_i 代表噪声像素, f_i 是待估计的无噪像素,则每一个像素 y_i 的离散泊松概率密度为:

$$p(y_i | f_i) = \frac{e^{-f_i} f_i^{y_i}}{y_i!} \quad (1)$$

泊松噪声具有与信号相关的特性,其噪声强度与信号强度成正比关系。比较常见的泊松噪声去除方法是采用方差稳定变换(variance stabilizing transformation, VST)。通过这种变换,可以将泊松噪声转化为近似高斯分布的形式,然后利用成熟的高斯去噪方法进行处理。Dabov 等人^[3]提出了用于图像去噪的块匹配与 3D 滤波(BM3D),在变换域中应用非局部自相似性(NSS)和增强的稀疏学习方案来提高模型在高斯噪声上去噪的性能。Azzari 等人^[4]提出了一种基于 BM3D 的迭代算法(iterative vst block matching-and-3D, I+VST+BM3D),对泊松噪声图像进行去噪,该算法逐步提

高了方差稳定化变换(VST)在高斯去噪滤波器中的有效性。Zhang 等人^[5]提出了一种方差稳定变换网络(VST-Net),该网络延续了传统方差稳定变换(VST)方法的优势,提高了泊松噪声的去噪效率。然而,方差稳定变换(VST)生成的近似图像在信噪比较低的情况下并不准确。尤其是在进行逆变换时,偏差较为明显,影响去噪效果的整体性能。相比之下,不依赖于方差稳定化的泊松噪声去除方法,如 Salmon 等人^[6]提出针对泊松噪声的非局部主成分分析法(non-local principal component analysis, NLPCA)和非局部稀疏主成分分析法(non-local sparse principal component analysis, NLSP-CA),该方法能够有效应对低峰值的泊松噪声去除问题,但在整体图像恢复方面表现欠佳,并且计算效率较低。Chen 等人^[7]提出的可训练非线性反应扩散(trainable nonlinear reaction diffusion, TNRD)模型,通过基于损失函数的方法从训练数据中学习包括滤波器和影响函数在内的所有参数,可以有效去除图像中的高斯噪声,然而,由于泊松噪声与高斯噪声具有不同的统计特性,导致在进行泊松噪声去除时,效果不好。为此, Feng 等人^[8]又将 TNRD 的反应项调整为符合泊松噪声的统计特性,并引入近端梯度下降法,提出可训练非线性扩散的快速准确泊松去噪模型(TRDPD),专门用于泊松噪声移除,但是该模型去噪后的图像仍存在伪影。

为克服 TNRD 模型在泊松噪声去噪中的不足,本文提出了一种结合 Anscombe 变换的多尺度去噪策略。该方法在保

1. 西安石油大学 陕西西安 710065

2. 咸阳师范学院 陕西咸阳 712000

[基金项目] 国家自然科学基金项目(61401383); 陕西省自然科学基金基础研究计划项目(2021JM-518)

留 TNRD 模型优势的基础上, 提升了泊松去噪性能。

1 泊松去噪网络结构模型

本文通过引入多尺度金字塔结构对 TNRD 模型进行改进。该方法首先对含有泊松噪声的输入图像进行 Anscombe 变换, 然后采用双三次插值算法构建一个多分辨率金字塔, 以实现图像在不同尺度层次上的分解。接下来, 利用 TNRD 模型对每个尺度层次的图像分别执行去噪处理。最后, 通过上采样与加权融合的方式整合来自不同尺度的去噪结果, 并采用 Anscombe 变换的精确无偏逆变换的闭式近似来恢复图像, 从而获得最终的输出图像。完整流程如图 1 所示。




图 1 多尺度非线性反应扩散流程图

1.1 Anscombe 变换

为消除信号依赖性并均衡图像中各点的噪声方差, 本文对含有泊松噪声的图像应用了方差稳定变换 (variance stabilizing transformation, VST)。通过这一变换, 原数据能够转换成具有已知恒定方差 (例如单位方差) 的高斯噪声分布。本文采用方差稳定变换中的 Anscombe 变换:

$$S(y) = 2\sqrt{y + \frac{3}{8}} \quad (2)$$

对泊松分布噪声图像进行处理, 记含噪图像为 y , 经 Anscombe 变换后得到 $S(y)$ 。此时, 图像中的噪声近似服从方差为 1 的高斯分布^[9]。在变换后的图像上, 通过 TNRD 进行去噪处理, 得到去噪后的图像记作 (y^*) 。接下来, 需要运用 Anscombe 逆变换, 将 y^* 恢复到原始统计特性, 从而得到估计的无噪声图像。对去噪后的图像直接应用。

Anscombe 逆变换会引入偏差, 而 Anscombe 渐近无偏逆变换可以减轻偏差, 但去噪精度会存在问题。为了解决这个问题, 本文使用精确无偏逆变换, 这种方法考虑到噪声的统计特性, 即使在低信号水平下也能准确估计感兴趣的信号^[10]。在实际应用中, 由于精确无偏逆需要对参数进行列表, 因此可以采用一种封闭形式近似^[11], 公式为:

$$f^{-1}(y^*) = \frac{1}{4}(y^*)^2 + \frac{1}{4}\sqrt{\frac{3}{2}}(y^*)^{-1} - \frac{11}{8}(y^*)^{-2} + \frac{5}{8}\sqrt{\frac{3}{2}}(y^*)^{-3} - \frac{1}{8} \quad (3)$$

这种封闭形式在保证去噪精度的同时降低了计算成本。

1.2 TNRD 模型

Chen 等人提出一种创新的图像恢复框架, 该框架通过模拟非线性反应扩散过程来实现含高斯噪声的图像去噪。TNRD 的显著特性在于其参数是依据损失函数, 从训练数据中学习获取。基于反应扩散模型的 TNRD 网络可视为一种特殊的卷积网络, 网络结构如图 2 所示, 其公式可表述为:

$$\frac{u_i - u_{i-1}}{\Delta t} = - \underbrace{\sum_{i=1}^{N_k} \mathbf{K}_i^T * \phi'_i(\mathbf{K}_i * u_{i-1})}_{\text{扩散项}} - \underbrace{\psi'(u_{i-1}, f)}_{\text{反应项}} \quad (4)$$

式中: $\mathbf{K}_i \in \mathbf{R}^{N \times N}$ 表示高度稀疏矩阵, 表示一组线性滤波器, 本文选取的滤波器大小为 5×5 ; N_k 表示滤波器的数量; $\mathbf{K}_i * u \leftrightarrow \mathbf{k}_i * u$ 表示滤波器核 $\mathbf{k}_i$ 与图像 u 进行二维卷积; ϕ'_i 表示影响函数; $\psi(u)$ 表示反应项函数, 反应项由数据项的梯度导出。当模型用于图像去噪时, 数据项设置为:

$$D'(u, f) = \frac{\lambda'}{2} \|Au - f\|_2^2 \quad (5)$$

由 $\psi(u) = \nabla_u D(u)$, 可以得到反应项函数 $\psi'(u) = \lambda' A^T (Au - f)$, A 是单位矩阵, λ' 控制了反应项对去噪过程的影响程度。得到用于图像去噪的扩散过程:

$$u_i = u_{i-1} - \left(\sum_{i=1}^{N_k} \mathbf{k}_i * \phi'_i(\mathbf{k}_i * u_{i-1}) + \lambda' (u_{i-1} - f_n) \right) \quad (6)$$

在监督的方式下, 需要训练一个代价函数来衡量扩散网络的输出和真实图像之间的差异。本文目标是训练具有 $T=10$ 阶段的扩散网络, 代价函数公式为:

$$L(\Theta_{1,2,\dots,T}) = \sum_{s=1}^S l(u_r^s, u_{\text{gt}}^s) \quad (7)$$

式中: u_r 是最后阶段 T 的输出。本文将均方损失函数作为代价函数, 定义为:

$$l(u_r^s, u_{\text{gt}}^s) = \frac{1}{2} \|u_r^s - u_{\text{gt}}^s\|_2^2 \quad (8)$$

因此, 整个训练过程被表述为以下优化问题:

$$\begin{cases} \min_{\Theta} L(\Theta) = \sum_{s=1}^S l(u_r^s, u_{\text{gt}}^s) = \sum_{s=1}^S \frac{1}{2} \|u_r^s - u_{\text{gt}}^s\|_2^2 \\ \text{s.t.} \begin{cases} u_0^s = f_0^s \\ u_i^s = u_{i-1}^s - \left(\sum_{i=1}^{N_k} \mathbf{k}_i * \phi'_i(\mathbf{k}_i * u_{i-1}^s) + \psi(u_{i-1}^s, f^s) \right) \\ i = 1, 2, \dots, T \end{cases} \end{cases} \quad (9)$$

式中: N_s 是训练的采样数; u_{gt}^s 和 f^s 分别是真实图像和噪声图像。影响函数通过标准径向基函数 (radial basis functions, RBFs) 来进行参数化表达, 即每个影响函数 ϕ 都可以被表示为一组标准的高斯径向基函数的加权线性组合, 本文选取了 89 个高斯径向基函数, 其参数化公式为:

$$\phi'_i(z) = \sum_{j=1}^M \omega'_{ij} \exp \left(-\frac{(z - \mu_j)^2}{2\gamma^2} \right) \quad (10)$$

式中: $\omega_{i,j} = (\omega_{i,1}, \omega_{i,2}, \dots, \omega_{i,M}) \in \mathbf{R}^M$ 表示权重; M 表示径向基函数

的个数。在训练该模型的过程中,采用等间距中心 μ_j 和统一尺度 γ 的高斯径向基函数,因此,权重 ω_{ij} 是加权系数。为了避免可能缩放的问题,定义线性滤波器 k_i 的参数化表达式为:

$$k_i' = \frac{\sum_r \omega_{i,r} b_r}{\|\omega_i'\|_2} \quad (11)$$

由离散余弦变换核 b_r 的加权线性组合定义,式中 k_i' 被归一化来消除所提出的扩散模型中出现的模糊性。




图2 可训练非线性反应扩散模型网络结构图

1.3 多尺度金字塔结构

在图像处理领域,多尺度分析策略已成为一种普遍应用于各类复杂图像处理问题的关键技术之一。其在目标检测、图像分类、图像分割和图像去噪^[12-15]等多个研究方向中,展现出卓越的灵活性和有效性。

在图像去噪领域,多尺度分析常以图像金字塔的形式呈现,该方法通过对输入图像进行向下采样操作,构建不同尺度的金字塔结构,从而有效处理图像中的噪声。下采样有效地对相邻像素值进行平均处理,导致噪声的不相关性减小。由于自然图像中相邻像素通常具有高度相关性,因此下采样对图像信息的破坏程度较小^[16]。在面对较大噪声时,各种去噪方法均存在各不相同的伪影,并且常常会保留一些低频噪声。处理低频噪声的一种自然思路是采用多尺度方法,即从粗到细的处理方式,在进行去噪之前对图像进行下采样相当于扩大了进行去噪的邻域大小,从而能够在更大的区域上抓取并去除低频噪声^[17]。

本文针对不同峰值的泊松噪声去噪效果开展实验研究,采用两种下采样与上采样融合的处理流程。在运用本文所提算法进行实验时,观察到对于所添加的6种峰值的泊松噪声,同一种下采

样与上采样融合流程在整体上去噪效果欠佳。鉴于不同峰值的泊松噪声具有显著差异,为实现精准去噪,特对上采样流程与下采样融合流程分别予以独立界定,进而构建更为精确有效的去噪策略。依据实验结果,对于本文添加的泊松噪声,根据实验情况将峰值为1、2、4的泊松噪声划分为较低峰值,将峰值为8、20、40的泊松噪声划分为较高峰值。

对于较低峰值的泊松噪声,如图3所示,下采样过程通过递归下采样来构建,以原始含噪图像作为第一层,后续每层图像通过对其前序层执行1/2降采样获得,按照尺寸从大到小,形成一至四层不同分辨率的图像金字塔结构。下采样融合过程定义为:首先,此过程起始于去噪后的图像金字塔最低分辨率的第四层,将第四层图像进行上采样,使其尺寸与第三层图像一致,随后乘以第三层自适应权重level3,将其融合至第三层图像中,进而形成新的第三层图像;以此类推,持续进行上采样与融合操作,直至获得融合后的第一层图像;最后,将原始的第一层去噪后图像乘以第一层自适应权重level1,同时将融合后的第一层图像乘以(1-level1),二者进行融合操作,从而得到针对低峰值泊松噪声优化后的最终图像。

对于较高峰值的泊松噪声,如图4所示,下采样过程同样以原始含噪图像作为第一层,然后其余各层均在第一层基础上,下采样分别为初始的1/2、1/4、1/8尺寸大小,按照尺寸从大到小,形成一至四层不同分辨率的图像金字塔结构。该过程与低峰值情况具有一定相似性,然而在融合操作上存在差异。融合过程在获得新的第二层图像时停止,然后上采样至第一层图像大小乘以level2,再乘以(1-level1),将第一层图像乘以第一层自适应权重level1,二者进行融合操作,以此得到针对高峰值泊松噪声图像的最终去噪图像。




图3 较低峰值的泊松噪声去噪过程




图4 较高峰值的泊松噪声去噪过程

2 实验结果与分析

2.1 实验环境与数据集

本文模型训练与测试基于 ubuntu18.04 系统，PyTorch 版本 1.8.1，Cuda 版本 11.1。本文使用 BSD400 数据集^[18] 中的 400 张分辨率为 180 px×180 px 的灰度图像作为训练

集，选取 BSD500 数据集^[19] 中除去 BSD400 和 BSD68^[20] 外的 32 张图像构建验证集，并采用 Set12、Kodak24^[21]、BSD68 数据集作为测试集。本文分别向训练数据集中添加了峰值为 1、2、4、8、20 和 40 的泊松噪声，以针对不同噪声强度分别进行训练。

2.2 实验结果

为了验证所提出的泊松去噪算法的性能，本文在多个测试数据集上与多种经典去噪算法进行了比较。表 1~3 以及图 5~7，分别展示了本文算法与 BM3D、I+VST+BM3D、NLPCA 和 TNRD 算法在客

观评价指标和视觉质量方面的对比结果。由于未获取到 TRDPD^[8] 的可训练代码，本文仅依据相关文献中的客观评价指标进行对比分析，而未进行直接的视觉效果对比，具体结果如表 4 所示。

表 1 不同算法在 Set12 测试集上的平均 PSNR 和 SSIM 结果

去噪算法	噪声水平					
	Peak=1	Peak=2	Peak=4	Peak=8	Peak=20	Peak=40
NLPCA	20.69/0.506	21.52/0.565	22.02/0.594	22.24/0.614	22.37/0.622	22.53/0.629
BM3D	20.12/0.555	21.51/0.600	22.40/0.635	25.33/0.709	27.38/0.770	28.20/0.744
TNRD	20.59/0.532	22.00/0.593	23.44/0.648	25.13/0.702	27.33/0.783	29.14/0.832
I+VST+BM3D	21.17/0.544	22.43/0.585	24.00/0.642	25.57/0.700	27.74/0.770	29.33/0.812
Proposed	21.25/0.565	22.64/0.625	24.10/0.679	25.71/0.735	27.82/0.803	29.45/0.844

表 2 不同算法在 Kodak24 测试集上的平均 PSNR 和 SSIM 结果


去噪算法	噪声水平					
	Peak=1	Peak=2	Peak=4	Peak=8	Peak=20	Peak=40
NLPCA	22.00/0.502	22.83/0.546	23.41/0.578	23.73/0.593	23.89/0.605	23.99/0.609
BM3D	21.29/0.541	22.68/0.577	23.50/0.604	25.66/0.664	27.30/0.720	28.50/0.745
TNRD	21.88/0.512	22.94/0.554	23.78/0.604	25.49/0.668	27.31/0.750	29.34/0.808
I+VST+BM3D	22.81/0.544	23.73/0.579	24.90/0.618	26.21/0.661	28.05/0.731	29.54/0.781
Proposed	22.65/ 0.547	23.71/ 0.592	24.88/ 0.640	26.25/0.698	28.13/0.770	29.64/0.820

表 3 不同算法在 BSD68 测试集上的平均 PSNR 和 SSIM 结果


去噪算法	噪声水平					
	Peak=1	Peak=2	Peak=4	Peak=8	Peak=20	Peak=40
NLPCA	21.26/0.466	21.99/0.506	22.49/0.534	22.72/0.547	22.91/0.554	22.99/0.558
BM3D	20.54/0.495	21.86/0.534	22.58/0.557	24.52/0.625	26.04/0.686	27.41/0.732
TNRD	20.99/0.477	22.12/0.525	22.93/0.581	24.56/0.649	26.34/0.742	28.36/0.806
I+VST+BM3D	21.65/0.487	22.56/0.524	23.68/0.569	24.92/0.624	26.73/0.703	28.25/0.762
Proposed	21.64/ 0.506	22.62/0.556	23.74/0.609	25.23/0.681	27.06/0.761	28.59/0.818

表 4 本文算法和 TRDPD 在 BSD68 测试集上的平均 PSNR 和 SSIM 结果


去噪算法	噪声水平					
	Peak=1	Peak=2	Peak=4	Peak=8	Peak=20	Peak=40
TRDPD	21.49/ 0.512	22.54/ 0.557	23.70/ 0.610	24.96/0.670	26.88/0.754	28.42/0.809
Proposed	21.64/0.506	22.62/0.556	23.74/0.609	25.23/0.681	27.06/0.761	28.59/0.818



(a) 含噪图 (b) 原图




(c) NLPCA (d) BM3D




(e) TNRD (f) I+VST+BM3D (g) Proposed

图 5 峰值为 1 的图像去噪效果图



(a) 含噪图 (b) 原图




(c) NLPCA (d) BM3D



(e) TNRD (f) I+VST+BM3D (g) Proposed

图 6 峰值为 8 的图像去噪效果图



(a) 含噪图 (b) 原图



(c) NLPCA (d) BM3D




图7 峰值为40的图像去噪效果图

在和 TNRD、TRDPD 对比时,均是使用卷积核大小为 5×5 时的去噪结果。为了更直观地比较去噪结果,本文分别从3个数据集里选取一张图像添加噪声,用不同算法去噪,并且对去噪图像的局部细节进行了放大对比,以更直观地展示不同算法在细节保留上的差异。

从图5(源自 Set12 数据集)可以看出,经 NLPCA 和 I+VST+BM3D 处理后图像呈现出整体模糊的视觉效果,严重影响了图像的清晰度和可辨识度。BM3D 和 TNRD 虽在一定程度上能够保持图像的整体结构,但在图像纹理部分却引入了伪影,并且存在不同程度的模糊现象,导致纹理细节难以准确分辨。相比之下,本算法去噪后的图像纹理清晰可辨,纹理细节得到了有效地保留和恢复,显著提升了图像的视觉质量。

对于图6(取自 Kodak24 数据集),NLPCA 处理后的图像很模糊,只能看见头盔大致轮廓。BM3D 处理后的图像,头盔边缘和头盔下边花纹都被平滑掉,而且引入很多伪影。I+VST+BM3D 和 TNRD 处理后的图像在头盔上的数字和头盔下的花纹上引入伪影,导致数字和花纹模糊不清,相较于本算法,其恢复的纹理清晰度和完整性明显不足。

对于图7(来自 BSD68 数据集),NLPCA 处理后的图像整体模糊不清,且出现大量条状伪影,严重干扰了图像的正常视觉感知。I+VST+BM3D 和 BM3D 在处理斑马头部时,对耳朵轮廓的恢复效果不佳,导致图像边缘模糊,大量细节信息丢失。TNRD 处理之后斑马面部的纹理仍有伪影,影响了图像的视觉质量。本文提出的算法处理之后图像边缘清晰,纹理信息完整,图像中噪声基本得到去除。

从表1~3数据可以看出,本文所提方法在 Set12 和 BSD68 数据集上的 PSNR 与 SSIM 指标取得了很好的结果。在 Kodak24 数据集的低峰值泊松噪声场景下,本文的算法虽

PSNR 略逊于 I+VST+BM3D,但 SSIM 指标相对较高。从视觉效果来看,本文的去噪效果和其他算法相比具有明显优势。总体来看,本文提出的算法去噪效果更好。

根据表4结果显示,相较于 TRDPD 算法,本文提出的算法在处理较低峰值泊松噪声图像时的结构相似度指标略显不足,但在峰值信噪比方面表现出一定的优势。在处理较高峰值泊松噪声图像时,本文算法在结构相似度和峰值信噪比两个指标上均取得了良好的效果。总的来说,两种方法,性能相当,各有优势。

3 总结

本文采用多尺度非线性反应扩散和 Anscombe 变换及其精确无偏逆变换的闭式近似来处理泊松噪声图像。该方法中,充分利用多尺度特征提取能力,从不同维度提取图像信息,并将图像浅层信息与深层信息相结合,助力网络学习图像信息,增强了去噪效果,提升了算法对图像细节的保留能力。具备上采样和下采样模块的多尺度融合架构在保留精细纹理与抑制伪影方面取得了很好的效果。

参考文献:

- [1] 张远鹏,陈鸿韬,王伟娜.基于非凸非光滑变分模型的灰度图像泊松噪声移除算法[J].浙江大学学报(理学版),2023,50(2):160-166.
- [2] 张芳.图像泊松去噪算法研究[D].杭州:杭州电子科技大学,2017.
- [3] DABOV K, FOI A, KATKOVNIK V, et al. Image denoising by sparse 3-D transform-domain collaborative filtering[J]. IEEE transactions on image processing, 2007, 16(8): 2080-2095.
- [4] AZZARI L, FOI A. Variance stabilization for noisy+estimate combination in iterative poisson denoising[J]. IEEE signal processing letters, 2016, 23(8): 1086-1090.
- [5] ZHANG M H, ZHANG F Q, LIU Q G, et al. VST-Net: variance-stabilizing transformation inspired network for poisson denoising[J]. Journal of visual communication and image representation, 2019, 62(7): 12-22.
- [6] SALMON J, HARMANY Z, DELEDALLE C A, et al. Poisson noise reduction with non-local PCA[J]. Journal of mathematical imaging and vision, 2014, 48: 279-294.
- [7] CHEN Y J, POCK T. Trainable nonlinear reaction diffusion: a flexible framework for fast and effective image restoration[J]. IEEE transactions on pattern analysis and machine intelligence, 2017, 39(6): 1256-1272.

- [8] FENG W S, QIAO P, CHEN Y J. Fast and accurate poisson denoising with trainable nonlinear diffusion[J]. IEEE transactions on cybernetics, 2018, 48(6): 1708-1719.
- [9] 许玉婷, 吴志芳, 王强, 等. 基于剪切波变换的辐射图像泊松噪声降噪技术研究 [J]. 原子能科学技术, 2022, 56(3): 577-584.
- [10] MAKITALO M, FOI A. Optimal inversion of the generalized anscombe transformation for poisson-gaussian noise[J]. IEEE transactions on image processing, 2013,22(1):91-103.
- [11] MAKITALO M, FOI A. A closed-form approximation of the exact unbiased inverse of the anscombe variance-stabilizing transformation[J]. IEEE transactions on image processing, 2011,20(9):2697-2698.
- [12] GOU Y B, HU P, LV J C, et al. Multi-scale adaptive network for single image denoising[C]//NIPS'22: Proceedings of the 36th International Conference on Neural Information Processing Systems. NewYork: ACM, 2022: 14099-14112.
- [13] 汤勇峰. 基于多尺度卷积神经网络的图像去噪方法研究 [J]. 无线互联科技, 2022, 19(24):154-156.
- [14] 许雪, 郭业才, 李晨. 基于卷积神经网络的多尺度特征融合去噪算法 [J]. 计算机与数字工程, 2023, 51(10): 2400 - 2404.
- [15] 李晨, 李雪婷, 李红旭, 等. 融合多尺度特征的遥感图像去噪方法 [J]. 电光与控制, 2024, 31(6): 74-80.
- [16] BURGER H C, HARMELING S. Improving denoising algorithms via a multi-scale meta-procedure[C]// DAGM'11: Proceedings of the 33rd international conference on Pattern recognition.NewYork:ACM,2011:206-215.
- [17] LEBRUN M, COLOM M, MOREL J M. Multiscale image blind denoising[J].IEEE transactions on image processing, 2015, 24(10): 3149-3161.
- [18] DONG W S, WANG P Y, YIN W T, et al. Denoising prior driven deep neural network for image restoration[J].IEEE transactions on pattern analysis and machine intelligence, 2019, 41(10): 2305-2318.
- [19] 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). Piscataway: IEEE, 2001, 2: 416.
- [20] REMEZ T, LITANY O, GIRYES R, et al. Class-aware fully convolutional gaussian and poisson denoising[J]. IEEE transactions on image processing, 2018, 27(11): 5707-5722.
- [21] ZHANG L, WU X L, LI X, et al. Color demosaicking by local directional interpolation and nonlocal adaptive thresholding[J]. Journal of electronicimaging, 2011, 20(2): 23016.

【作者简介】

赵俊普(1998—), 男, 河南驻马店人, 硕士研究生, 研究方向: 图像处理。

张小波(1979—), 男, 陕西咸阳人, 博士, 教授、硕士生导师, 研究方向: 图像处理和自然语言处理。

(收稿日期: 2024-11-20)

(上接第 23 页)

- [16] MA N N, ZHANG X Y, ZHENG H T, et al. ShuffleNetV2: practical guidelines for efficient CNN architecture design[DB/OL].(2018-07-30)[2024-05-19].https://doi.org/10.48550/arXiv.1807.11164.
- [17] HAN K, WANG Y H, TIAN Q, et al. GhostNet: more features from cheap operations[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2020:1580-1589.
- [18] TAN M X, PANG R M, LE Q V. EfficientDet: scalable and efficient object detection[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2020:10778-10787.
- [19] AZAD R, NIGGEMEIER L, HUTTEMANN M, et al. Beyond self-attention: deformable large kernel attention for medical image segmentation[C]//2024 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV). Piscataway: IEEE, 2024:1276-1286.

【作者简介】

彭和平(1966—), 男, 湖北武汉人, 博士, 教授, 研究方向: 公差设计基础理论与方法、精度控制技术与系统开发等。

高一峰(2001—), 男, 湖北荆州人, 硕士研究生, 研究方向: 深度学习。

(收稿日期: 2024-12-12)