

中图法分类号: TP391 文献标识码: A 文章编号: 1006-8961(2025)10-3275-14

论文引用格式: Huang Y, Jiang M, Li Z, Wang F and Li A L. 2025. Real image denoising via separating features. Journal of Image and Graphics, 30(10):3275-3288(黄颖, 姜茂, 李泽, 王菲, 李艾琳. 2025. 以分离噪声特征为引导的真实图像降噪. 中国图象图形学报, 30(10):3275-3288)[DOI:10.11834/jig.240332]

以分离噪声特征为引导的真实图像降噪

黄颖, 姜茂*, 李泽, 王菲, 李艾琳

重庆邮电大学计算机科学与技术学院, 重庆 400065

摘要: 目的 基于合成噪声训练的去噪模型在实际应用中效果不佳。同时,许多真实图像去噪算法仅对图像进行端到端处理,未充分利用噪声信号的整体信息,不能有效去除噪声对图像结构信息的干扰。针对这些问题,提出一种以分离噪声特征为引导的真实图像降噪网络。**方法** 采用特征分离的策略,设计噪声图像到无噪声图像映射和无噪声图像到噪声图像映射的对称网络约束噪声特征分离,从而将噪声特征从图像内容特征中分离开来。采用对比学习对噪声特征提取进行进一步的约束,提高模型对噪声特征的学习能力。然后将分离模块提取到的噪声特征作为图像降噪的先验,噪声特征引导网络在特征域进行噪声特征的抑制。最后,双向映射都通过相应的损失函数进行约束,该网络架构具有较强的适应性和稳定性。**结果** 实验在SIDD(smartphone image denoising dataset),DND(darmstadt noise dataset)sRGB和PolyU(PolyU-real-world-noisy-images-dataset)3个数据集上进行测试。在PolyU数据集上与其他算法相比,峰值信噪比(peak signal-to-noise ratio, PSNR)提高0.25%,结构相似性(structural similarity index measure, SSIM)提高0.72%;在SIDD数据集中进行消融实验以验证分离网络的有效性。**结论** 本文提出的特征分离—引导降噪模型,综合特征分离和特征引导的思想,并融合对比学习的优点。该模型更好地利用了噪声信息,针对性地进行图像降噪,提升了图像降噪的稳定性和泛化性。

关键词: 图像降噪;真实噪声;特征分离;特征引导;对比学习

Real image denoising via separating features

Huang Ying, Jiang Mao*, Li Ze, Wang Fei, Li Ailin

School of Computer Science and Technology, Chongqing University of Posts and Telecommunications, Chongqing 400065, China

Abstract: Objective Image noise refers to the distortion phenomenon in visual signals caused by random variations or external interference. This phenomenon often leads to poor performance in various computational tasks. The core goal of image denoising is to restore clear, accurate, and high-quality images from those affected by noise interference, which makes them more consistent with human visual perception for subsequent image analysis, processing, or visual presentation. Currently, restoring damaged high-quality images has become a primary objective in the field of image processing. Many studies have achieved promising results in dealing with known distributions of noise (such as additive Gaussian white noise). However, real-world noise differs fundamentally from synthetic noise due to its origins from various factors, such as changes in lighting conditions, sensor stability, and environmental interference. This complexity leads to poor generalization capability of models trained on synthetic noise when faced with real noise, which results in suboptimal denoising effects. Some deep learning methods directly learn residual images through networks and use differences as constraints to

收稿日期:2024-06-20;修回日期:2024-11-11;预印本日期:2024-11-18

*通信作者:姜茂 S221201015@stu.cqupt.edu.cn

基金项目:国家自然科学基金项目(62471076)

Supported by: National Natural Science Foundation of China (62471076)

realize image denoising. However, real noise exhibits high non-uniformity and complexity, while single-task networks for pixel-space noise separation often ignores the complexity of noise distribution and the correlation between noise and the overall structure of the image. Therefore, this approach easily mistakes non-noise information in the image for noise and removes it. This error leads to loss of image clarity and details, which disrupts the overall structure of the image. Meanwhile, some methods adopt a combination of traditional methods and deep learning, which utilizes prior information to separate image data. Compared with traditional direct mapping approaches, these methods are more flexible and can more accurately locate and process noise. Thus, they improve the adaptability to different types of noise to some extent. However, these techniques have certain limitations in that they tend to ignore the characteristics of the image itself, which may affect its overall structure during denoising. In addition, such means usually require additional computational and network steps, which may be limited in practical applications. We propose a noise feature separation network to mitigate the impact of noise learning bias on the image itself and better balance prior information and image characteristics.

Method In this study, we draw inspiration from the concept of separation and employ a multi-module joint network, which is called the feature separation and guidance for real image denoising network, to realize feature separation and guidance. This network comprises a separation module, a guidance module, and a contrastive learning module. Considering that convolutional neural networks (CNNs) may overlook the global structural information of images when extracting deep semantic features, the basic architecture network of our network module is implemented using a cross-structure of CNN and Transformer. First, we designed a symmetric network to constrain the noise separation module without relying on any prior information. The symmetric network learns the bidirectional mapping relationship of images by mapping noise images to noise-free images, and vice versa. Subsequently, the separated noise features are used as guidance information for the image denoising module, which enables multi-scale guidance for removing noise signal features in the feature space. Finally, based on the idea of contrastive learning, we further constrain the separation module by leveraging the differences between positive and negative samples to realize noise feature separation. Given that our model learns the bidirectional mapping relationship between noisy and noise-free images, the noise separation module is constrained by structural and contrastive losses. This constraint provides more accurate noise signal features for the image denoising module and enhances the accuracy and generalization performance of the network denoising.

Result Experiments were conducted on the SIDD dataset for training and on three datasets (smartphone image denoising dataset(SIDD), darmstadt noise dataset(DND) sRGB, and PolyU-real-world-noisy-images-dataset(PolyU)) for testing. Compared with other real image denoising methods, our approach produces more consistent results in peak signal-to-noise ratio (PSNR) and structural similarity index measure (SSIM). Specifically, on the PolyU dataset, PSNR improved by 0.25%, and SSIM enhanced by 0.72%. Several ablation experiments were also conducted, and the effectiveness of each algorithm module was verified through visual demonstrations. Experimental results demonstrate that our proposed algorithm significantly improves the effect of image denoising and enhances the generalization performance of the model to a certain extent.

Conclusion This study proposes a feature space separation-guided denoising model. Based on the concept of feature separation, this model effectively transforms between feature space and pixel space, which enables flexible learning of noise signal features and provides accurate guidance information for the denoising model. Further adoption of contrastive learning improves the learning of noise signal features. Leveraging the cross-structure of Transformer and CNN enhances the retention of image features during the denoising process, which reduces the loss of key information. This network architecture efficiently separates the noise features within the image from its intrinsic features. As a result, more accurate localization and processing of noise signals is realized while preserving the original details and structure of the image. By separating and reconstructing noise signals in the feature space, our method minimizes the loss of overall image information during the denoising process, which improves denoising effectiveness and maintains image quality. The proposed method exhibits competitive performance when compared with representative state-of-the-art methods for image denoising.

Key words: image denoising; real noise; feature separation; feature guidance; contrastive learning

0 引言

图像降噪的主要目标是从含有噪声的图像中还原出清晰的图像。图像降噪旨在去除噪声的同时保留图像边缘、纹理和细节,以生成高质量的降噪图像。图像降噪不仅在各种基础应用场景中显著发挥作用,例如智能手机上的夜间视觉,而且对许多高级视觉任务产生积极影响(王亚鹏等,2021)。

传统的图像降噪(Buades等,2008;Mairal等,2009),使用如非局部均值降噪、高斯滤波、中值滤波等基于滤波的方法对图像降噪。然而,在应用这些方法时,通常需要手动调节参数以获得最佳结果,参数调节的过程过于烦琐且费时。早期工作(Chen和Pock,2017)将自然先验与深度神经网络结合,在此过程中过度依赖于自然先验信息。然而,先验信息存在一定的局限性,并不完全适用于所有图像,无法很好地恢复图像信息。随着深度学习在图像去噪领域的发展,上述问题已经得到了一定程度的缓解。在处理加性高斯白噪声(additive white Gaussian noise, AWGN)等合成噪声图像时,深度学习模型的性能通常比较好,可能由于这些噪声类型具有较为确定的统计特征,模型学习相对容易。在真实场景中,噪声的表现形式更加复杂且具有随机性,仅仅依赖合成噪声数据集训练的去噪模型在真实世界的表现可能会受到限制。

为了解决上述问题,研究人员逐渐引入一系列真实噪声数据集(Abdelhamed等,2018;Plötz和Roth,2017;Xu等,2018)。当使用真实噪声数据集进行训练时,去噪模型能够更有效地模拟并学习各种真实场景中的噪声情况,其中包括但不限于光照变化、传感器噪声和压缩噪声等。这种训练方法能够使得模型在一定程度上更好地适应真实场景下的噪声特性,从而提高了其适应性和泛化能力。然而,大多数深度学习方法都是基于数据拟合的,端到端的图像去噪算法一般通过最小化去噪图像和干净图像之间的像素差异学习噪声的映射关系,缺乏对噪声本源的深入理解。但是噪声本身与图像具有高度相关性(Chen等,2018),具有复杂的统计结构,是非独立的。并且在某种情况下,噪声像素与图像像素是相似的,甚至可能隐藏在图像细节中,模型需要能够区分噪声与图像内容并恢复原始图像。一些去噪

模型(Zhang等,2017;Chang等,2020)缺乏对噪声的深入理解与建模能力,很容易混淆噪声与图像内容。

为了解决这个问题,研究者们采用图像分离技术处理噪声。Chen等人(2018)结合低秩矩阵分解和自适应正则化等技术实现图像恢复,利用低秩矩阵分解对高光谱噪声图像中的噪声特征进行有效建模,提高了图像处理中降噪策略的整体有效性。Tian等人(2023)将小波变换融入到网络架构,通过小波变换将图像分解为多个频率成分,动态调整网络增强模块的参数,以在不同的频率成分上执行降噪处理。进而通过图像的判别学习来抑制噪声,同时保留图像的主要结构和细节。Zheng等人(2021)提出一种基于深度卷积的字典学习图像降噪方法。从训练数据中学习字典稀疏和表示稀疏的先验,为每个图像学习特定字典,提高了图像内容的自适应能力,使得降噪效果更加精确。以上采用图像分解的方法避免了传统直接映射的方法,能够精确地定位和处理噪声,并在一定程度上提高了对不同类型噪声的适应能力,但是忽略了图像本身的特性,在去噪过程中可能影响图像本身结构。这类方法还需要额外的计算和网络步骤,在实际应用中可能会受到一些限制。

此外,由于卷积神经网络(convolutional neural network, CNN)可以利用局部感受野捕获图像中的局部结构和纹理信息,通过卷积和池化操作提取图像更高级的语义特征,但是在一些情况下忽略了全局结构信息。Transformer(Zhao等,2022;Zamir等,2022)不受感受野大小的限制,可以通过自注意力机制在全局范围内捕获图像的上下文信息。Transformer采用多头注意力机制和前馈神经网络,并且自注意力机制允许模块在处理图像时考虑到块之间的关系。Yuan等人(2023)开发了一种CNN和Transformer结合的图像后处理网络,在去噪任务中将局部信息引入到Transformer运算,增强了网络对局部像素信息的表示能力,以实现网络各层之间的信息交互。这一算法的设计在于降低噪声的同时保留了图像的细节,展现了CNN和Transformer在图像处理领域的有效结合。

为了实现图像降噪而不会引起图像本身内容的失真,本文借鉴分离的思想,在以往图像分离方法的基础上进行了更深入的研究。图像去噪本身就是在保留图像信息的同时降低噪声对图像影响,最优的

去噪模式是分离开噪声而不对图像结构影响,即从特征空间的角度进行分析,利用图像的特征表示分离噪声信号特征。噪声信号与图像本身形成的方式的差异促使本文基于两者在特征空间的表现进行分离,进而利用分离出的噪声信号特征引导设计自适应降噪网络。同时网络还结合卷积层和 Vision Transformer 层(Song 等,2023)交互作用以捕捉长距离依赖,提高图像的重建质量和真实度。另外,为了进一步提高网络对噪声特征的学习能力,使其能更准确地引导网络在多尺度方面实现噪声抑制,本文引入对比学习方法。通过对比学习,网络可以通过在负样本与正样本之间的差异学习到更加鲁棒的噪声特征表示,从而使得降噪模块有效地保留图像的细节和结构。

本文的贡献包括:1)从噪声特征角度出发,对降噪问题进行分析。基于噪声与图像形成方式的差异,提出一种新的方法,即在特征空间实现噪声与图像的分离,从而实现对真实噪声图像自适应降噪。2)为了提高图像降噪的准确性以及特征提取的质量,将分离的噪声特征作为图像降噪的先验信息,从而有针对性地引导图像降噪,并引入卷积神经网络(CNN)和 Transformer 交互组合进行图像特征提取,更好地保持图像结构和细节。3)在噪声分离和特征提取的基础上,构建了噪声分离网络(noise separating network, NSNet)结构,利用对比损失约束噪声特征信息优化降噪过程。NSNet 通过端到端网络集成实现了对图像噪声的有效处理,并通过实验验证了本文方法的有效性。

1 相关工作

1.1 图像降噪

在传统的图像降噪中,通常基于对图像和噪声统计特性的理解设计相应的滤波器,以引导图像噪声的去除过程。例如,Buades 等人(2008)参考像素邻域之间的相似性,利用非局部滤波器计算像素之间的欧氏距离,从而影响滤波器的权值以实现降噪。由于滤波器在图像滑动时需要考虑窗口大小和卷积过程,导致处理图像时速度慢、效率低。

近年来,基于大型数据集训练的深度学习降噪模型,取得了很不错的结果。例如,卷积盲去噪网络(convolutional blind denoising network, CBDNet)

(Guo 等,2019)使用真实的噪声模型和真实世界中的无噪声图像对训练两个子网来估计噪声和非盲点降噪。RIDNet(residual inception-based denoising network)(Zhou 等,2019)提出具有特征注意力的单阶段降噪网络用于真实图像降噪,在残差结构中利用残差缓解低频信息流,同时应用特征注意机制利用通道间的依赖性。尽管这些方法能够改善图像降噪的性能,但是它们仍然是基于学习噪声图像和无噪声图像之间的映射关系,缺乏对图像内容的适应性,容易导致过度平滑伪影。为了能够有效地提取图像中的噪声信息,降低噪声图像与噪声的相关性,一些方法通过网络学习噪声输入图像与其降噪输出之间的差异,去噪卷积神经网络(denoising convolutional neural network, DnCNN)(Zhang 等,2017)由多个卷积层结合批量归一化等学习噪声分布映射函数,侧重于捕捉输入图像中的噪声和其他高频信息。这类方法可以通过网络学习到像素级的残差信息,取得了较好的降噪效果,但是网络过度关注图像中的像素级细节,忽略了图像整体结构和语义信息,以至于网络在训练过程中过度拟合训练数据。贺敏雪等人(2021)通过构建图像金字塔,在特征域提取图像识别对象的整体特征和局部特征,有效增强了图像识别方法。CBDNet(Guo 等,2019)通过实现对噪声水平的估计来平衡图像降噪和图像整体结构信息,建立了泊松-高斯噪声模型对原始空间上的图像进行处理,以实现噪声图像的噪声水平估计,但是简单地由网络估计噪声可能不够准确。Pan 等人(2023b)在特征域利用噪声信息构建了一个降噪残差子网络,通过迭代估计噪声水平实现对噪声的预测,进一步引导图像在特征域降噪,取得了较好的降噪性能。然而,基于噪声水平的估计可能受到噪声随机变化的限制,影响降噪精度。因此本文提出在特征域实现噪声信号的学习和分离方法,为降噪过程提供更准确、更可靠的噪声信息。

1.2 特征引导图像降噪

利用引导信息提高图像恢复的性能的思想在许多以往的工作中得到了验证。在许多以往的工作中,已经验证了利用引导信息提高图像恢复的性能的思想。通过引入额外的先验知识或复杂信息,如噪声模型、特征域的统计特性或图像结构信息,可以帮助模型更好地理解图像内容,为模型提供更多的上下文信息和约束条件。联合滤波(黄涛等,2019)

利用外部图像调整滤波器参数实现网格化去噪。Fang 等人(2021)通过从噪声图像中提取边缘信息引导图像降噪,通过在降噪过程中逐步引入边缘特征信息,在降噪图像中丰富了图像的纹理细节。特征引导在图像处理的其他领域也有广泛应用。为了减少光晕伪影并产生更好的边缘重建,Kou 等人(2015)在梯度域中执行引导滤波。通过将深度图和 RGB 图像合并到一个联合目标函数中,提供更全面的引导信息,设计这种信息引导方法(Ham 等,2015)获得了比普通超分辨率方法更好的性能。为了获得更好的性能,研究者将深度神经网络与引导信息结合,以实现更高效的图像恢复。Li 等人(2016)从对齐的 RGB 图像中提取特征用于指导深度图的低分辨率。Liu 等人(2019)提出一种用于单图像超分辨率(single image super-resolution, SISR)的相位一致性边缘图引导的多尺度深度编解码网络。这些方法证明了针对性的引导信息对图像进行恢复是有益的。本文不通过引入外部先验信息,而是采用从噪声图像中分离噪声特征信息,并用于指导网络针对性降噪。

1.3 对比学习

对比学习通过实例判别来比较和分析不同样本之间的相似性和差异性,已经成为一种有效的自我监督学习范式(He 等,2020)。AEER-Net(autoencoder and contrastive regularization network)(Wu 等,2021)引入负样本的概念用于图像去雾,通过将负样本信息作为空间的下界,AEER-Net 能够利用正样本和负样本进行训练。然而,大多数负样本是非共识的,因此与正样本相距较远。Semi-UIR(semi-supervised underwater image restoration)(Huang 等,2023)通过将样本映射到 VGG(Visual Geometry Group)特征空间,计算正负样本的偏差问题,引入对比正则化来防止错误标签的过拟合。在此背景下,本文利用对比学习增加噪声分离模块和图像映射模块之间的差异性。通过在网络结构的特征空间中应用对比学习,远离图像背景特征,从而增强对噪声特征的分

2 方 法

本文提出的 NSNet 如图 1 所示,该方法使用多编码器—解码器实现分离重建架构,充分利用了通

过分离的噪声特征引导图像降噪。由于噪声与图像之间的复杂关系,从特征空间角度对噪声进行分离可以很好地避免重建之后图像信息丢失问题。考虑到噪声分离的不确定性,采用对比损失来约束网络获取噪声特征的学习过程,其目标是使网络学习到的噪声特征尽可能远离干净图像特征,在一定程度上增强网络对噪声特征的区分能力。利用网络学习到的噪声特征引导网络对噪声进行去除,最终重建出高质量无噪声图像。

为了充分利用上下文的图像特征,本文结合 CNN 采样和 Transformer 视觉注意力块实现特征的提取与特征空间上全局信息的建模和调整。为了方便,将无噪声图像和噪声图像分别表示为 I_{NF} , $I_N \in \mathbf{R}^{H \times W}$,其中图像具有 $H \times W$ 的分辨率。独立的噪声信号为 N_I ,具有和 I_N 相同的分辨率。

2.1 研究方法

图像降噪主要是从受污染的观测图像 I_N 中恢复无噪声图像 I_{NF} ,具体为

$$I_N = I_{NF} + N_I \quad (1)$$

在真实噪声图像中,噪声 N_I 具有复杂的分布,运用任何算法恢复的 $\tilde{N}_I$ 都不能完全得到 N_I 。噪声与图像的信号之间是一种错综复杂的关系。在图像中,不同像素的噪声也存在差异性,并且在某些情况下,噪声像素与图像像素本身具有关联性,例如,在低对比度或低光条件下,噪声可能会模糊或混合在图像细节中,这使得噪声的准确区分变得困难。即仅仅依赖对图像的像素进行处理来分离噪声存在一定的局限性。

一些深度学习方法通过网络直接学习 N_I ,并使用差值作为约束,忽略了噪声分布的复杂性以及噪声与图像整体结构的相关性,破坏了图像的整体结构。为了减少噪声学习的偏差对图像本身的影响,本文没有像以往的方法一样简单地学习残差图像,通过像素相减估计降噪图像,而是通过估计差异性噪声特征,结合图像本身的特征,并利用噪声特征引导神经网络实现图像降噪。

为了实现从特征空间的角度分离噪声特性,进而提高网络的泛化性,本文采用式(1)中的基本假设。在噪声特征空间中的这种假设是一种有效的先验,可以应用于多种场景,从而在网络的中间阶段引导图像降噪过程的进行。然而,这种方法本身具有挑战性,因为不准确的噪声特征可能会增强结果中




图1 NSNet网络架构

Fig. 1 The network architecture of NSNet ((a) overall structure of NSNet; (b) encoder; (c) decoder)

的伪影和颜色偏差。如果为了平衡噪声特征的精确提取而增加过多的约束,可能会影响其他模块的性能,导致次优解。因此,需要设计网络,增加网络训练时的自适应性和效率。本文在图像降噪中仅使用式(1)的基本假设分解目标函数,而不引入其他先验。具体表示为

$$\min \sum_{i=1}^n \| (I_N^i - N_i^i) - I_{NF}^i \|_F^2 \quad (2)$$

式中, I_N^i, I_{NF}^i 表示第 i 幅噪声图像和无噪声图像, N_i^i 为第 i 幅图像的噪声信号。即在网络预测噪声的过程中,实现噪声信号 N_i^i 与实际噪声信号分布的一致性。由于在同一组样本中,噪声信号可以视为噪声图像和无噪声图像的差异映射,噪声图像和无噪声图像两者转换的共性在于对噪声信号的学习。通过网络实现对噪声信号的分离,将分离的噪声信号特征作为后续去噪过程的引导信息,进而重建无噪声图像,表示为

$$\min \sum_{i=1}^n \| \psi_{NF}((\phi_N(I_N^i), \phi_R(I_{NF}^i, I_N^i)) - I_{NF}^i \|_F^2 \quad (3)$$

式中, $\phi_N(\cdot), \phi_R(\cdot)$ 分别表示用于噪声图像特征提取模块和噪声特征分离模块,它们的输出是图像特征和噪声特征, $\psi_{NF}(\cdot)$ 表示用于重建合成无噪声图像

模块。

通过使用网络学习深层次的语义特征,将提取的高级特征映射到一个潜在空间中。在这个潜在空间中,通过对比约束网络学习的目标(如噪声特征),能更准确地理解图像的结构和内容。对比约束网络通过学习图像特征的分布情况来提高对噪声和信号的区分能力,从而更有效地分离图像中的噪声和信号成分。一旦噪声特征被成功分离,网络可以根据需要对图像进行重建,以获得无噪声和准确的图像。

2.2 噪声的分离与对比学习

为了提高基于真实噪声图像降噪模型的性能和泛化能力,本文不引入其他的先验,噪声图像分解目标函数为

$$\begin{aligned} \min_{\phi_N, \phi_R, \psi_{NF}} & \| I_{NF} - \psi_{NF}(\phi_N(I_N), \phi_R(I_{NF})) \|_F^2 + \\ & \| I_N - \psi_N(\phi_N(I_N), \phi_{NF}(I_{NF})) \|_F^2 + \\ & \| \phi_R(I_N) - \phi_R(I_{NF}) \|_F^2 \end{aligned} \quad (4)$$

在此过程中, $\phi_R(\cdot)$ 学习到噪声特征与干净特征之间的差异,进行更精确的噪声特征分离,而无需事先了解噪声的分布或性质。 $\phi_R(I_N, I_{NF})$ 在重建模块中引导 $\phi_N(I_N)$ 和 $\phi_{NF}(I_{NF})$ 实现噪声信号特征去除和

图像信号特征保留,以实现图像降噪。 $\psi_N(\cdot)$ 表示重建噪声图像模块。

可是,上述目标函数不能直接用于训练模型,因为噪声特征是无噪声图像和噪声图像之间的差异性特征,使得 $\|\phi_R(I_N) - \phi_R(I_{NF})\|_F^2 = 0$ 。为了提取高质量的噪声特征,进而提出一种基于对比学习的噪声分离方法。通过对比学习提高噪声特征分离的精度,为后续图像降噪提供可靠的基础。

具体而言,通过网络学习的噪声特征 $(\min\|\phi_R(I_N) - \phi_R(I_{NF})\|_F^2)$ 对后续图像降噪具有引导性意义 $(\min\|I_{NF} - \psi_{NF}(\phi_R(I_N), \phi_N(I_N))\|_F^2)$ 。对于无噪声图像,本文将对应的噪声图像作为正样本,将无噪声图像作为负样本,然后通过对比学习提取与噪声无关的图像特征。该网络从正样本中提取相似特征、从负样本中提取差异特征。噪声图像与其对应的无噪声图像,将提取与噪声无关的图像特征,完全能够符合噪声与图像特征域的假设 $\min\|\phi_R(I_{NF}) - \phi_R(I_N)\|_F^2$ 。通过对比学习,特征分离模块可以从空间结构上估计噪声图像的噪声特征,而不是图像特征。基于上述描述本文构建了对称网络结构,通过网络将无噪声图像重建为噪声图像,将噪声图像重建为无噪声图像,网络之间共享噪声分离模块 ϕ_R 。在图像重建过程中,噪声特征的有效处理是实现噪声图像和无噪声图像之间的有效信息交换和特征利用的关键。本文采用对比损失,在约束噪声特征的同时训练 $\phi_R(\cdot)$ 尽可能远离干净图像特征,确保学习到的特征能够更好地捕捉噪声信息,并促使网络学习到更具区分性的特征表示,具体为

$$L_{\text{contr}} = \sum_{i=1}^n w_i \frac{\|\phi_R(I_{N_i}) - \phi_R(I_{NF_i})\|}{\|\phi_R(I_{N_i}) - \phi_{NF}(I_{NF_i})\|} \quad (5)$$

式中, $\phi_{NF}(\cdot)$ 表示无噪声图像映射模块,在设计噪声映射模块 $\phi_N(\cdot)$ 时,为了确保对称网络的平衡性,采用一种结构与 $\phi_{NF}(\cdot)$ 相同但参数不同的设计策略。 n 为批次大小, $w_i \in [0, 1]$ 表示权重系数,采用 L_1 损失测量输出与正样本与负样本之间的特征空间距离。

2.3 整体架构

基于上述描述,为了将分离思想具体化,本文设计了一个具有对称网络和参数共享的编解码器结

构,该结构明确了噪声分离和重建无噪声图像模块。主要包括图像映射模块 $\phi_{N/NF}$ 、噪声分离模块 ϕ_R 、重建噪声图像模块 ψ_N 和重建无噪声图像模块 ψ_{NF} ,如图1所示。

图像映射模块 $\phi_{N/NF}$ 和噪声分离模块 ϕ_R 具有相同的结构,但图像模块中的参数不共享。每个模块由卷积层和Transformer的组合单元,为了提取网络中不同抽象级别的特征,在性能和计算资源的平衡下该模块采用4层卷积的组合。图像模块 $\phi_{N/NF}$ 接收无噪声图像 I_{NF} 或噪声图像 I_N ,用于提取图像特征;噪声分离模块 ϕ_R 接收噪声图像 I_N 和无噪声图像 I_{NF} 两个输入,并用于分离噪声特征。考虑到图像降噪过程中噪声局部信息的表示能力,以及图像重建时的全局结构信息的恢复,本文引入了Transformer块与卷积层同时进行训练的策略,以获取更精确的信息。Transformer块有助于在上下文捕获图像细节特征,并由卷积层进行下采样。通过这种训练策略提高网络对图像的特征能力。

去噪模块 ψ_{NF} 和重建模块 ψ_N 由逆卷积和Transformer的组合构成。此外,本文采用了UNet结构作为整体网络架构,通过跳跃连接将对应层的图像模块特征和噪声模块特征与合成模块的对应级别进行融合,具体为

$$\tilde{I}_{NF} = \psi_{NF}(\phi_R(I_N), \phi_N(I_N)) \quad (6)$$

$$\tilde{I}_N = \psi_N(\phi_R(I_N), \phi_{NF}(I_{NF})) \quad (7)$$

式中, $\tilde{I}_N, \tilde{I}_{NF}$ 表示重建噪声图像和重建无噪声图像。

2.4 损失函数

为了更好地训练网络,通过总损失 L 进行约束,总损失函数包含内容损失 L_{rec} 、对比损失 L_{contr} 以及结构损失 L_{ssim} 。

结构损失 L_{ssim} 表示结构相似性损失,具体为

$$L_{\text{ssim}} = 1 - f_{\text{SSIM}}(\tilde{I}_N, I_N) \quad (8)$$

内容损失 L_{rec} 通过计算输出与输入之间的 L_1 距离,包含重建损失和加噪损失,使不同的模块学习不同的特征,具体为

$$L_{\text{rec}} = \|\tilde{I}_N - I_N\|_1 + \|\tilde{I}_{NF} - I_{NF}\|_1 \quad (9)$$

总损失 L 表示为

$$L = \lambda_1 L_{\text{rec}} + \lambda_2 L_{\text{contr}} + \lambda_3 L_{\text{ssim}} \quad (10)$$

经过实验确认将权重参数 $\lambda_1, \lambda_2, \lambda_3$ 设置为1.0, 0.1, 0.4。

3 实验

3.1 实验设置

本文提出的 NSNet 通过 Pytorch 来实现。并在 NVIDIA RTX A5000 GPU 上训练和评估。本文在包含 160 对真实捕获的 SIDD 数据集上训练模型,将训练图像裁剪为 256×256 像素的图像块,并通过随机旋转以及翻转来增强数据。训练模型时采用以下参数,每个补丁随机裁剪为 256×256 像素,批量大小设置为 4,迭代轮次设置为 300 epoch,通过 Adam 优化器训练网络,初始学习率设置为 10^{-4} ,使用余弦衰减修改学习率,使其不断衰减至 10^{-6} 。

3.2 数据集

本文将提出的 NSNet 方法在 SIDD (smartphone image denoising dataset) (Abdelhamed 等, 2018)、DND (darmstadt noise dataset) (Plötz 和 Roth, 2017) 和 PolyU (PolyU-real-world-noisy-images-dataset) (Xu 等, 2018) 上进行实验,这是广泛运用于现实世界图像降噪的数据集。SIDD 数据集使用智能手机摄像头捕获噪声—无噪声图像对。每个噪声图像被捕获多次,并且均值图像用于无噪声目标样本。使用该数据集提供的 320 个图像对 (SIDD-medium) 随机裁剪为 256×256 像素用于训练,使用 1 280 个图像对的验证集用于测试。DND 数据集仅提供 50 个图像对用于测试。本文使用 DND 数据集的 sRGB 图像,它的噪声—无噪声图像对是通过使用不同的 ISO (International Organization for Standardization) 设置分两次拍摄同一场景进行的。高 ISO 图像被视为噪声输入,而相应的低 ISO 图像由于几乎没有噪声,因此将其作为目标样本。由于该数据集的真实样本未公开,需要将去噪结果文件上传至官方网站进行评估。PolyU 数据集包含 40 幅不同场景的图像,涵盖了室内正常光照场景、暗光场景以及室外正常光照场景。由于图像尺寸较大,本文从 40 个场景中随机裁剪 100 幅尺寸为 256×256 像素的区域评估本文图像降噪方法。这个数据集的目的是提供多样化的场景,以便更全面地评估降噪算法的适用性。

3.3 实验效果评估

为了评估所提出方法的效果,本文在多种场景的图像上进行测试。采用两个广泛应用的客观评价指标:峰值信噪比 (peak signal-to-noise ratio, PSNR)

和结构相似性 (structural similarity, SSIM) 以评估所提方法的性能。PSNR 是图像对应像素点之间的误差,基于像素距离作为考量,PSNR 值越高表示效果越好。SSIM 对图像的亮度、对比度和结构综合评估,更符合人眼对图像的感知。SSIM 值为 $0 \sim 1$,越接近 1 表示图像恢复越乐观。表 1 总结了 SIDD、DND sRGB 和 PolyU 在各个方法上的比较结果。其中 DRANet (dual residual attention network, DRANet) (Yang 等, 2023)、DCANet (deep connected attention networks) (Wu 等, 2023) 是通过它们训练好的降噪模型进行 PolyU 数据集上的测试。对于其他方法的数据,则是通过相关文献或综述 (Kong 等, 2023) 获取。

表 1 列出了在 SIDD、DND sRGB 图像和 PolyU 数据集上测试时的平均 PSNR 和 SSIM 值。与其他模型相比,NSNet 在去除真实的噪声方面取得了比较好的结果。在 SIDD 验证集上,NSNet 在 PSNR 方面对比 Resformer 略有欠缺,但是对比 PolyU 数据集上本文方法有显著提升。在 PolyU 数据集上,本文提出的方法相比于其他所有方法 PSNR 提升了 0.10 dB, SSIM 相较于最好的方法指标也有 0.007 的提升。如表 1 所示,只使用 SIDD 数据集训练模型,并在 3 个数据集上进行泛化测试在不同场景下表现出出色的泛化性能,可以有效处理其他数据集的数据。

为了更好地评估 NSNet 模型的视觉效果,图 2 和图 3 展示了不同方法的降噪视觉效果图。图 2 为 DND sRGB 测试集和 SIDD 验证集的可视化结果,从图像的直观表现来看,NSNet 呈现出较为突出的特征细节,有效地减少图像中的噪声同时保留了更多的细节信息。网络首先在图像特征层面将噪声分离开来,然后有针对性地对图像进行降噪处理。使得 NSNet 在去除噪声方面具备了更强的适应性,有助于确保图像质量的细节保持与提升。图 3 展示了 NSNet 在 PolyU 数据集上的实验结果,本文方法通过尽可能从图像中分离噪声,从而保留更多的图像细节。尽管在视觉效果上,NSNet 与其他方法的结果比较接近,但通过对各项指标的深入分析,发现 NSNet 在图像质量方面有显著提升。

3.4 消融研究

本文将综合考虑 NSNet 在特征分离、网络模块和基础结构 3 个方面的表现,对其设计的有效性进行评估。

表 1 不同数据集上各方法的结果
Table 1 Results of various methods on different datasets

方法	SIDD		DND sRGB		PolyU	
	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM
基准	23.66	0.457	29.83	0.701	35.44	0.937
DnCNN(Zhang等,2017)	23.66	0.583	32.43	0.790	—	—
FFDNet(Zhang等,2018)	38.27	0.948	37.61	0.941	38.76	0.970
RIDNet(Zhuo等,2019)	38.71	0.954	39.23	0.953	38.57	0.970
CBDNet(Guo等,2019)	33.26	0.869	38.06	0.942	37.81	0.956
AINDNet(Kim等,2020)	38.93	0.952	39.37	0.951	37.33	0.954
CycleISP(Zamir等,2020)	39.52	0.957	39.56	0.956	37.61	0.955
DeamNet(Ren等,2021)	39.35	0.955	39.63	0.953	37.70	0.958
Resformer(Zamir等,2022)	40.02	0.960	40.03	0.956	37.66	0.956
DRANet(Yang等,2023)	39.50	0.957	39.64	0.952	38.89	0.964
DCANet(Wu等,2023)	39.27	0.956	39.57	0.953	38.74	0.963
NSNet(本文)	39.04	0.943	39.49	0.952	38.99	0.977

注:“基准”表示噪声图像与真值之间的比较结果,加粗字体表示各列最优结果,“—”表示对应文献中未对该项指标提供相关信息。




图2 DND sRGB和SIDD去噪结果的可视化质量对比,第1行为DND sRGB数据集,其他行为SIDD数据集
Fig. 2 Visual quality comparison of denoising results on the DND sRGB and SIDD dataset. The first row is from the DND sRGB dataset, while the others are from the SIDD dataset ((a) noisy images;(b) comparison images)

3. 4. 1 特征分离有效性分析

噪声特征学习是NSNet的基础,为了验证噪声特征分离的有效性,利用训练好的NSNet网络模型

将其中噪声分离模块的特征可视化,如图4所示。图4(a)为噪声特征分离结果可视化图,图4(b)为原图。其次本文通过合成模块 $\psi_N(\cdot)$ 分别解码了图像




图3 PolyU数据集的视觉效果对比

Fig. 3 Visual quality comparison of augmentation results on the PolyU dataset

((a) noisy images; (b) noise-free images; (c) DCANet; (d) Resformer; (e) CycleISP; (f) DRANet; (g) NSNet)

特征和噪声特征,以显示网络具体所学习的噪声图像。如图5所示,图5(a)表示噪声图像特征解码,图5(b)表示噪声信息特征,图5(c)是合成的重建无噪声图像。从图5可以看出,图像信息模块所学习到的图像保留了图像本身的结构信息,并且在一定情况下降低了图像噪声。而噪声分离模块主要学习图像的噪声特征。这些现象展示了网络在学习的过程中成功地对噪声进行了分离,并且证明了噪声特征学习的有效性。




图4 噪声特征可视化

Fig. 4 Noise feature visualization ((a) visualization of noise feature separation results; (b) original images)

3.4.2 网络模块有效性评估

基于网络架构,本文从3个方面进行验证:1)训练单映射模块 ϕ_N 和重建模块 ψ_{NF} 的类UNet网络,UNet每层使用CNN和Transformer的交叉结构,将其命名为基础网络结构(baseNet);2)训练两个baseNet




图5 噪声特征分离效果图

Fig. 5 Effectiveness of noise feature separation ((a) noisy images; (b) noise feature images; (c) noise-free images)

拼接而成结构,通过图像特征引导恢复高质量图像,命名为双分支网络结构(dualNet),其中未将 I_{NF} 送入网络进行对比训练,即利用双网络的噪声图像特征引导网络实现图像降噪;3)训练无对比损失约束的网络结构,即无对比损失结构网络(NSNet_{no_Lcontr})。消融实验的指标结果如表2所示,在没有噪声特征引导或对比损失的情况下,其指标有不同程度的下降。同时本文展示了消融实验的视觉效果,如图6所示。表2显示,未用噪声特征引导的情况下,PSNR最大降低了0.64 dB;去掉对比损失时,PSNR最大降低了0.29 dB。去除这两个分量大幅度降低了网络性能。

表 2 消融实验
Table 2 Ablation experiment

方法	SIDD		DND sRGB		PolyU	
	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM
基础网络	37.44	0.930	37.37	0.923	37.97	0.951
双分支网络	38.40	0.939	39.01	0.931	38.45	0.950
NSNet _{no_Lcontr}	38.75	0.941	39.23	0.942	38.80	0.963
NSNet(本文)	39.04	0.943	39.49	0.952	38.99	0.977



图 6 消融实验效果对比

Fig. 6 Comparison of ablation experiment results

((a) noisy images; (b) noise-free images; (c) baseNet; (d) dualNet; (e) NSNet_{no_Lcontr}; (f) ours)

如果去除 NSNet 在降噪过程中的噪声特征引导,从而忽略合成重建的噪声分离的过程,NSNet 就为单网络结构,并且缺失了对比重建的过程。通过对图像进行编码和解码来恢复原始图像,其中滤波处理可以在一定程度上减少噪声和冗余信息,但是也对图像造成不可逆的信息丢失,结果图像缺乏原始图像的细节。双网络结构在去除噪声分离模块 ϕ_r 的基础上,通过利用噪声图像本身的信息引导图像去噪,从而取得了不错的效果。然而,在信息引导去噪过程中特征规则未能明确定义,导致特征学习的意义不明确。尽管如此,双网络结构相较于单网络结构在噪声去除方面表现更佳,这也证明了信息引导方法的有效性。

将对比学习引入后,评价指标和降噪图像的细节得到一定的改善,如图 6 和表 2 所示。对比学习约束图像噪声的分离,并且可以通过远离无噪声图像获得更加细节的噪声特征和无噪声图像特征,从而


更好地引导网络获得无噪声图像。本文提出的 NSNet 具有将噪声特征分离,并且能够细化图像特征的能力。

3. 4. 3 基础结构评估

使用 CNN-Transformer 交叉网络作为 NSNet 的基础结构。Transformer 在提取全局信息方面表现良好,有效弥补了卷积运算对远距离像素相关运算能力不足的问题。本文在单编解码结构网络的特征层面进一步分析 CNN 结构和 CNN-Transformer 交叉网络的特征表示。如图 7 所示,交叉结构的网络特征图相较于纯 CNN 结构的网络特征图更为细致,并且从所有通道特征图的概率分布来看,交叉结构的特征表示更加稳定。

4 结 论

本文通过噪声特征分离—引导实现了真实噪声



(a) 噪声图像

(b) 交叉结构网络特征图

(c) CNN 网络结构特征图

图7 结构特征可视化比较

Fig. 7 Visualization of structural features comparison

((a) noisy images; (b) CNN-Transformer cross-structured network feature maps; (c) CNN network structure feature maps)

条件下的图像降噪处理,提出一种图像噪声网络 NSNet。与传统在像素空间实现噪声分离的端到端网络不同,NSNet在特征空间对噪声特征进行处理。通过对称网络对噪声特征分离的约束,NSNet能够学习噪声特征对应噪声图像的特征表示,进而引导图像去噪过程中噪声抑制。借助对比学习约束网络学习正样本和负样本之间的差异表示,捕获更加精确的噪声信号特征。基于这些优点,本文方法能够有针对性地抑制噪声特征,从而实现更好的质量增强,即保留图像本身的细节信息。本文在SIDD数据集上进行了模型训练,并通过跨数据集的验证实验,结果表明该方法具有良好的泛化性和有效性。特别地,该方法采用了CNN和Transformer交叉网络结构作为基础结构,增强了网络对局部像素信息的表示能力。

受限于现有真实数据集,分离网络的噪声特征表示会受到一定限制。在之后的研究中,将设法降低对配对真实数据集的依赖,探索不配对的噪声图像到干净图像的转换方法,在特征空间实现真实图像的降噪,以适应更广泛的复杂环境中的真实噪声图像降噪需求。除此之外,还可将其应用到更多低视觉任务中(如低光照图像去噪),从而实现高质量的图像增强。

参考文献(References)

- Abdelhamed A, Lin S and Brown M S. 2018. A high-quality denoising dataset for smartphone cameras//Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: IEEE: 1692-1700 [DOI: 10.1109/cvpr.2018.00182]
- Buades A, Coll B and Morel J M. 2008. Nonlocal image and movie denoising. International Journal of Computer Vision, 76(2): 123-139 [DOI: 10.1007/s11263-007-0052-1]
- Chang M, Li Q, Feng H J and Xu Z H. 2020. Spatial-adaptive network for single image denoising//Proceedings of the 16th European Conference on Computer Vision. Glasgow, UK: Springer: 171-187 [DOI: 10.1007/978-3-030-58577-8_11]
- Chen Y, Cao X Y, Zhao Q, Meng D Y and Xu Z B. 2018. Denoising hyperspectral image with non-i.i.d. noise structure. IEEE Transactions on Cybernetics, 48(3): 1054-1066 [DOI: 10.1109/TCYB.2017.2677944]
- Chen Y J and Pock T. 2017. Trainable nonlinear reaction diffusion: a flexible framework for fast and effective image restoration. IEEE Transactions on Pattern Analysis and Machine Intelligence, 39(6): 1256-1272 [DOI: 10.1109/TPAMI.2016.2596743]
- Fang F M, Li J C, Yuan Y T, Zeng T Y and Zhang G X. 2021. Multi-level edge features guided network for image denoising. IEEE Transactions on Neural Networks and Learning Systems, 32(9): 3956-3970 [DOI: 10.1109/TNNLS.2020.3016321]
- Guo S, Yan Z F, Zhang K, Zuo W M and Zhang L. 2019. Toward convo-

- lutional blind denoising of real photographs//Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, USA: IEEE: 1712-1722 [DOI: 10.1109/cvpr.2019.00181]
- Ham B, Cho M and Ponce J. 2015. Robust image filtering using joint static and dynamic guidance//Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition. Boston, USA: IEEE: 4823-4831 [DOI: 10.1109/cvpr.2015.7299115]
- He K M, Fan H Q, Wu Y X, Xie S N and Girshick R. 2020. Momentum contrast for unsupervised visual representation learning//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 9726-9735 [DOI: 10.1109/cvpr42600.2020.00975]
- He M X, Yu Y and Cheng R Q. 2021. Vehicle logo recognition method based on feature enhancement. *Journal of Image and Graphics*, 26(5): 1030-1040 (贺敏雪, 余烨, 程茹秋. 2021. 特征增强策略驱动的车标识别. *中国图象图形学报*, 26(5): 1030-1040) [DOI: 10.11834/jig.200327]
- Huang S R, Wang K Y, Liu H, Chen J and Li Y S. 2023. Contrastive semi-supervised learning for underwater image restoration via reliable bank//Proceedings of 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver, Canada: IEEE: 18145-18155 [DOI: 10.1109/cvpr52729.2023.01740]
- Huang T, Cao L and Liu X P. 2019. Feature preservation with combined filters for mesh denoising. *Journal of Image and Graphics*, 24(8): 1292-1301 (黄涛, 曹力, 刘晓平. 2019. 保特征的联合滤波网格去噪算法. *中国图象图形学报*, 24(8): 1292-1301) [DOI: 10.11834/jig.180654]
- Kim Y, Soh J W, Park G Y and Cho N I. 2020. Transfer learning from synthetic to real-noise denoising with adaptive instance normalization//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 3479-3489 [DOI: 10.1109/cvpr42600.2020.00354]
- Kong Z M, Deng F X, Zhuang H M, Yu J, He L F and Yang X W. 2023. A comparison of image denoising methods [EB/OL]. [2024-06-20]. <https://arxiv.org/pdf/2304.08990.pdf>
- Kou F, Chen W H, Wen C Y and Li Z G. 2015. Gradient domain guided image filtering. *IEEE Transactions on Image Processing*, 24(11): 4528-4539 [DOI: 10.1109/TIP.2015.2468183]
- Li Y J, Huang J B, Ahuja N and Yang M H. 2016. Deep joint image filtering//Proceedings of the 14th European Conference on Computer Vision. Amsterdam, the Netherlands: Springer: 154-169 [DOI: 10.1007/978-3-319-46493-0_10]
- Liu H, Fu Z L, Han J G, Shao L, Hou S D and Chu Y Z. 2019. Single image super-resolution using multi-scale deep encoder-decoder with phase congruency edge map guidance. *Information Sciences*, 473: 44-58 [DOI: 10.1016/j.ins.2018.09.018]
- Mairal J, Bach F, Ponce J, Sapiro G and Zisserman A. 2009. Non-local sparse models for image restoration//Proceedings of the 12th IEEE International Conference on Computer Vision. Kyoto, Japan: IEEE: 2272-2279 [DOI: 10.1109/ICCV.2009.5459452]
- Pan Y Z, Ren C, Wu X H, Huang J and He X H. 2023b. Real image denoising via guided residual estimation and noise correction. *IEEE Transactions on Circuits and Systems for Video Technology*, 33(4): 1994-2000 [DOI: 10.1109/TCSVT.2022.3216681]
- Plötz T and Roth S. 2017. Benchmarking denoising algorithms with real photographs//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE: 2750-2759 [DOI: 10.1109/cvpr.2017.294]
- Ren C, He X H, Wang C C and Zhao Z B. 2021. Adaptive consistency prior based deep network for image denoising//Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, USA: IEEE: 8592-8602 [DOI: 10.1109/cvpr46437.2021.00849]
- Song Y D, He Z Q, Qian H and Du X. 2023. Vision transformers for single image dehazing. *IEEE Transactions on Image Processing*, 32: 1927-1941 [DOI: 10.1109/TIP.2023.3256763]
- Tian C W, Zheng M H, Zuo W M, Zhang B, Zhang Y N and Zhang D. 2023. Multi-stage image denoising with the wavelet transform. *Pattern Recognition*, 134: #109050 [DOI: 10.1016/j.patcog.2022.109050]
- Wang Y P, Li Y, Wang J B, Zhao X and Miao Z. 2021. A robust lightweight deep learning method for remote sensing scene image classification and retrieval under label noise. *Journal of Image and Graphics*, 26(12): 2991-3004 (王亚鹏, 李阳, 王家宝, 赵勋, 苗壮. 2021. 噪声鲁棒的轻量级深度遥感场景图像分类检索. *中国图象图形学报*, 26(12): 2991-3004) [DOI: 10.11834/jig.200538]
- Wu H Y, Qu Y Y, Lin S H, Zhou J, Qiao R Z, Zhang Z Z, Xie Y and Ma L Z. 2021. Contrastive learning for compact single image dehazing//Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, USA: IEEE: 10546-10555 [DOI: 10.1109/cvpr46437.2021.01041]
- Wu W C, Lv G N, Duan Y Y, Liang P, Zhang Y G and Xia Y L. 2023. DCANet: dual convolutional neural network with attention for image blind denoising [EB/OL]. [2024-06-20]. <https://arxiv.org/pdf/2304.01498.pdf>
- Xu J, Li H, Liang Z T, Zhang D and Zhang L. 2018. Real-world noisy image denoising: a new benchmark [EB/OL]. [2024-06-20]. <https://arxiv.org/pdf/1804.02603.pdf>
- Yang L, Kong S Y, Deng J H, Li H and Liu Y H. 2023. DRA-Net: a dual-branch residual attention network for pixelwise power line detection. *IEEE Transactions on Instrumentation and Measurement*, 72: #5010813 [DOI: 10.1109/TIM.2023.3259047]
- Yuan J L, Zhou F, Guo Z T, Li X Z and Yu H Y. 2023. HCformer: hybrid CNN-transformer for LDCT image denoising. *Journal of Digital Imaging*, 36(5): 2290-2305 [DOI: 10.1007/s10278-023-00842-9]
- Zamir S W, Arora A, Khan S, Hayat M, Khan F S and Yang M H.

2022. Restormer: efficient transformer for high-resolution image restoration//Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans, USA: IEEE: 5718-5729 [DOI: 10.1109/cvpr52688.2022.00564]
- Zamir S W, Arora A, Khan S, Hayat M, Khan F S, Yang M H and Shao L. 2020. CycleISP: real image restoration via improved data synthesis//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 2693-2702 [DOI: 10.1109/cvpr42600.2020.00277]
- Zhang K, Zuo W M, Chen Y J, Meng D Y and Zhang L. 2017. Beyond a Gaussian denoiser: residual learning of deep CNN for image denoising. IEEE Transactions on Image Processing, 26(7): 3142-3155 [DOI: 10.1109/TIP.2017.2662206]
- Zhang K, Zuo W M and Zhang L. 2018. FFDNet: toward a fast and flexible solution for CNN-based image denoising. IEEE Transactions on Image Processing, 27(9): 4608-4622 [DOI: 10.1109/TIP.2018.2839891]
- Zhao M, Cao G, Huang X L and Yang L F. 2022. Hybrid transformer-CNN for real image denoising. IEEE Signal Processing Letters, 29: 1252-1256 [DOI: 10.1109/LSP.2022.3176486]
- Zheng H Y, Yong H W and Zhang L. 2021. Deep convolutional dictionary learning for image denoising//Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, USA: IEEE: 630-641 [DOI: 10.1109/cvpr46437.2021.00069]
- Zhuo S K, Jin Z, Zou W B and Li X. 2019. RIDNet: recursive information distillation network for color image denoising//Proceedings of 2019 IEEE/CVF International Conference on Computer Vision Workshop. Seoul, Korea (South): IEEE: 3896-3903 [DOI: 10.1109/iccvw.2019.00483]

作者简介

黄颖,男,副教授,博士生导师,主要研究方向为图像处理、图像融合、图像质量评估、计算成像、智能信息处理与模式识别。E-mail: huangying@cqupt.edu.cn

姜茂,通信作者,女,硕士研究生,主要研究方向为图像增强。E-mail: s221201015@stu.cqupt.edu.cn

李泽,男,硕士研究生,主要研究方向为图像增强。E-mail: s221201019@stu.cqupt.edu.cn

王菲,女,硕士研究生,主要研究方向为图像增强。E-mail: iswangfeia@163.com

李艾琳,女,博士,讲师,主要研究方向为计算机视觉、图像生成与修复、多模态学习和图像风格迁移。E-mail: lial@cqupt.edu.cn