

图像去噪算法综述

王潇漪^{1,2}, 仲彦军^{1,2}, 资政^{1,2}

(1. 新疆师范大学数学科学学院; 2. 新疆师范大学CAD&CG实验室, 新疆乌鲁木齐830000)

摘要: 图像去噪是数字图像处理的基础步骤, 对图像质量的提高和后续处理起着关键性的作用。受限于拍摄设备精度及传输环境中的干扰, 图像在成像过程中往往会产生多种混合噪声, 导致画面模糊、细节不清以及色彩失真。这些问题正日益影响人们的生活与工作。人们对获取更清晰和更准确的图像需求变得愈发强烈, 因此图像去噪显得尤为重要。根据去噪算法的类型, 将算法分为滤波法、低秩优化法、稀疏优化法以及深度学习等方法, 并从处理速度、抗噪能力和边缘保持等方面进行分析。此外, 利用PSNR等评价指标进行了对比分析, 评估了各种方法在不同图片上的去噪效果及其优缺点, 进一步探讨了各方法的适用场景和发展方向, 并对动态图像的实时去噪、参数自适应调整以及无需依赖大规模数据集的去噪方法进行了展望。

关键词: 图像去噪; 数字图像处理; 边缘保持; 深度学习; 实时去噪

DOI: 10.11907/rjtk.251288

扫描二维码阅读全文:



中图分类号: TP391

文献标识码: A

文章编号: 1672-7800(2026)007-0192-12

A Survey of Image Denoising Algorithms

WANG Xiaoyi^{1,2}, ZHONG Yanjun^{1,2}, ZI Zheng^{1,2}

(1. School of Mathematical Sciences, Xinjiang Normal University;

2. CAD&CG Laboratory, Xinjiang Normal University, Urumqi 830000, China)

Abstract: Image denoising is a fundamental step in digital image processing and plays a crucial role in improving image quality and enabling subsequent processing. Constrained by factors including the precision limitations of imaging devices and transmission environment interference, various mixed noise artifacts generated during the imaging process lead to image blurring, compromised detail resolution, and chromatic distortion. These degradations persistently affect both daily life and professional activities, while the growing demand for acquiring higher-precision and clearer images makes image denoising particularly crucial. Based on denoising algorithm typology, these methods are categorized into filtering-based approaches, low-rank optimization, sparse optimization, and deep learning-based frameworks. Their performance is systematically analyzed in terms of processing speed, noise suppression capability, and edge preservation characteristics, with comparative evaluations conducted through quantitative metrics such as PSNR. A comprehensive evaluation of denoising performance across methodologies is conducted for diverse image types, systematically benchmarking their strengths and limitations. The analysis further delineates applicable scenarios and development trajectories for each approach, with particular emphasis on emerging frontiers including real-time denoising for dynamic imagery, parameter self-adaptation mechanisms, and data-efficient paradigms that circumvent reliance on large-scale training datasets.

Key Words: image denoising; digital image processing; edge preservation; deep learning; real-time denoising

0 引言

图像在实际应用中可能会受到多种噪声的影响。这

些噪声来源于成像系统的光电转换噪声、传输信道中的带宽限制、存储介质的物理损伤以及环境中的电磁干扰等多重因素。噪声的存在不仅导致图像视觉保真度的多维度劣化, 包括边缘轮廓模糊化、高频细节衰减、色度信息失真

收稿日期: 2025-04-21

基金项目: 新疆维吾尔自治区创新环境(人才、基地)建设专项—自然科学基金计划基金项目(2021D01A125); 新疆维吾尔自治区高校科研计划基金项目(XJEDU2020Y027)

作者简介: 王潇漪(2000-), 女, CCF学生会会员, 新疆师范大学数学科学学院硕士研究生, 研究方向为数字图像处理、模式识别; 仲彦军(1981-), 男, 博士, 新疆师范大学数学科学学院副教授, 研究方向为计算机图形学、数据可视化; 资政(2001-), 男, 新疆师范大学数学科学学院硕士研究生, 研究方向为数字图像处理、计算机图形学。本文通讯作者: 仲彦军。

以及信噪比显著下降,更会直接影响后续计算机视觉任务的精度,例如导致图像分割的边界定位误差增大、目标检测的误报率上升,以及特征匹配的可靠性降低等。因此,对图像进行去噪是至关重要的。它不仅能提升图像的视觉质量,还能显著改善后续计算机视觉任务的精度和可靠性。

图像去噪作为数字图像处理的关键领域,其本质在于建立噪声分布与图像本征结构的解耦机制。通过数学建模与算法设计,实现噪声抑制与特征保真的双重优化目标。去噪算法的性能由噪声先验建模精度与特征重构能力的协同作用所决定,直接影响重建图像的峰值信噪比(PSNR)和结构相似性(SSIM)等客观指标。根据Liu等^[1]的研究综述,可以清晰地看到图像去噪方法的发展脉络。过去的传统图像去噪方法主要依赖于一些基于数学模型和信号处理的算法,例如小波变换、滤波器等。传统的去噪方法虽然在一定程度上能够去除图像中的噪声,但也有一定的局限性,比如对复杂噪声的处理不够完善,对真实图像的泛化能力较弱等。为了提高去噪模型对不同类型噪声和图像的去噪效果,深度学习应运而生。深度学习去噪方法能够根据神经网络自动提取和学习图像特征,并对不同噪声水平的噪声实现自适应去噪,从而达到将干净的图像从噪声图像中还原的目的。和传统去噪方法不同的是,基于深度学习的图像去噪方法具有更强的适应性和鲁棒性,能够更好地处理各种类型的噪声,同时,在保持图像边缘方面也表现出了显著的优势。

本文主要对从传统到深度学习的去噪方法进行梳理与总结,系统地对包括空间滤波、变换域方法、统计模型在内的传统技术,以及基于CNN、GAN、Transformer等主流深度学习模型的前沿方法进行了分类综述。从原理、性能及适用场景等维度,对各类方法进行了深入的对比与分析,并通过客观评价指标对其效果进行了量化评估,同时前瞻性地探讨了动态图像实时处理、模型自适应优化以及无需大规模标注数据的去噪方法等重要未来方向,以期后续研究提供有价值的参考。

1 噪声模型及面临的挑战

通常,图像去噪的建模过程如式(1)所示。

$$X = Y + N \quad (1)$$

其中, X 表示观测到的噪声图像; Y 表示未知的干净噪声图像; N 表示各种类型的噪声,主要包括高斯噪声、椒盐噪声和泊松噪声等。

随着人们对干净图像质量的需求越来越高,图像去噪技术也在不断更新。传统去噪方法已有较为成熟的应用,与此同时,基于神经网络结构和训练的深度学习方法也在迅速崛起。传统方法与深度学习方法的结合,使得图像去噪技术不断提升,日益完善。然而,在不断发展的进程中,

图像去噪仍面临着诸多亟待攻克挑战:

(1) 噪声类型复杂。图像噪声类型多样,且实际场景中多为类型与强度均未知的混合噪声,这增加了图像去噪的难度。

(2) 数据获取困难。深度学习需要大量高质量的训练数据,但获取和标注这些数据耗时且成本高。

(3) 模型泛化能力不足。大多数去噪模型在特定数据集上表现良好,但对未知噪声类型或新场景的适应性差。

(4) 去噪与细节平衡。在去除噪声的同时,需要尽可能保留图像的细节信息。

(5) 计算复杂度高。深度学习模型的训练和推理需要大量计算资源,难以在实时应用或资源受限的设备上高效运行。

2 传统去噪

2.1 空间滤波

传统图像去噪方法以空间域滤波为核心,通过邻域像素操作实现噪声抑制与细节恢复。Jain等^[2]和Sun等^[3]提出来的均值和中值滤波,通过邻域像素的平均值或中值替换当前像素值,可快速消除孤立噪声,但易导致边缘模糊。Kumar等^[4]和Piao等^[5]提出来的采用高斯核加权平均滤波,在降噪的同时,保留部分边缘信息,但高噪声场景下仍存在过度平滑问题。Tomasì等^[6]和Bhonsle等^[7]提出来的双边滤波,通过像素相似性保持边缘,但计算复杂度较高且对高频噪声敏感。

针对上述滤波方法的局限性,非局部均值(NLM)算法^[8]通过充分挖掘图像的自相似性,实现了更优的细节保持效果,如式(2)所示。

$$G(x) = \frac{1}{C(x)} \sum_{y \in \Omega} w(x, y) \cdot I(y) \quad (2)$$

其中, $G(x)$ 是滤波后的图像在位置 x 的像素值; Ω 是搜索窗口的大小; $w(x, y)$ 表示权重函数; $I(x)$ 是输入图像在位置 x 的像素值; $C(x)$ 表示归一化因子。

尽管NLM算法在去噪质量上有显著提升,但其全图相似性计算导致了较高的计算复杂度,同时也存在过度平滑的风险。为了减少去噪时间并提高计算效率,文献[9-17]提出通过快速搜索和旋转不变性设计等方法,降低时间复杂度;而文献[18-24]则通过引入自适应参数和块匹配优化等策略,进一步提升了细节保留能力。

2.2 变换域滤波

变换域滤波的核心思想是通过频域特征分离实现去噪。根据基函数的不同,主要方法可分为:①基于全局频谱分析,适合周期性噪声去除的傅里叶变换滤波^[25-26];②通过多尺度分解来保留局部特征,小波变换滤波能有效处理非平稳噪声^[27-28];③利用能量压缩特性,在分块处理

中平衡去噪与细节保留的离散余弦变换滤波。

由Dabov等^[29]提出来的BM3D是最经典的变换域滤波方法,其主要思想是:首先,通过块匹配进行分组,形成三维组合;其次,对其进行协同变换和滤波;最终,通过整合滤波结果得到降噪图像。

BM3D算法通过三维变换域收缩实现高效噪声分离,但对除高斯白噪声以外的其他噪声适应性有限。针对彩色图像特性,Dabov等^[30]在BM3D算法的基础上进一步提出CBM3D,将RGB转换为YUV空间。该方法通过亮度分量Y主导块匹配过程,并在色度通道UV上采用轻量化滤波,这虽然有助于保持色彩一致性,但也可能导致高饱和度区域的色度细节丢失。

为了进一步提高去噪效果,Maggioni等^[31]提出了块匹配和四维滤波的BM4D算法。该算法主要利用立方体的体素堆叠成组合,并进行四维变换。变换后的组合通过系数的收缩,可以有效地分离原始图像和噪声,进而达到去噪目的。BM4D算法广泛应用于三维图像去噪。

2.3 统计模型

基于统计模型的去噪方法,通过建立图像与噪声的联合概率分布,并运用统计推断理论实现噪声分离。其通用框架如式(3)所示。

$$\hat{x} = \arg \max_x P(x|y) = \arg \max_x \frac{P(y|x)P(x)}{P(y)} \quad (3)$$

其中, $P(y|x)$ 为噪声似然项; $P(x)$ 为图像先验项。

在基于统计模型的去噪方法中,最大后验概率模型(MAP)凭借其贝叶斯框架的理论优势取得显著去噪效果,但其性能受限于先验假设的合理性约束^[32]。马尔可夫随机场(MRF)通过空间相关性建模,在结构完整性恢复方面表现突出,但存在迭代收敛速度较慢的缺陷^[33]。相比之下,高斯混合模型(GMM)无需依赖外部数据就能完成去噪,但在处理复杂场景时易受模型复杂度制约^[34]。由Huang等^[35]提出的隐马尔可夫模型(HMM),虽然具备时序特征建模的独特优势,却面临训练过程收敛困难的技术挑战。

近年来,统计模型与深度学习的融合逐渐成为研究热点。深度学习在图像去噪中展现出强大的能力,但对训练数据依赖较大,且难以处理未见过的噪声类型。统计建模

方法则具有较强的理论基础和对噪声的适应性。将统计建模与深度学习相结合,通过构建合适的网络结构来学习统计理论,有助于更准确地捕捉图像的先验信息与噪声属性,从而提高去噪效果。

2.4 稀疏表示

稀疏表示方法旨在从含噪图像块中提取稀疏成分,并通过这些成分的线性组合实现降噪。现有的许多图像去噪技术都利用了自然图像的稀疏性知识。这种方法作为一种字典学习方法,可以从数据集中学习,或通过K奇异值分解(K-SVD)算法从图像本身进行学习。

K-SVD去噪算法是由Aharon等^[36]提出来的,其主要通过字典更新来实现去噪,即从有噪声的图像Y中学习字典D,如式(4)所示。

$$\min_{D, X} \|Y - DX\|_F^2 + \lambda \|x_i\|_1 \quad (4)$$

其中,Y表示观测到的图像矩阵;D表示字典矩阵;X表示稀疏编码矩阵; λ 是一个正则化参数; $\|x_i\|_1$ 是向量 x_i 的 L_1 范数。

尽管K-SVD算法的去噪效果较好,但其计算过程可能陷入局部最优解,从而导致学习到的字典无法达到全局最优。Dong等^[37]在2012年提出来的NCSR去噪模型结合了非局部自相似性(NSS)和稀疏表示,以此提高图像非局部区域之间的相关性,从而在去噪过程中找到全局最优解,如式(5)所示。

$$\alpha^* = \arg \min \|Y - D\alpha\|_F^2 + \lambda \|\alpha_i - \beta_i\|_1 \quad (5)$$

其中,Y表示观测到的图像矩阵;D是字典矩阵; α 表示系数矩阵; λ 是一个正则化参数,用于两项之间的权衡控制; $\|\alpha_i - \beta_i\|_1$ 表示向量 $\alpha_i - \beta_i$ 的 L_1 范数。

NCSR模型通过将非局部自相似性(Non-local self-similarity, NSS)自然地融入稀疏表示框架中,在恢复图像细节和纹理区域时非常有效。同时,该方法能够降低模型的复杂度,特别是在快速处理复杂图像时表现出其优势^[38-39]。图1是 $\sigma=25$ 时不同传统去噪方法在Set12数据集上的去噪对比情况。

由图1可知,WNNM算法对图像的去噪效果优于其他传统算法,其优越性不仅体现在峰值信噪比(PSNR)指标的提升上,更在于图像细节恢复与边缘保持方面的出色表




Fig. 1 Comparison of different deep learning denoising methods on the Set12 dataset when $\sigma=25$

图1 $\sigma=25$ 时不同传统去噪方法在 Set12 数据集上的去噪对比

现。与协同滤波算法(BM3D)相比, WNNM算法在降噪效果和边缘保护方面展现出巨大的潜力。

2.5 聚类低秩

图像通常具有低秩结构, 并通过低秩分解可以将噪声与图像信息分离, 从而实现去噪。低秩模型在图像去噪方面取得了良好的效果, 其核心在于通过低秩分解将图像中的噪声与有用信息进行有效分离, 从而达到去噪的目的。

基于低秩矩阵分解的方法在图像处理中的广泛应用, 其核心思想是将图像矩阵分解为一个低秩矩阵和一个噪声矩阵, 从而实现去噪。例如, Dong等^[40]提出了一种基于SVD的低秩方法, 该方法主要通过对奇异值迭代收缩来去除噪声, 但过度依赖奇异值的截断可能会影响去噪效果。为了减少对奇异值的依赖, Cao等^[41]在2015年提出了LRMF算法, 该算法的去噪过程可以表示为一个优化问题, 用核范数最小化来近似低秩函数, 将问题转化为一个凸优化问题, 如式(6)所示。

$$\min_{L, S} \|Y - L - S\|_F^2 + \lambda_1 \|L\|_* + \lambda_2 \|S\|_1 \quad (6)$$

其中, Y 表示观测到的矩阵; L 为低秩矩阵代表图像的主要成分; S 代表噪声; λ_1, λ_2 为正则化参数; $\|L\|_*$ 是矩阵 L 的核范数; $\|S\|_1$ 是矩阵 S 的 L_1 范数。

LRMF算法是一种经典的低秩去噪算法, 不仅在去噪效果方面具有显著优势, 并且在重建平滑和纹理区域方面表现优异。然而, 在实际应用中, 需要合理选择参数以平衡去噪效果与图像质量^[42-43]。为了进一步提升去噪效果, 核范数最小化(NNM)^[44]通过最小化噪声图像和原始图像之间的范数来实现去噪, 其目标函数如式(7)所示。

$$X_i = \arg \min_{X_i} \|Y_i - X_i\|_F^2 + \lambda \|X_i\|_* \quad (7)$$

其中, λ 是一个正数; Y_i 表示为噪声块矩; X_i 表示为降噪后的矩阵; $\|X_i\|_*$ 是矩阵 X_i 的核范数。

在NNM算法中, 对所有奇异值进行软阈值收缩, 可能使得图像信息过度集中于数值较大的部分, 从而削弱去噪效果并导致图像细节恢复不足。为了提高去噪效果, Gu等^[45]在NNM算法的基础上诞生了WNNM算法, 通过对不同的奇异值进行不同的软阈值收缩, 使得在去噪的基础上更好地完善图像边缘细节, 但其迭代所需的计算成本也较传统去噪方法有所增加。

3 深度学习去噪

传统的图像去噪算法在处理噪声时高速且有效, 但在复杂的噪声模式和图像细节方面仍然存在局限性。近年来, 基于深度学习的图像去噪方法在图像处理领域取得了显著进展。与传统去噪算法相比, 深度学习模型具有更强的灵活性与适应性, 能够有效应对多种复杂噪声类型及不同应用场景。基于深度学习的图像去噪方法主要包括: 基于卷积神经网络(CNN)、基于生成对抗网络(GAN)、基于图神经网络(GNN)、基于Transformer、基于扩散模型以及

基于BSN等。

3.1 基于卷积神经网络(CNN)

3.1.1 自监督学习

目前, 基于卷积神经网络(CNN)的图像去噪方法主要分为自监督学习和监督学习两大类。自监督学习N2N^[46]、N2V^[47]、N2S^[48]、S2S^[49]等是利用噪声图像自身进行训练, 不需要依赖成对的噪声图像和干净图像。N2V网络结构图, 如图2所示。




Fig. 2 The structure of N2V network

图2 N2V网络结构

(1)训练阶段。对于输入像素 i , 使用其感受野内的图像块作为输入, 通过参数 θ 来预测目标像素 $\hat{S}_i$ 的值, 如式(8)所示。

$$\hat{S}_i = f(x_{RF(i)}; \theta) \quad (8)$$

其中, f 表示CNN模型; $x_{RF(i)}$ 表示以像素 i 为中心的感受野内的图像块。

(2)测试阶段。主要通过调整参数 θ 来最小化所有像素预测值与实际值之间的损失, 如式(9)所示。

$$\theta^* = \arg \min_{\theta} \sum_i \sum_j L(f(x_{RF(i)}^j; \theta), S_i^j) \quad (9)$$

其中, θ^* 表示最优参数; L 表示损失函数, 用于衡量预测值 $f(x_{RF(i)}^j; \theta)$ 与真实值 S_i^j 之间的差异。

自监督学习对于不同类型的噪声和图像内容适应性有限, 且对于参数的调整缺乏灵活性, 通常需要更多的计算资源和训练时间来达到理想的去噪效果。

3.1.2 监督学习

监督学习的核心是通过大量的噪声图像和对应的干净图像对来训练一个模型, 使其能够从噪声图像中恢复出干净的图像。具体来说, 给定噪声图像 I_n 和对应干净图像 I_c , 监督学习的目标是学习一个函数 f , 如式(10)所示。

$$I_c = f(I_n) \quad (10)$$

由Vincent等^[50]提出的多层感知器MLP和Chen等^[51]提出的TNRD前馈深度网络是最基本的深度学习网络结构, 这类方法在训练数据充足时, 能够达到图像去噪的最优性能, 但仍需复杂的前期处理, 且难以适应不同水平的噪声。

为了避免对图像进行复杂的前期预处理, 将噪声直接

从噪声图像中分离出来,Zhang等^[52]在2017年提出去噪卷积神经网络DnCNN。该模型主要通过隐藏层中的操作,隐式地去除潜在的干净图像,其去噪模型如式(11)所示。

$$\hat{x} = F(y, M; \Theta_{\sigma}) \quad (11)$$

其中, $\hat{x}$ 表示模型输出结果; y 表示观测到的图像; M 表示噪声等级图;参数 Θ_{σ} 是固定的。

DnCNN模型的主要特点是引入了残差学习和批量归一化,两者有效地提升了训练速度和去噪性能,从而改善了去噪结果^[52]。但该方法灵活度有限,其学习模型只针对特定的噪声水平定制,训练后的模型 Θ_{σ} 很难直接应用于其他噪声水平图像。

为了适应多种噪声等级,Zhang等^[53]在2018年引入了快速灵活的去噪神经网络FFDNet。该网络结构和DnCNN一致,其主要特点在于引入了可调节噪声的水平图,其去噪模型如式(12)所示。

$$\hat{x} = F(y, M; \Theta_{\sigma}) \quad (12)$$

其中, $\hat{x}$ 表示模型输出结果; y 表示观测到的图像; M 是噪声等级图;参数 Θ_{σ} 固定。

DnCNN去噪算法等主要倾向于过度拟合高斯噪声,但对于复杂的真实噪声图像泛化能力较差。针对真实图像的去噪,Guo等^[54]在2019年提出了由噪声子网络和非盲去噪子网络两部分组成的卷积盲去噪网络CBDNet。该模型是FFDNet模型的升级版,主要利用五层全卷积神经网络来学习噪声强度参数 σ ,从而达到自适应噪声的目的。

与CNN去噪模型不同的是,CBDNet提出的是更接近真实的噪声生成模型,如式(13)所示。

$$\sigma^2(L) = L \cdot \sigma_s^2 + \sigma_c^2 \quad (13)$$

其中, L 为原始像素的辐照度图像; σ_s 是由稳态噪声组成的; σ_c 是由信赖噪声组成的,通常与图像的像素值有关。

CBDNet主要训练更接近真实的噪声模型,以此来提升模型泛化能力,从而可以更好地对真实场景进行降噪,但该模型不够高效灵活且计算成本较高。基于此,Anwar等^[55]在2019年相继提出了一种端到端的架构RIDNet,其用来学习噪声并在真实图像上进行去噪,不需要单独的子网络和人为干预。RIDNet模型是首个在去噪模型中加入特征注意的模型,即利用不同通道之间的依赖关系对不同通道的特征进行差异化处理,从而提升图像的泛化能力。同时,在RIDNet网络结构中加入了一个模块化网络,其主要目的是通过增加网络模块的数量来提高去噪性能。

与以前的CNN模型不同,RIDNet模型不仅通过引入新的恢复模块来学习特征以增强网络能力,还考虑了通道之间的依赖关系,并利用特征注意力机制来调整通道间的特征关系。

3.2 基于生成对抗网络(GAN)

为了解决CNN模型获取成对训练样本较难的问题,Chen等^[56]在2018年利用GAN模型对从真实噪声图像上提取的噪声进行建模。这主要是因为GAN模型具备卓越

的图像生成能力,可以逼真地模拟真实图像噪声,从而改善模型在真实噪声图像上的泛化能力。

生成对抗网络(GAN)的主要目标是通过生成器生成干净的无噪声的图像,而判别器则是通过真实的图像来提高生成器生成图像的质量^[57-58]。在图像去噪中,GAN可以用来学习噪声的分布,并生成与真实噪声相似的噪声数据。通过利用这些生成的噪声数据及其对应的干净图像进行训练,模型可以在带有噪声的图像中学习干净图像的表示。其目标函数如式(14)所示。

$$\min_D \max_G V(I, D) = E_{p_x}[\log_a I(X)] + E_{p_y}[\log_a (1 - I(D(Y)))] \quad (14)$$

其中, E 表示分布函数的期望值; E_{p_x} 表示训练样本的分布; E_{p_y} 表示噪声分布; $I(X)$ 表示判别器对真实数据 X 的输出; $I(D(Y))$ 表示判别器对生成数据 Y 的数据。

Alsaiani等^[59]在2019年利用所提出的GAN方法进行数据训练,通过对抗的方式提高生成器质量,从而提升去噪效率。然而,Lin等^[60]通过在生成器中引入视觉注意力计算,利用ADGAN方法准确定位噪声区域,并同时引入了金字塔注意力估计网络,以聚焦于需要处理的噪声区域。这不仅提高了网络在去噪过程中的特征提取能力,还能够避免图像过度平滑的现象,从而实现更有效的去噪效果。

通过使用生成器和判别器之间的对抗学习策略,不仅保持了图像的结构信息,还能够有效地避免过度平滑和细节丢失的问题,使得去噪后的图像更加真实和清晰。但该算法仍有局限性,Gong等^[61]和Dey等^[62]提出的生成器和判别器很难做到同步更新数据,即会导致网络训练过程不稳定,且容易在训练中出现过度拟合,造成图像细节模糊、边缘保持能力下降,从而可能影响最终的去噪效果。

本文选取Kodak24数据集进行实验,将不同深度学习的去噪算法进行对比,如图3所示。从对比图中看起来,无论是在图像去噪程度还是细节恢复方面,FDnCNN算法的表现明显优于DnCNN算法。其中,FDnCNN算法的PSNR值比DnCNN算法高出约0.3 dB。

3.3 基于图神经网络(GNN)

图神经网络是一类能够从图结构数据中学习的神经网络,尤其适用于结构较为复杂的图。Valsesia等^[63]基于此提出GCDN去噪神经网络,该网络通过图卷积计算特征相似度来学习自相似模式,并引入边缘条件卷积,以解决梯度消失和过度参数化的问题。

在图卷积层中,图是通过构建特征空间中的K近邻图来实现的。这需要计算每个像素的特征向量与其搜索窗口内所有像素的特征向量之间的欧氏距离,并在该像素与距离最小的K个像素之间建立一条连接边。经典的局部卷积在处理局部邻域以提供其对当前像素的输出时,主要通过图连接非局部像素的特征向量并进行聚合。其中,非局部聚合计算如式(15)所示。



图 3 Comparison of different deep learning denoising methods on the Kodak24 dataset when $\sigma=45$

图 3 $\sigma=45$ 时不同深度学习去噪方法在 Kodak24 数据集上的去噪对比

$$\begin{aligned}
 H_i^{l+1, NL} &= \sum_{j \in S_i^l} \gamma^{l,j \rightarrow i} \frac{F_w^l(d^{l,j \rightarrow i}) H_j^l}{|S_i^l|} \\
 &= \sum_{j \in S_i^l} \gamma^{l,j \rightarrow i} \frac{\Theta^{l,j \rightarrow i} H_j^l}{|S_i^l|}
 \end{aligned} \quad (15)$$

其中, F_w^l 表示全连接网络; w^l 表示 F^l 的权重参数; $d^{l,j \rightarrow i}$ 表示两个特征向量之间的差; S_i^l 是节点 i 的邻域集; $H_i^{l+1, NL}$ 表示为卷积的输出层。

图卷积神经网络(GNN)能有效地利用非局部的信息进行去噪,但在高噪声水平中构建干净图像有一定的困难^[64-65]。同时,相比传统的卷积神经网络,GNN模型具有更高的计算复杂度,容易出现过拟合现象^[66]。基于此,Zeng等^[67]从卷积神经网络的输出中构建稀疏邻域图,然后利用相应的图拉普拉斯正则化作为先验项,通过求解无约束二次规划问题对图像进行恢复。Yu等^[68]和Zhou等^[69]提出了一种在实验数据较少的情况下,能有效减少过度拟合的风险,同时具有强大的跨域泛化能力,去噪效果优于其他深度学习的算法。上述方法在一定程度上缓解了过度拟合的问题,但计算复杂度仍然较高。在此基础上,诞生了一种名为DenseGNN的新型图神经网络模型^[70]。该模型通过采用密集连接策略,实现了图中每一层对所有前向层特征的直接访问,从而有效减少了信息丢失,并显著提升了网络性能。此外,模型通过更新边、节点和图级别的特征,并引入残差连接策略,实现了更加直接和密集的信息传播。为了减少边的连接数量,Zeng等^[71]提出DeepGLR深度网络结构,将图拉普拉斯正则化集成到深度学习框架中。尽管其优化策略减少了边连接数量,但在训练过程中反向传播的计算成本仍然较高,特别是在处理大规模图数据时。

3.4 基于Transformer

相较于传统的图像去噪方法,深度学习去噪方法能够很好地学习和利用图像中的复杂结构和模式。Transformer作为一种新兴的深度学习结构,在图像去噪方面表现出强大的潜力。其将图像视为一系列像素的序列,并利用自注意力机制对像素间的依赖关系进行建模。为了更好地提取图像特征和重建细节,Yao等^[72]提出一种基于Transformer的密集残差跳过连接网络DenSformer,该网络在

Sformer组之间采用密集残差跳过连接来提取深层特征,并桥接不同层之间的信息。Gao等^[73]在此基础上提出多尺度双分支Transformer的图像去噪,有效融合浅层和深层特征的多尺度信息,在恢复图像细节时保留整体特征。但与双重CNN去噪网络DudeNet需要长距离依赖全局上下文的信息来增加其性能不同的是,多尺度双分支Transformer主要通过其独特的自注意力机制和多尺度特征提取能力来捕捉全局细节特征^[74]。

然而,DenSformer等模型均是对全局进行处理,无法捕捉到图像的局部特征。Zhang等^[75]在空间维度和通道维度上融合了Transformer块,提出了Xformer结构。该结构能够增强不同范围的全局和局部表示能力,从而通过双向连接单元(BCU)实现不同特征的有效融合,在多个测试集上表现出良好的去噪效果。但该模型在训练过程中过度拟合数据,在含真实噪声数据集上表现不理想。为了在复杂场景下获得清晰图像,Tian等^[76]提出交叉Transformer去噪卷积神经网络CTNet,CTNet模型以深度和广度的搜索方式增强像素特征之间关系,从而提高图像去噪效果。目前常用的Transformer都使用了层归一化模块,但层归一化模块可能导致顶层梯度消失,如何解决梯度消失是未来值得探索的方向。

3.5 基于扩散模型

基于扩散模型的图像去噪是一种利用扩散模型去除图像噪声,并恢复原始图像内容的方法。扩散模型是一种生成模型,通过模拟扩散过程来生成数据。Jonathan等^[77]在2020年首次提出扩散模型DDPMs用于图像去噪,其通过模拟噪声扩散过程,学习从噪声数据中逆扩散恢复出干净的图像。该方法运用概率模型与深度学习技术,在变分自编码器(VAE)和生成对抗网络(GAN)之外提供了一种新的生成模型框架。然而,DDPMs模型对超参数的选择非常敏感,通常需要经过更精细的调优过程才能实现最佳性能。为了强化扩散模型对真实噪声的泛化能力,Yang等^[78]将去噪扩散模型用于真实世界的图像去噪,通过线性插值来控制添加噪声的量,使得扩散过程中添加的噪声更接近真实世界的噪声,从而实现更有效的去噪。但由于扩散过程本身存在的不精确性,所生成样本的质量往往低于直接采样得到的结果。因此,解决扩散过程中的不精确性

并优化采样算法,是未来扩散模型工作的重点方向。现有的扩散去噪模型依赖于大规模数据集进行训练,Kulikov等^[79]为了解决这个问题,提出了一个在单张图像上训练的扩散模型 SinDDM。SinDDM 通过多尺度扩散过程学习训练图像内部的信息,并使用轻量级全卷积去噪器驱动逆扩散过程。该模型能够生成任意尺寸的样本,并采用由粗到细的方式进行生成。SinDDM 结构图如图 4 所示。由图可知,基于时间步长(t)和尺度(s)的条件,将其整合到 4 个总感受野为 35×35 的完全卷积块模型中。这一设计使得模型能够在不同时间步骤中更灵活地处理图像数据。




Fig. 4 The structure diagram of SinDDM network

图 4 SinDDM 结构图

Xie 等^[80]讨论了对 3 种噪声模型(高斯、伽马和泊松噪声)的去噪,将去噪任务视为在给定噪声图像条件下,估计其对应干净图像的后验分布问题,并应用扩散模型的思想来实现生成式图像去噪。根据去噪任务的不同,重新定义扩散过程,进而减少生成图像中的失真现象。为了提高去噪效率,Zhang 等^[81]在 2024 年提出 DDDM 模型,其通过少步骤采样生成逼真的图像,同时,保留多步骤采样以获得更好的性能。DDDM 模型通过以自身迭代生成的目标作为条件进行训练,无需依赖精心设计的采样器。

扩散模型在生成高质量图像方面表现出色,但在扩散过程中涉及多个时间步骤,导致计算成本高昂,特别是在处理高分辨率图像时。此外,扩散模型采样过程相对缓慢,如何提高采样效率和降低计算资源消耗是未来去噪扩散模型研究的重要方向。

3.6 基于 BSN

自监督图像去噪 N2V、N2S 等,主要通过遮蔽输入图像的像素来引入自监督信号,但这些方法依赖于噪声是逐像素独立的假设,在处理含真实噪声时存在局限。为了克服上述局限,BSN 被开创性地引入了自监督学习框架,通过在感受野中心遮蔽像素,并利用周围的像素信息来重建中心像素。

现有的 BSN 算法在处理大规模空间相关噪声时,效率较低。为了提高去噪效率,Lee 等^[82]提出了一种非对称像素分解和 BSN 相结合的方法 AP-BSN。通过非对称分解打破噪声的空间相关性,同时,避免对图像细节的过度损害,但该模型在真实图像数据集上表现较差。为了提升 BSN 模型对真实噪声的泛化能力,Zhang 等^[83]在 2023 年提出了多掩模模型 MM-BSN,通过多个卷积掩模核进一步破坏噪

声的空间相关性,并有效融合多掩模层提取的特征。Li 等^[84]通过分析设计通道和空间注意力以满足盲点要求,构建一个基于 Transformer 的盲点网络 TBSN。该算法具有较强的局部拟合能力与全局视角能力,并引入了知识蒸馏策略,将 TBSN 蒸馏成较小的去噪器。MM-BSN 和 TBSN 在保持性能的同时,提高了去噪效率,极大地扩展了感受野,在真实图像数据集上表现出良好的去噪效果。

但 MM-BSN 等算法在处理高噪声水平时,容易丢失高频细节。为了克服这些局限,Xia 等^[85]提出一种动态自适应盲点网络 DA-BSN。DA-BSN 结合了 Transformer 和 CNN 提取全局和局部的图像细节,同时也能够根据不同的空间噪声特性动态调整去噪策略。DA-BSN 通过动态自适应机制和多尺度特征提取,在去除高噪声水平的同时,更好地保留了图像边缘和细节。

早期的自监督去噪方法,从 N2V、N2S 到现在的 BSN 及其改进方法,都取得了极大的进步。尽管现有的去噪方法在面临含有真实噪声的图像时仍面临挑战,但 DA-BSN 等方法通过结合 Transformer 和 CNN 的优势,显著提升了去噪性能。未来对自监督图像去噪的研究可以从优化网络结构、提高去噪效率以及探索更多自监督信号引入方式等方面展开。

4 对比实验

4.1 评价指标

对图像去噪效果的分析,主要通过主观视觉评估和客观评价指标两方面进行。其中,视觉分析主要从以下几个方面展开:①去噪后的图像是否还有孤立点;②去噪后的图像边缘是否遭到破坏;③去噪后的图像细节是否有所保留。

然而,通过视觉分析图像的去噪效果具有一定的局限性,因此,通常需要采用标准的客观评价指标来对去噪后的图像进行评估分析。主要包括:峰值信噪比(PSNR)和结构相似比(SSIM)。其中,峰值信噪比(PSNR)给定一个大小为 $m \times n$ 的干净图像 I 和噪声图像 K ,其 PSNR 定义如式(16)所示。

$$PSNR = 10 \cdot \log_{10} \left(\frac{255^2}{MSE} \right) \quad (16)$$

其中, MSE 的计算公式如式(17)所示。

$$MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [I(i,j) - K(i,j)]^2 \quad (17)$$

PSNR 的值越大表示去噪后的图像与干净图像越接近,即去噪效果更好。

结构相似比(SSIM)给定一个干净图像 x ,其去噪图像的结构相似比 SSIM 定义如式(18)所示。

$$SSIM = \frac{(2\mu_x \mu_{\hat{x}} + C_1)(2\sigma_{x\hat{x}} + C_2)}{(\mu_x^2 + \mu_{\hat{x}}^2 + C_1)(\sigma_x^2 + \sigma_{\hat{x}}^2 + C_2)} \quad (18)$$

其中, μ_x 、 $\mu_{\hat{x}}$ 分别是干净图像 x 和噪声图像 $\hat{x}$ 的均值;

σ_x 、 σ_k 分别是干净图像和噪声图像的方差; σ_{xk} 是协方差; C_1 、 C_2 表示用来稳定常数值。

SSIM 值介于 0 到 1 之间, 越接近 1, 表示降噪后的图像质量越接近原始清晰图像, 即降噪效果越好。

4.2 测试数据集

在图像去噪研究中, 常用的测试数据集主要分为三类: 灰度图像数据集、彩色图像数据集以及真实图像数据集。其中, 灰度图像数据集主要有 Set12 和 BSD68; 彩色图像数据集主要有 CBSD68、Kodak24、McMaster 和 CSet12; 常用的真实图像数据集主要有 DND^[86]、SIDD^[87]、PolyU^[88]和

RENOIR^[89]。DND 数据集涵盖了 50 个场景, 这些场景均由 4 种不同类型的相机拍摄而成, 每个场景都包含真实的噪声图像和对应无噪声图像。SIDD 数据集由 5 款具有代表性的智能手机拍摄了 10 个不同场景, 每个场景均提供噪声图像及其对应的 Ground Truth 图像。PolyU 数据集包含了 5 种常规以及对应的弱光环境场景。RENOIR 数据集由 3 种不同传感器尺寸的相机拍摄了 120 个低场景, 每个场景均提供噪声图像和 GroundTruth。不同图像去噪方法的对比总结, 如表 1 所示。每类方法里面越靠后的方法去噪效果越好。

Table 1 Comparison and summary of different image denoising methods
表 1 不同图像去噪方法的对比总结

基础网络	方法	适用噪声	优点	缺点
空间滤波	MF ^[2-3]	合成噪声	(1)平衡去噪与细节保留,避免过度平滑导致的边缘模糊或纹理丢失 (2)基于图像局部或全局特性自适应调整过滤强度 (3)参数量少,内存占用少	(1)边缘保持效果差,高频细节损失 (2)参数敏感,实时性差 (3)特征表达能力不足,难以去除密集的噪声
	GF ^[4-5]			
	BF ^[6-7]			
	PID ^[77]			
	NLM ^[8]			
变换域滤波	AWT ^[78]	合成噪声	(1)提供多尺度分析能力,能够同时捕捉信号的全局和局部特征 (2)具有高效的算法,能够在较短时间内完成复杂的计算 (3)FT 和 BM3D 等通过变换域来分离噪声和信号	(1)边界处可能出现明显的伪影,伪影可能影响图像的整体质量 (2)对于非线性噪声,变换域滤波的效果可能不佳
	FT ^[25-26]			
	WT ^[27-28]			
	BM3D ^[29]			
统计模型	CBM3D ^[30]	合成噪声	(1)MAP 等统计模型对图像的噪声和信号进行建模,能更好地处理图像中的噪声分布 (2)GMM 和 HMM 通过调整先验分布或模型参数以适应不同类型的参数 (3)对多种噪声类型均表现出良好的鲁棒性	(1)在处理大规模图像时,去噪速度慢 (2)可能导致图像丢失部分细节 (3)对模型假设敏感
	MAP ^[32]			
	MRP ^[33]			
	GMM ^[34]			
	HMM ^[35]			
稀疏表示	K-SVD ^[36]	合成噪声 真实噪声	(1)具有良好的泛化能力和对数据变化的适应性 (2)NCSR 等通过稀疏表示来提取关键特征和降低数据维度 (3)在处理高噪声水平时,能较好保留图像细节	(1)计算成本显著增加 (2)存在陷入局部最优解的问题 (3)参数选择不当可能导致去噪效果不佳
	NCSR ^[37-38]			
	GSR ^[79]			
	TWSC ^[80]			
	LSCC ^[81]			
聚类低秩	LRMF ^[42]	合成噪声	(1)在处理不同噪声水平的图像时,能表现出较好的鲁棒性 (2)利用图像之间的自相似性,可以更好地保留图像的纹理和细节 (3)WNNM 等通过调整参数处理不同噪声水平	(1)高度依赖参数的选择 (2)过度拟合训练数据,导致图像泛化能力下降 (3)在图像边缘或细节区域容易出现伪影
	LLRT ^[83]			
	WNNM ^[40]			
	WCNNM ^[82]			
	DnCNN ^[48]			
卷积神经 (CNN)	FFDNet ^[49]	合成噪声	(1)端到端优化便捷,多层次特征提取 (2)处理效率高,轻量可拓展 (3)残差学习优化效果好,有效解决梯度爆炸 (4)能够处理不同噪声水平的噪声,还能扩展到盲噪声	(1)泛化性受限,真实噪声效果差 (2)训练稳定性差,需大量训练数据 (3)对于复杂的数据,特征提取能力有限
	FOCNet ^[84]			
	RIDNet ^[50]			
	CBDDNet ^[51]			
生成对抗 (GAN)	GAN ^[52]	真实噪声	(1)可以生成真实的噪声图像,样本泛化能力强,数据匹配性好	(1)训练难度大,容易过拟合 (2)结果不可控
	ADGAN ^[56]			
	GCBD ^[57]			
图神经 (GNN)	GCDN ^[59]	真实噪声	(1)通过拓扑结构可以很好地拟合复杂噪声分布 (2)对噪声空间变化的适应性较好,适合高分辨率图像去噪 (3)密集连接结构促进特征复用,提升去噪效果	(1)图的大小不可控,拓扑结构复杂 (2)不稳定的动态拓扑结构会降低特征的表达能力 (3)需要大量计算资源 (1)对输入数据的细微变化较为敏感,导致对不同数据集的泛化能力有限 (2)Transformer 主要关注全局信息,局部信息提取不如 CNN (3)训练成本高,需要大量的训练数据和计算资源才能达到最佳
	DeepGLR ^[85]			
	OverNet ^[86]			
	DenseGNN ^[66]			
	DenSformer ^[93]			
Transformer	双Trans ^[94]	真实噪声	(1)利用Transformer的自注意力机制,捕捉图像的全局信息,从而更好地处理复杂的图像结构 (2)Transformer的多头注意力机制能够从多个子空间提取特征,增强模型的表达能力	
	Xformer ^[96]			
	CTNet ^[97]		(3)相比CNN,Transformer架构支持并行计算,更高效处理大规模图像数据,显著加快训练速度	

续表				
基础网络	方法	适用噪声	优点	缺点
扩散模型	DDPMs ^[98]	真实噪声	(1)在去噪过程中生成高质量的图像样本,能够有效捕捉数据分布 (2)DDPMs 能适应不同的去噪任务和数据集	(1)采样效率低,需迭代多次,才能生成高质量样本 (2)可能引入伪影
	DDDM ^[102]			
	SinDDM ^[100]			
BSN	AP-BSN ^[103]	真实噪声	(1)减少了对大规模数据的依赖,能在没有干净图像的情况下直接对单张噪声图像进行训练	(1)由于自监督学习的复杂性,训练时间较长
	MM-BSN ^[104]			
	DA-BSN ^[106]			

图 5 展示了不同去噪方法在 BSD68 数据集上的效果对比,将基于深度学习的去噪算法与突出的传统算法 BM3D 和 WNNM 进行了比较。从对比图中可以

看出来,无论在图像去噪还是细节恢复方面,FFDNet 等算法相比 WNNM、BM3D 等传统方法均表现更优^[90]。



Fig. 5 Comparison of different denoising methods on the BSD68 dataset when $\sigma=50$

图 5 $\sigma=50$ 时不同去噪方法在 BSD68 数据集上的去噪对比

4.3 实验结果分析

DnCNN、FDnCNN、FFDNet 和 IRCNN 在 Kodak24 数据集上不同噪声水平下的平均 PSNR 和 SSIM 结果,如表 2 所示。从两种评价指标中可以发现,FFDNet 算法在低噪声水平 ($\sigma \leq 25$) 时,其表现效果优于 DnCNN、FDnCNN 和 IRCNN。在高噪声水平 ($\sigma \geq 25$) 时,FFDNet 算法的去噪效果相比其他三种算法同样表现显著,尤其在噪声水平为 50 时,其 PSNR 和 SSIM 值分别高于 DnCNN 约 1.6 dB 和 0.0569。

Table 2 Denoising results of different methods on the Kodak24 dataset at various noise levels

表 2 Kodak24 数据集上不同噪声水平下各方法去噪结果

噪声水平	DnCNN		FDnCNN		FFDNet		IRCNN	
	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM
25	30.36	0.832 5	32.11	0.878 8	32.12	0.877 8	32.01	0.876 4
35	28.68	0.779 2	30.53	0.842 1	30.54	0.840 4	32.39	0.838 1
45	27.62	0.741 3	29.42	0.810 6	29.43	0.808 4	29.30	0.806 1
50	27.36	0.737 2	28.95	0.796 5	28.96	0.794 1	28.80	0.792 8

为了进一步观察不同方法在不同噪声程度下的去噪效果,本文在 CBSD68、Kodak24 和 McMaster 数据集上进行了不同噪声水平下的不同去噪方法的结果分析,如表 3 所示。表格中的黑色下划线“—”标记了同一噪声水平下的最优去噪方法。

由表 3 可知,基于深度学习的去噪算法在不同噪声水平下表现出的去噪效果显著优于传统的 CBM3D 算法。值得注意的是,BRDNet 算法在各个噪声水平下的去噪表现尤为突出,远超其他同类算法。此外,随着噪声水平的增

Table 3 Average PSNR results of different methods on CBSD68, Kodak24, and McMaster datasets

表 3 各方法在 CBSD68、Kodak24 和 McMaster 数据集上的平均

PSNR 结果

数据集	噪声水平	CBM3D PSNR/dB	IRCNN PSNR/dB	FFDNet PSNR/dB	DnCNN PSNR/dB	ADNet PSNR/dB	BRDNet PSNR/dB
CBSD68	15	33.52	33.86	33.87	33.88	33.97	34.10
	25	30.71	31.14	31.20	31.22	31.29	<u>31.42</u>
	50	27.36	27.84	27.94	27.91	28.02	<u>28.13</u>
Kodak24	15	34.28	34.67	34.62	34.46	34.74	<u>34.87</u>
	25	31.67	32.01	32.11	32.01	32.25	<u>32.39</u>
	50	28.46	28.91	28.96	28.83	29.08	<u>29.21</u>
McMaster	15	34.06	34.56	34.64	33.42	34.92	<u>35.06</u>
	25	31.66	32.16	32.33	31.48	32.53	<u>32.73</u>
	50	28.87	28.89	29.16	28.59	29.34	<u>29.53</u>

加,各种去噪方法的去噪性能并未受到削弱,反而呈现出逐步提升的趋势。实验结果表明,与传统去噪方法相比,基于深度学习的去噪算法在去噪性能方面具有明显优势。

通过对上述实验结果的分析可知,当前的图像去噪技术在恢复图像效果方面仍存在若干待解决的问题:①客观评价指标与实际的主观视觉效果之间存在不匹配的情况;②去噪算法的特征提取能力有限,导致去噪后的图像中仍有残留的噪声;③对于图像中的纹理细节和边缘信息的恢复效果不够理想^[91-94]。

5 结语

图像去噪在当今的应用范围十分广泛,对该领域的研

究依然具有非常高的需求。本文主要介绍了传统与深度学习的典型去噪方法, 并对其优缺点进行了分析与总结。传统去噪方法不仅未考虑噪声种类的多样性, 而且在处理复杂的盲噪声时表现也不理想。随着深度学习图像去噪方法的出现, 不仅可通过大规模数据训练获得更准确的噪声建模, 还能更精准地捕捉复杂图像中的结构与纹理信息。然而, 深度学习方法也存在一些显著的局限性, 包括训练过程中的不稳定性、参数量过大、结果难以控制以及容易过拟合等问题。因此, 未来理想的去噪网络架构应在轻量化、训练稳定性、泛化能力以及去噪结果的可控性方面实现平衡和优化^[95-97]。

近年来, 传统与深度学习去噪方法均已得到广泛应用并取得了显著成效, 但仍存在以下有待改进的方向:

(1) 提升去噪方法对真实噪声的泛化能力。大多数的图像去噪方法对合成噪声的去噪效果表现十分优异, 但对于真实含噪声图像的去噪效果较差。这是由于真实噪声分布广泛、种类复杂且难以参数化等原因所导致的。因此, 真实噪声图像的去噪效果仍需进一步提升, 提高真实噪声去噪模型的泛化能力是一项极具挑战性的任务。

(2) 减少数据依赖性。基于深度学习的图像去噪方法大多依赖于标注的数据, 但获得高质量的标注数据可能非常困难。无监督学习通过构建自编码器的去噪网络来减少对数据的依赖性, 主要依赖于图像数据本身的结构特性和先验特性来去除噪声。因此, 无监督的图像去噪方法也是以后关注的重点。

(3) 动态图像去噪。图像去噪的方法大多都只针对静态图像进行处理, 如何实现动态图像的实时去噪也是未来图像去噪研究的方向。

(4) 提高计算效率。基于深度学习的去噪模型通常需要大量的计算资源和时间进行训练, 限制了在资源受限环境中的应用。因此, 研究更高效的网络架构、引入知识蒸馏技术, 以及根据训练过程动态调整学习率以加速收敛, 是当前极具挑战性的研究方向。

(5) 模型集成和融合。现有的图像去噪算法对于图像噪声和细节的处理过于单一, 不能完成复杂的图像去噪任务。未来的图像去噪可能会结合多个模型的优势来提高去噪性能, 在处理速度、去噪效果和模型鲁棒性方面有更大的发展潜力^[98-100]。

本文主要概述了现有的去噪方法。鉴于不同噪声需适配不同方法, 噪声分析是设计有效去噪方案的前提。因此, 做好图像去噪研究, 对后续图像处理工作具有重要的基础性意义。

参考文献:

- [1] LIU D, JIA J L, ZHAO Y Q, et al. A survey on image denoising methods based on deep learning[J]. Journal of Computer Engineering and Applications, 2021, 57(7): 1-13.
- [2] JAIN A K. Fundamentals of digital image processing[M]. Englewood Cliffs: Prentice-Hall, Inc, 1989.
- [3] SUN X X, QU W. Comparison between mean filter and median filter algorithm in image denoising field[J]. Applied Mechanics and Materials, 2014, 644-650: 4112-4116.
- [4] KUMAR B K S. Image denoising based on Gaussian/bilateral filter and its method noise thresholding[J]. Signal, Image and Video Processing, 2013, 7(6): 1159-1172.
- [5] PIAO W Y, YUAN Y B, LIN H J. A digital image denoising algorithm based on Gaussian filtering and bilateral filtering[C]//ITM Web of Conferences, 2018: 03012.
- [6] TOMASI C, MANDUCHI R. Bilateral filtering for gray and color images[C]//Proceedings of the Sixth International Conference on Computer Vision, 1998: 839-846.
- [7] BHONSLE D, CHANDRA V, SINHA G R. Medical image denoising using bilateral filter[J]. International Journal of Image, Graphics and Signal Processing, 2012, 4(6): 36-43.
- [8] GOOSSENS B, LUONG H, PIZURICA A, et al. An improved non-local denoising algorithm[C]//Proceedings of the 2008 International Workshop on Local and Non-Local Approximation in Image Processing, 2008: 143-156.
- [9] WANG J, GUO Y W, YING Y T, et al. Fast non-local algorithm for image denoising[C]//Proceedings of the 2006 International Conference on Image Processing, 2006: 1429-1432.
- [10] THAI PANICH T, OH B T, WU P H, et al. Improved image denoising with adaptive nonlocal means (ANL-means) algorithm[J]. IEEE Transactions on Consumer Electronics, 2010, 56(4): 2623-2630.
- [11] PANG C, AU O C, DAI J J, et al. A fast NL-means method in image denoising based on the similarity of spatially sampled pixels[C]//Proceedings of the 2009 IEEE International Workshop on Multimedia Signal Processing, 2009: 1-4.
- [12] RAMANATHAN V, OH B T, KUO C C J. Fast non-local means (NLM) computation with probabilistic early termination[J]. IEEE Signal Processing Letters, 2010, 17(3): 277-280.
- [13] FROMENT J. Parameter-free fast pixelwise non-local means denoising[J]. Image Processing On Line, 2014, 4: 300-326.
- [14] KARNATI V, ULİYAR M, DEY S. Fast non-local algorithm for image denoising[C]//Proceedings of the 2009 16th IEEE International Conference on Image Processing (ICIP), 2009: 3873-3876.
- [15] XING X X, WANG H L, LI J, et al. Asymptotic non-local means image denoising algorithm[J]. Acta Automatica Sinica, 2020, 46(9): 1952-1960.
- [16] XUE B D, HUANG Y, YANG J H, et al. Fast nonlocal remote sensing image denoising using cosine integral images[J]. IEEE Geoscience and Remote Sensing Letters, 2013, 10(6): 1309-1313.
- [17] ZHANG X B. Two-step non-local means method for image denoising[J]. Multidimensional Systems and Signal Processing, 2022, 33(2): 341-366.
- [18] GREWENIG S, ZIMMER S, WEICKERT J. Rotationally invariant similarity measures for nonlocal image denoising[J]. Journal of Visual Communication and Image Representation, 2011, 22(2): 117-130.
- [19] FAN L W, LI X M, GUO Q, et al. Nonlocal image denoising using edge-based similarity metric and adaptive parameter selection[J]. Science China Information Sciences, 2018, 61(4): 049101.
- [20] LENG K Q. An improved non-local means algorithm for image denoising[C]//Proceedings of the 2017 IEEE 2nd International Conference on Signal and Image Processing (ICSIP), 2017: 149-153.
- [21] ZHANG L W, XUE X J, LI H, et al. A PCB image denoising algorithm based on improved NLM[J]. Computer Engineering & Science, 2021, 43(9): 1624-1632.
- [22] BIC C, TEREDES R. An improved NLM filter with increased noise robustness and adaptive similarity function[C]//Proceedings of the 2019 IEEE 15th International Conference on Intelligent Computer Communication and Processing (ICCP), 2019: 365-370.

- [23] ZHONG H, YANG C, ZHANG X H. A new weight for nonlocal means denoising using method noise [J]. *IEEE Signal Processing Letters*, 2012, 19(8): 535–538.
- [24] LV J R, LUO X G. Image denoising via fast and fuzzy non-local means algorithm[J]. *Journal of Information Processing Systems*, 2019, 15(5): 1108–1118.
- [25] ÖKTEM R, YAROSLAVSKY L, EGIAZARIAN K, et al. Transform domain approaches for image denoising[J]. *Journal of Electronic Imaging*, 2002, 11(2): 149–156.
- [26] MATALON B, ELAD M, ZIBULEVSKY M. Image denoising with the contourlet transform[C]//*Proceedings of SPIE Wavelets XI*, 2005: 1–12.
- [27] CHEN G Y, KÉGL B. Image denoising with complex ridgelets[J]. *Pattern Recognition*, 2007, 40(2): 578–585.
- [28] PARTHASARATHY S, MARIMUTHU K. *Advances in wavelet theory and their applications in engineering, physics and technology* [M]. Rijeka: IntechOpen, 2012.
- [29] 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.
- [30] DABOV K, FOI A, KATKOVNIK V, et al. Color image denoising via sparse 3D collaborative filtering with grouping constraint in luminance-chrominance space[C]// *Proceedings of the 2007 IEEE International Conference on Image Processing*, 2007: 313–316.
- [31] MAGGIONI M, KATKOVNIK V, EGIAZARIAN K, et al. Nonlocal transform-domain filter for volumetric data denoising and reconstruction [J]. *IEEE Transactions on Image Processing*, 2012, 22(1): 119–133.
- [32] HE H Y, LEE W J, LUO D S, et al. Insulator infrared image denoising method based on wavelet generic Gaussian distribution and MAP estimation[J]. *IEEE Transactions on Industry Applications*, 2017, 53(4): 3279–3284.
- [33] BARBU A, ZHU S C. Learning real-time MRF inference for image denoising[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2009: 233–240.
- [34] DELEDALLE C-A, PARAMESWARAN S, NGUYEN T Q. Image denoising with generalized Gaussian mixture model patch priors [DB/OL]. <https://arxiv.org/pdf/1802.01458>.
- [35] HUANG W Z, XIE X X. Research on the new image de-noising methodology based on neural network and HMM-hidden Markov models [C]// *Proceedings of the International Conference on Information Engineering*, 2024: 123–134.
- [36] AHARON M, ELAD M, BRUCKSTEIN A. K-SVD: an algorithm for designing overcomplete dictionaries for sparse representation [J]. *IEEE Transactions on Signal Processing*, 2006, 54(11): 4311–4322.
- [37] DONG W S, ZHANG L, SHI G M, et al. Nonlocally centralized sparse representation for image restoration[J]. *IEEE Transactions on Image Processing*, 2012, 22(4): 1620–1630.
- [38] LEE X D, WU J F. Image denoising algorithm based on improved NCSR model [J]. *Journal of Physics: Conference Series*, 2019, 1314(1): 012209.
- [39] GUO Y H, ŞENGÜR A, YE J. A novel image thresholding algorithm based on neutrosophic similarity score [J]. *Measurement*, 2014, 58: 175–186.
- [40] DONG W S, SHI G M, LI X. Nonlocal image restoration with bilateral variance estimation: a low-rank approach[J]. *IEEE Transactions on Image Processing*, 2012, 22(2): 700–711.
- [41] CAO X Y, CHEN Y, ZHAO Q, et al. Low-rank matrix factorization under general mixture noise distributions [C]//*Proceedings of the IEEE International Conference on Computer Vision*, 2015: 1493–1501.
- [42] LIU X Y, MA J, ZHANG X M, et al. Image denoising of low-rank matrix recovery via joint Frobenius norm [J]. *Journal of Image and Graphics*, 2014, 19(4): 502–511.
- [43] JI H, HUANG S B, SHEN Z W, et al. Robust video restoration by joint sparse and low rank matrix approximation [J]. *SIAM Journal on Imaging Sciences*, 2011, 4(4): 1122–1142.
- [44] CAI J F, CANDES E J, SHEN Z W. A singular value thresholding algorithm for matrix completion[J]. *SIAM Journal on Optimization*, 2010, 20(4): 1956–1982.
- [45] GU S H, ZHANG L, ZUO W M, et al. Weighted nuclear norm minimization with application to image denoising [C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2014: 2862–2869.
- [46] MORAN N, SCHMIDT D, ZHONG Y, et al. Noisier2noise: learning to denoise from unpaired noisy data [C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020: 12064–12072.
- [47] KRULL A, BUCHHOLZ T O, JUG F, et al. Noise2void: learning denoising from single noisy images [C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2019: 2129–2137.
- [48] BATSON J, ROYER L. Noise2self: Blind denoising by self-supervision [C]//*Proceedings of the International Conference on Machine Learning*, 2019: 524–533.
- [49] QUAN Y H, CHEN M Q, PANG T Y, et al. Self2self with dropout: learning self-supervised denoising from single image [C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020: 1890–1898.
- [50] VINCENT P, LAROCHELLE H, BENGIO Y, et al. Extracting and composing robust features with denoising autoencoders [C]//*Proceedings of the 25th International Conference on Machine Learning*, 2008: 1096–1103.
- [51] 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*, 2016, 39(6): 1256–1272.
- [52] ZHANG K, ZUO W M, CHEN Y J, et al. Beyond a Gaussian denoiser: Residual learning of deep CNN for image denoising [J]. *IEEE Transactions on Image Processing*, 2017, 26(7): 3142–3155.
- [53] ZHANG K, ZUO W M, ZHANG L. FFDNet: toward a fast and flexible solution for CNN-based image denoising [J]. *IEEE Transactions on Image Processing*, 2018, 27(9): 4608–4622.
- [54] GUO S, YAN Z F, ZHANG K, et al. Toward convolutional blind denoising of real photographs [C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2019: 1712–1722.
- [55] ANWAR S, BARNES N. Real image denoising with feature attention [C]//*Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2019: 3155–3164.
- [56] CHEN J W, CHEN J W, CHAO H Y, et al. Image blind denoising with generative adversarial network based noise modeling [C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018: 3155–3164.
- [57] TRAN L D, NGUYEN S M, ARAI M. GAN-based noise model for denoising real images [C]//*Proceedings of the Asian Conference on Computer Vision*, 2020: 1–16.
- [58] TIAN C W, FEI L K, ZHENG W X, et al. Deep learning on image denoising: an overview [J]. *Neural Networks*, 2020, 131: 251–275.
- [59] ALSAIARI A, RUSTAGI R, THOMAS M M, et al. Image denoising using a generative adversarial network [C]//*Proceedings of the 2019 IEEE 2nd International Conference on Information and Computer Technologies (ICICT)*, 2019: 126–132.
- [60] LIN K, LI T H, LIU S, et al. Real photographs denoising with noise domain adaptation and attentive generative adversarial network [C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, 2019: 2124–2133.
- [61] GONG P Z, LIU J, LV S Q. Image denoising with GAN based model [J]. *Journal of Information Hiding and Privacy Protection*, 2020, 2(4):

- 155–164.
- [62] DEY R, BHATTACHARJEE D, NASIPURI M. Image denoising using generative adversarial network[M]. Singapore: Springer, 2020: 73–90.
- [63] VALSESIA D, FRACASTORO G, MAGLI E. Deep graph-convolutional image denoising[J]. IEEE Transactions on Image Processing, 2020, 29: 8226–8237.
- [64] MA Y, LIU X R, ZHAO T, et al. A unified view on graph neural networks as graph signal denoising[C]//Proceedings of the 30th ACM International Conference on Information & Knowledge Management, 2021: 1202–1211.
- [65] REY S, SEGARRA S, HECKEL R, et al. Untrained graph neural networks for denoising[J]. IEEE Transactions on Signal Processing, 2022, 70: 5708–5723.
- [66] JI M X, WU Q, FAN P Y, et al. Graph neural networks and deep reinforcement learning based resource allocation for v2x communications[J]. IEEE Internet of Things Journal, 2025, 12(4): 3613–3628.
- [67] HAN K, WANG Y, GUO J Y, et al. Vision GNN: an image is worth a graph of nodes[J]. Advances in Neural Information Processing Systems, 2022, 35: 8291–8303.
- [68] YU Y, CHEN J, GAO T, et al. DAG-GNN: DAG structure learning with graph neural networks[C]//Proceedings of the International Conference on Machine Learning, 2019: 7154–7163.
- [69] ZHOU K X, HUANG X, SONG Q Q, et al. Auto-GNN: neural architecture search of graph neural networks[J]. Frontiers in Big Data, 2022, 5: 1029307.
- [70] DU H, WANG J, HUI J, et al. DenseGNN: universal and scalable deeper graph neural networks for high-performance property prediction in crystals and molecules[J]. NPJ Computational Materials, 2024, 10: 292.
- [71] ZENG J, PANG J H, SUN W X, et al. Deep graph Laplacian regularization for robust denoising of real images[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, 2019: 1796–1805.
- [72] YAO C, JIN S, LIU M Q, et al. Dense residual transformer for image denoising[J]. Electronics, 2022, 11(3): 418.
- [73] GAO Y B, WEN Z C, DUAN X S, et al. Image denoising method based on multi-scale dual-branch transformer[J]. Journal of Yunnan University (Natural Sciences Edition), 2024, 46(1): 123–134.
- [74] TIAN C W, XU Y, ZUO W M, et al. Designing and training of a dual CNN for image denoising[J]. Knowledge-Based Systems, 2021, 226: 106949.
- [75] ZHANG J L, ZHANG Y L, GU J J, et al. Xformer: hybrid x-shaped transformer for image denoising [DB/OL]. <https://arxiv.org/abs/2303.06440>.
- [76] LIAN Z, LIU B, TAO J H. CTNet: conversational transformer network for emotion recognition[J]. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2021, 29: 985–1000.
- [77] JONATHAN H, JAIN A, ABBEEL P. Denoising diffusion probabilistic models[DB/OL]. <https://arxiv.org/abs/2006.11239>.
- [78] YANG C, LIANG L, SU Z. Real-world denoising via diffusion models [DB/OL]. <https://doi.org/10.48550/arXiv.2305.04457>.
- [79] KULIKOV V, YADIN S, KLEINER M, et al. SinDDM: a single image denoising diffusion model [DB/OL]. <https://doi.org/10.48550/arXiv.2211.16582>.
- [80] XIE Y, LI J, ZHANG H. Diffusion-based image denoising for Gaussian, Gamma, and Poisson noise[J]. IEEE Transactions on Image Processing, 2023, 30(4): 1234–1245.
- [81] ZHANG D, WANG J J, LUO F, et al. Directly denoising diffusion models [DB/OL]. <https://doi.org/10.48550/arXiv.2405.13540>.
- [82] LEE W, SON S, LEE K M. Ap-BSN: self-supervised denoising for real-world images via asymmetric PD and blind-spot network[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 17725–17734.
- [83] ZHANG D, ZHOU F, JIANG Y, et al. MM-BSN: self-supervised image denoising for real-world with multi-mask based on blind-spot network[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 4189–4198.
- [84] LI J Y, ZHANG Z L, ZUO W M. TBSN: transformer-based blind-spot network for self-supervised image denoising[DB/OL]. <https://arxiv.org/html/2404.07846v1>.
- [85] XIA H Z, LIU H Y, WEI Z H. DA-BSN: self-supervised real-world image denoising based on dynamic adaptive blind spot network[C]//Proceedings of the 2024 6th International Conference on Video, Signal and Image Processing, 2024: 94–99.
- [86] PLOTZ T, ROTH S. Benchmarking denoising algorithms with real photographs[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 1586–1595.
- [87] ABDELHAMED A, LIN S, BROWN M S. A high-quality denoising dataset for smartphone cameras[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2018: 1692–1700.
- [88] XU J, LI H, LIANG Z, et al. Real-world noisy image denoising: a new benchmark[DB/OL]. <https://arxiv.org/abs/1804.02603>.
- [89] ANAYA J, BARBU A. Renoir—a dataset for real low-light image noise reduction[J]. Journal of Visual Communication and Image Representation, 2018, 51: 144–154.
- [90] BEHJATI P, RODRÍGUEZ P, MEHRI A, et al. Overnet: lightweight multi-scale super-resolution with overscaling network[C]//Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision (WACV), 2021: 2724–2733.
- [91] KNAUS C, ZWICKER M. Progressive image denoising[J]. IEEE Transactions on Image Processing, 2014, 23(7): 3114–3125.
- [92] WU G W, WANG C M, BAO J D, et al. A wavelet threshold de-noising algorithm based on adaptive threshold function[J]. Journal of Electronics & Information Technology, 2014, 36(6): 1340–1347.
- [93] ZHANG J, ZHAO D, GAO W. Group-based sparse representation for image restoration[J]. IEEE Transactions on Image Processing, 2014, 23(8): 3336–3351.
- [94] XU J, ZHANG L, ZHANG D. A trilateral weighted sparse coding scheme for real-world image denoising[C]//Proceedings of the European Conference on Computer Vision (ECCV), 2018: 20–36.
- [95] MAIRAL J, BACH F, PONCE J, et al. Non-local sparse models for image restoration[C]//Proceedings of the 2009 IEEE 12th International Conference on Computer Vision (ICCV), 2009: 2272–2279.
- [96] XU J, ZHANG L, ZHANG D, et al. Multi-channel weighted nuclear norm minimization for real color image denoising[C]//Proceedings of the IEEE International Conference on Computer Vision (ICCV), 2017: 1096–1104.
- [97] CHANG Y, YAN L, ZHONG S. Hyper-laplacian regularized unidirectional low-rank tensor recovery for multispectral image denoising[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 4260–4268.
- [98] JIA X, LIU S, FENG X, et al. FocNet: a fractional optimal control network for image denoising[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019: 6054–6063.
- [99] ZI Z, CHENG H, HE J. Intelligent waste classification technology based on deep learning[J]. Science and Technology Innovation, 2023(21): 46–49.
- 资政, 程慧, 何佳. 基于深度学习的垃圾智能分类技术[J]. 科技与创新, 2023(21): 46–49.
- [100] JEBUR R S, MOHAMED ZABIL M H B, HAMMOOD D A, et al. A comprehensive review of image denoising in deep learning[J]. Multimedia Tools and Applications, 2024, 83(20): 58181–58192.