

融合多尺度特征的高效去除图像摩尔纹算法



隆伟¹, 胡玛莉², 黎鹏¹, 刘阳², 朱洲森², 廖雪花^{1,*}

¹四川师范大学计算机科学学院, 四川成都 610101

²四川师范大学物理与电子工程学院, 四川成都 610101

摘要: 针对图像摩尔纹干扰复杂多样、纹理细节与边缘信息难以被充分保留, 以及现有去摩尔纹模型效果欠佳、计算复杂度较高等问题, 本文提出了一种基于 UNet 的高效去摩尔纹算法 MSFDNet (Multi-Scale Feature and Density-aware Network)。首先, 在特征提取阶段引入基于密度参数的加权卷积层 (WCL), 通过自适应权重调整增强卷积核中心区域响应; 其次, 设计多尺度特征增强模块 (MCFE), 利用不同膨胀率卷积分支结合通道注意力机制, 有效捕获跨尺度纹理特征; 同时提出空间特征调制模块 (SFM), 通过空间注意力机制突出摩尔纹干扰集中区域, 提升网络对空间分布差异的感知能力; 在解码阶段结合跳跃连接与残差连接策略, 实现多尺度信息的有效融合与鲁棒恢复。MSFDNet 算法在 TIP、FHDMi 与 UHDM 三个公开数据集上, 在 PSNR、SSIM 和 LPIPS 三项评估指标上均优于目前主流的去摩尔纹算法。在 TIP 数据集上, PSNR 达到 31.04 dB、SSIM 达到 0.943, 较其他算法有明显提升; 在 FHDMi 数据集上, PSNR 达到 24.695 dB, 在 UHDM 数据集上 SSIM 提升至 0.8154, 均优于目前主流算法; 所提算法能够在有效去除图像摩尔纹的同时保持图像纹理与边缘细节, 兼具更强的泛化能力与鲁棒性。

关键词: 图像摩尔纹去除; 加权卷积; 多尺度特征增强; Unet

DOI: 10.57237/j.cst.2026.01.002

Efficient Image Moir é Removal Algorithm That Integrates Multi-scale Features

Long Wei¹, Hu Mali², Li Peng¹, Liu Yang², Zhu Zhousen², Liao Xuehua^{1,*}

¹College of Computer Science, Sichuan Normal University, Chengdu 610101, China

²College of Physics and Electronic Engineering, Sichuan Normal University, Chengdu 610101, China

Abstract: Aiming at the complex and diverse interference of image moir é patterns, the difficulty in fully preserving texture details and edge information, and the poor performance and high computational complexity of existing moir é pattern removal models, a new moir é pattern removal network model based on UNet network is proposed, which integrates weighted convolution and multi-scale attention mechanism. In the feature extraction stage, a weighted convolutional layer based on density parameters is introduced to enhance the central region response of the convolutional

基金项目: 国家社会科学基金一般项目 (20BMZ092).

*通信作者: 廖雪花, liaoxuehua@sicnu.edu.cn

收稿日期: 2025-12-11; 接受日期: 2026-01-12; 在线出版日期: 2026-01-20

<http://www.computscitech.com>

kernel through adaptive weight adjustment, while suppressing the influence of edge noise. Secondly, in order to more effectively capture multi-scale feature information, spatial attention blocks and multi-scale channel attention modules are used for deep level feature extraction to obtain more detailed and rich feature representations. In the decoding stage, a combination of skip connections and residual connections is used to enhance the robustness of the model through multi-scale output, and finally, Moir é fringes are removed through weighted convolutional layers. The experimental results show that the evaluation scores of the model on three public datasets, UHDM, TIP, and FHDMI, are better than those of mainstream models for removing image moir é patterns, proving that the model effectively improves the effectiveness of image moir é pattern removal.

Keywords: Image Moir é Removal; Weighted Convolution; Multi-scale Attention; UNet

1 引言

在使用拍摄仪器拍摄图像后,有时,图像中会出现一种分布不均的彩色波纹。这种不规则的波纹叫做摩尔纹,如图 1 所示。摩尔纹干扰是图像采集过程中常见的一种周期性条纹干扰现象,主要是由传感器阵列与图像纹理之间的混叠效应产生[1]。摩尔纹不仅影响图像的视觉质量,还会干扰图像的分析以及处理任务。早期去除

摩尔纹的方法主要基于频域滤波和空域滤波技术[2-4],但这些方法往往在去除摩尔纹的同时会损失图像的细节信息,导致图像模糊或产生伪影。其中,还出现了一些基于图像插值的算法,利用图像之间的色差的插值算法来去除图像摩尔纹[5-7],这些插值算法实现复杂,并且难以满足高质量图像处理的需求。



图 1 带有摩尔纹的图像

Figure 1 Image with moiré pattern

近年来,随着深度学习技术的发展,基于卷积神经网络(CNN)的图像去摩尔纹方法逐渐成为研究热点。早期研究中, Sun 等人[8]提出的多分辨率全卷积网络(Deep Multiresolution Fully Convolutional Neural Network, DMCNN)通过多分支处理不同分辨率图像,但未充分利用尺度间联系导致特征提取不足;随后 Gao 等人[9]在此基础上提出多尺度特征增强网络(Multi-Scale Feature Enhancement, MSFE)以融合不同分支上下文信息,但摩尔纹去除效果提升有限; Zheng 等人[10]从频域角度设计多尺度带通 CNN(Multi-Scale Bandpass CNN, MBCNN),将摩尔纹去除过程分解为纹

理恢复与色彩校正两个阶段; He 等人[11]针对摩尔纹频率复杂性、颜色通道不平衡性及外观多样性提出的 MopNet (Moir é Pattern Removal Neural Network) 到达了显著提升去摩尔纹效果,但在多尺度信息交互和特征融合方面仍存在改进空间;近几年,研究者们将去除高清图像摩尔纹作为研究重点,对于图像超分辨重建的研究也逐渐成熟[12-14],而 Bin 等人[15]针对高分辨率图像提出的 FHDe2Net (Full High Definition Demoir éing Network)在高清图像摩尔纹去除上虽表现优异,但在计算效率、处理速度及泛化能力方面仍存在不足。这些研究共同表明,尽管去摩尔纹方法不断

优化,但在多尺度信息交互、特征融合及高效处理方面仍存在改进空间。

为此,本文提出一种基于 UNet [16]改进的去摩尔纹算法 MSFDNet,以解决图像摩尔纹去除中多尺度纹理特征提取不足、边缘噪声干扰以及空间分布感知能力有限等问题。主要创新与贡献如下: 1) 设计增强型 UNet 块 (Enhanced UNet Block, EUB), 替换传统 UNet 中的简单卷积块,并将 EUB 中的普通卷积替换为加权卷积 (Weighted Convolution Layer, WCL) [17],通过自适应权重调整增强卷积核中心区域的响应,抑制边缘噪声干扰,提高对复杂摩尔纹纹理结构的特征提取能力; 2) 提出多尺度特征增强模块 (Multi-scale Channel Feature Enhancement, MCFE),集成在 EUB 中,利用多个不同膨胀率的卷积层捕获多尺度特征,实现对摩尔纹多尺度模式的精确感知; 3) 提出空间特征调制模块 (Spatial Feature Modulation, SFM),并且也将其集成在 EUB 中,通过空间注意力机制识别摩尔纹的空间分布特征,突出包含摩尔纹的重要区域,同时保持图像细节丰富区域,实现空间维度的智能特征调制。实验结果表明本文提出的融合多尺度特征的去除图像摩尔纹的算法能够有效识别和去除多种复杂类型的摩尔纹模式,同时保护无摩尔纹区域的图像质量,在处理不同分辨率和不同复杂度的图像时都表现出稳定的性能,具有较强的鲁棒性和实用性。

2 本文算法

2.1 网络结构

UNet 在近些年以及广泛应用于图像去噪[18-20]、去模糊[21]等,去除图像摩尔纹本身也是一种图像去噪任务。UNet 网络利用编码-解码结构获取多尺度特征,并通过跳跃连接实现不同层次信息的结合。但由于其特征提取深度有限且融合方式较为简单,在应对摩尔纹等复杂纹理时存在学习不足的问题,难以充分表达高级特征。所以,本文在 UNet 网络的基础上进行改进,提出一种融合多尺度特征的去除图像摩尔纹的网络,网络结构图如图 1 所示。

本文网络在编码阶段引入多阶段特征增强机制,通过多个 Stage 结合 MaxPool 操作逐步下采样,扩展感受野的同时提取不同尺度的底层特征,每个 Stage 中的 EUB 模块负责对当前尺度特征进行精细提取;在解码阶段,利用上采样模块 (Upsampling Block) 逐步恢复特征图分辨率,并再次通过 EUB 模块对特征进行重构与优化,同时,网络充分利用跳跃连接,将编码阶段不同 Stage 提取的特征传递至解码阶段对应层级,实现不同层级特征的直接交互,还设计了包含 Bottleneck 结构的连接通路,对不同层级的特征进行更复杂的交互与融合,最后通过 3×3 卷积层得到最终的去摩尔纹结果,以此增强网络对多尺度摩尔纹特征的捕捉与处理能力,提升去摩尔纹的效果。




图 2 UNet 网络结构改进

Figure 2 Improved UNet network structure

2.2 增强型 UNet 块

传统的 UNet 网络在特征提取和融合方面存在深度有限且融合方式简单的问题，一个重要原因在于 UNet 网络中使用了普通的双层卷积块，难以充分表达摩尔纹等复杂纹理的高级特征。为了提升网络的特征提取能力，本文设计了增强型 UNet 块 EUB 作为基础特征提取单元。如图 4 所示。

EUB 模块的设计遵循了渐进式特征提取和增强的策略，其核心思想是通过多阶段的特征处理来逐步提升网络对复杂纹理的感知能力。在初始特征提取阶段，模块通过两个 3×3 加权卷积层和 ReLU 激活函数构建基础特征表示，这种设计能够有效捕获局部纹理特征和边缘信息。第一个 3×3 加权卷积层负责初步特征提

取，第二个 3×3 加权卷积层则进一步深化特征表示，通过这种双层卷积结构，网络能够学习到更加丰富的特征表示。

随后，模块采用 1×1 加权卷积层进行特征精炼，这种设计不仅能够调整通道维度，还能够实现特征的压缩和扩展。通过两个连续的 1×1 加权卷积层，网络能够学习到更加抽象和高级的特征表示。同时，模块通过内部残差连接实现特征融合，这种设计不仅缓解了梯度消失问题，还允许网络学习残差映射，从而提升特征表达能力。在基础特征完成后，接着通过 MCFE 模块进行多尺度特征增强，最后通过 SFM 模块进行空间特征调制。这种设计使得网络能够在保持计算效率的同时，充分提取和利用摩尔纹图像的多尺度空间特征信息。




图 3 EUB 结构

Figure 3 Enhanced UNet Block structure

2.3 加权卷积层

加权卷积层 (WCL) 旨在提升网络对摩尔纹的复杂纹理特征的建模能力。传统卷积层采用统一权重的卷积核进行特征提取，难以适应摩尔纹图像中复杂且非均匀的空间分布特性。为此，本文引入了一种空间密度感知的加权卷积算子[17]，通过在卷积操作中引入空间权重矩阵，使网络能够根据像素相对于中心像素的位置进行差异化加权处理。

首先基于预设的密度参数 $den = [0.75, 0.5]$ 构造一维权重向量 α ，并通过外积运算生成二维空间权重矩阵 Φ ，公式如(1)所示。

$$\alpha = \{den, 1.0, flip(den)\}, \Phi = \alpha \otimes \alpha \quad (1)$$

其中 $\Phi \in \mathbb{R}^{k \times k}$ 会根据卷积核尺寸自动适配。当卷积核为 3×3 时，选取 α 的中心部分生成对应的 Φ ；当卷积核为 5×5 时，则直接使用完整权重矩阵。

在卷积操作中，卷积核权重 W 与空间权重矩阵 Φ 逐元素相乘，得到加权后的卷积核如(2)所示。

$$y = x * (W \odot \Phi) + b \quad (2)$$

其中 $\odot$ 表示逐元素乘法， x 输入特征图， y 为输出特征图。该算子在保持与标准卷积相同参数量和计算复杂度的前提下，有效提升了网络对复杂纹理的空间感知能力，能够更精准地建模摩尔纹的空间分布特征。同时，该模块完全兼容现有 CNN 架构，可直接替换标准卷积层进行部署。实验结果表明，引入该加权卷积算子不仅增强了网络的纹理表征能力，还为后续的多尺度特征增强和空间特征调制提供了更高质量的特征表示。

2.4 多尺度特征增强模块

摩尔纹具有跨尺度的空间分布特性，既包含局部细节干扰，也伴随大范围的条纹结构。针对这一特点，我们设计了多尺度特征增强模块 MCFE，模块结构图如图 2 所示。该模块借鉴了 Inception 模块[22]的多尺度卷积思路和 SE 注意力机制[23]的通道重标定策略，并结合去图像摩尔纹任务的特点进行了改进。

MCFE 首先通过不同膨胀率的卷积分支提取多尺

度特征,使网络能够同时感知细粒度的局部纹理与大尺度的条纹信息。随后,模块将多尺度特征进行融合,并引入改进后的轻量级的通道注意力,对关键尺度特征进行增强,对不相关或冗余特征进行抑制。这样既避免了特征拼接带来的维度冗余,又保证了特征融合的高效性。其核心计算表达式可化为(3)所示。其中, x_i 表示不同膨胀率卷积分支的输出, $GAP(\cdot)$ 表示全局平均池化, $\delta(\cdot)$ 表示 ReLU 激活, $\sigma(\cdot)$ 为 Sigmoid 函数。

$$y = \left(\sum_{i=1}^3 x_i \right) \otimes \sigma \left(W_2 \delta \left(W_1 GAP \left(\sum_{i=1}^3 x_i \right) \right) \right) \quad (3)$$

通过多尺度并行分支结构,网络能够同时捕获细粒度的高频摩尔纹和粗粒度的低频摩尔纹模式,显著提升了特征表达的丰富性。一方面增强了对大尺度周期性条纹的感知,另一方面也保留了局部纹理细节,从而在去除摩尔纹的同时保持了图像的清晰度和结构一致性。




图 4 MCFE 网络结构

Figure 4 Multi-scale Channel Feature Enhancement Network Structure

2.5 空间特征调制模块

摩尔纹图像中的纹理信息在空间分布上具有不均匀性,不同区域的重要性存在显著差异。为了增强网络对重要空间区域的特征提取能力,本文设计了空间特征调制模块 SFM,如图 3 所示。

该模块借鉴了空间特征提取模块[24]的设计思路,利用局部信息进行自适应动态调整每个像素位置的特征,增强模型对不同区域的适应性。对于输入的特征, SFM 模块首先在通道维度上执行两个并行且互补的特征平均池化和最大池化操作。沿通道维度进行全局最大池化操作,此操作能够捕获特征图中每个空间位置上最显著的特征响应,突出重要的局部信息,特别是对于摩尔纹等具有强烈局部对比度的纹理特征具有显著效果;沿通道维度进行全局平均池化操作,此操作能够捕获特征图中每个空间位置的整体信息,提供更平滑的上下文表示,有助于保持纹理的连续性和整体性。将两个池化结果在通道维度上拼接,这种拼接操作有效地融合了两种不同类型的空间上下文信息,为后续的特征处理提供了丰富的输入。然后通过卷积层生成空间注意力图,最后通过 Sigmoid 激活函数将注意力权重归一化到[0,1]区间。

SFM 模块的设计还考虑了计算复杂度和性能的平衡。通过合理的模块设计和特征处理流程, SFM 不仅能

够在保持较低计算复杂度,还显著提升网络的空间特征处理能力。同时网络能够自适应地关注摩尔纹集中的重要区域,抑制背景噪声区域的干扰。这种空间选择性的特征增强使得网络在处理复杂摩尔纹特征时具有更好的鲁棒性和准确性,有效提升了摩尔纹去除的视觉效果。




图 5 SFM 网络结构

Figure 5 Spatial Feature Modulation Network Structure

3 实验与结果分析

3.1 实验环境及参数配置

本文所研究的所有实验均在同一环境下进行。硬件环境方面配置 CPU 处理器 Intel(R) Xeon(R) Gold 5418Y (10 核)、NVIDIA RTX 4090 显卡,内存容量为 120 GB;深度学习框架采用 Pytorch 2.2.0, Python 版本为 3.10。

模型的主要参数设置如下:其中训练 UHDM 数据集训练轮次 (epochs) 为 150,批处理量 (batchsize)

为2;FHDMi的训练epochs也为150,batchsize也为2;而训练TIP数据集的epochs为90,batchsize设置为4。优化器(optimizer)使用Adam优化器,学习率为0.0002,动量为0.9、0.999。

3.2 数据集

本研究使用UHDM [25]、FHDMi [15]与TIP [8]三套公开摩尔纹数据集对所提方法进行训练与评测。三

者涵盖不同成像设备、显示介质与采集环境下产生的典型摩尔纹形态,能够充分反映任务在跨场景、跨设备条件下的泛化能力。UHDM数据集是超高分辨率、在真实环境下所拍出的图像;FHDMi数据集是高分辨率、真实摩尔纹图像;而TIP数据集是分辨率较低、合成的摩尔纹图像,与真实拍摄的摩尔纹存在差异。三者数据集的对比如表1所示。

表1 不同训练数据集对比

Table 1 Comparison of different training datasets table

数据集	图像分辨率/像素	规模	发布年份
TIP	256×256	8100 对训练图像, 1000 对验证图像	2018
FHDMi	1920×1080	8000 对训练图像, 1050 对验证图像	2020
UHDM	3840×2160	4500 对训练图像, 500 对验证图像	2022

3.3 评估指标

为全面衡量去摩尔纹效果,本文采用峰值信噪比(PSNR)、结构相似性(SSIM)与感知相似性指标(LPIPS)作为主要客观评价指标,对去除图像摩尔纹的算法进行比较分析。

峰值信噪比(PSNR)是衡量图像重建质量的传统指标,数值越高代表重建结果与参考图像越接近。其表达式如(4)所示。

$$\text{PSNR} = 10 \cdot \log_{10} \left(\frac{\text{MAX}_I^2}{\text{MSE}} \right) \quad (4)$$

其中, MAX_I 表示图像像素的最大可能取值, MSE 为重建图像与参考图像之间的均方误差,表达式如(5)所示。

$$\text{MSE} = \frac{1}{HW} \sum_{i=1}^H \sum_{j=1}^W (I(i, j) - \hat{I}(i, j))^2 \quad (5)$$

这里 I 表示参考图像, $\hat{I}$ 表示去除摩尔纹后的图像。

结构相似性(SSIM)用于衡量两幅图像在亮度、对比度和结构方面的相似性,更符合人眼感知。其定义为如(6)所示。

$$\text{SSIM}(I, \hat{I}) = \frac{(2\mu_I \mu_{\hat{I}} + C_1)(2\sigma_{II} + C_2)}{(\mu_I^2 + \mu_{\hat{I}}^2 + C_1)(\sigma_I^2 + \sigma_{\hat{I}}^2 + C_2)} \quad (6)$$

其中, $\mu_I, \mu_{\hat{I}}$ 分别为图像 I 与 $\hat{I}$ 的均值, $\sigma_I^2, \sigma_{\hat{I}}^2$ 为

方差, σ_{II} 为协方差, C_1, C_2 为稳定常数。

感知相似性指标(LPIPS)则通过深度网络对两幅图像的感知差异进行建模,其计算方式为(7)所示。

$$\text{LPIPS}(I, \hat{I}) = \sum_l \frac{1}{H_l W_l} \sum_{h,w} \|w_l \odot (\phi_l(I)_{hw} - \phi_l(\hat{I})_{hw})\|_2^2 \quad (7)$$

其中, $\phi(\cdot)$ 表示在预训练网络第 l 层提取的特征表示, w_l 为通道权重, H_l, W_l 分别为该层特征的空间维度。LPIPS 值越小,说明结果与参考图像在感知上越接近。

3.4 对比实验

将本文实现的算法模型与目前最主流的三个去图像摩尔纹算法模型进行比较(包括MBCNN [10], FHDe²Net [15], ESDNet [8]),通过峰值信噪比(PSNR)、结构相似性(SSIM)、感知相似性指标(LPIPS)三个评价指标来综合评价算法模型的性能优劣。如表2所示,本文提出的算法模型在三个公开数据集上的表现均优于其他方法。在低分辨率的TIP数据集上,本文方法的PSNR和SSIM分别达到31.04dB和0.943,相较于其他方法有更为显著的提升,说明该模型在低分辨率场景下具备更强的去除图像摩尔纹与图像结构保持能力。在高分辨率数据集FHDMi与UHDM上,本文算法模型同样保持领先,其中在FHDMi数据集上PSNR达到24.695dB,在UHDM数据集上SSIM提升至0.8154,均超过现有主流算法模型,验证了该方法在复杂纹理与高分辨率场景中

的泛化能力和鲁棒性。在感知指标方面，本文方法在各个数据集上的 LPIPS 值均为最优（例如在 FHDMi 和 UHDM 上分别达到 0.1240 与 0.2369），表明复原图像在感知质量上更接近真实图像，有效减少了视觉失真。实验结果数据表面，本文提出的模型不仅在客观定量指标上全面超越了当前最先进的去摩尔纹算法，而且在主观感知质量上也展现出更优的效果。

从图 6 可以明显观察到，目前主流算法模型在去

除摩尔纹的同时往往会引入一定程度的模糊或残留伪影，且仍存在明显的条纹残余，ESDNet 虽在一定程度上改善了图像质量，但细节表现仍不够理想。相比之下，本文算法模型在有效去除摩尔纹的同时，能够更好地保留图像纹理与结构信息，复原效果与原始图像更加接近，整体视觉质量也显著优于其他方法。进一步说明，本文提出的算法在客观指标和主观感知两方面均具备突出的优势。

表 2 对比实验结果

Table 2 Comparative experimental results

数据集	评估指标	MBCNN	FHDe2Net	ESDNet	本文
TIP	PSNR↑	30.03	27.78	29.81	31.04
	SSIM↑	0.893	0.896	0.916	0.943
	PSNR↑	22.309	22.930	24.500	24.695
FHDMi	SSIM↑	0.8095	0.7885	0.8351	0.8358
	LPIPS↓	0.1980	0.1688	0.1354	0.1240
	PSNR↑	21.414	20.338	22.119	22.198
UHDM	SSIM↑	0.7932	0.7496	0.7956	0.8154
	LPIPS↓	0.3318	0.3519	0.2551	0.2369




图 6 实验结果对比图：(a)输入图像；(b)MBCNN；(c) FHDe²Net；(d)ESDNet；(e)本文；(f)原始图像

Figure 6 Comparison chart of experimental results: (a)Input; (b)MBCNN; (c) FHDe²Net; (d)ESDNet; (e) MSFDNet; (f) GT

3.5 消融实验

为验证本文中各关键模块对去图像摩尔纹性能共同起优化作用，本文在统一训练与评测协议下进行消融实验。以完整模型为基线（包含加权卷积 WCL、多尺度特征增强 MCFE、空间特征调制 SFM），逐项或组

合移除相应模块，构建多种模型变体并进行对比。所有变体保持除被消融模块外的网络结构、训练超参数与数据处理流程完全一致，评估指标采用 PSNR、SSIM 与 LPIPS，使用 UHDM 数据集进行各个模型训练并测试。

实验中的基线模型为未使用 WCL、无 MCFE 模块与 SFM 模块所组合成的模型。最终得到的结果如表 3

所示，相对于基线模型，仅使用 WCL 的情况下，模型表现不出明显优势，PSNR 降低 0.24、SSIM 仅提升 0.0007，反而在其他模块组合情况下，能表现出更加明显的优势，但均劣于本文（WCL+MCFE+SFM）模型效果。

表 3 消融实验结果

Table 3 Ablation experiment results

模型	PSNR↑	SSIM↑	LPIPS↓
本文	22.198	0.8154	0.2369
MCFE + SFM	21.628	0.8119	0.2475
WCL+ SFM	20.260	0.7873	0.2793
WCL+ MCFE	21.447	0.8020	0.2693
SFM	20.490	0.7888	0.2705
MCFE	20.796	0.8009	0.2629
WCL	20.003	0.7837	0.2798
基线模型	20.243	0.7830	0.2736

4 结论

本文围绕图像去摩尔纹任务，提出了一种基于 UNet 骨干并融合多尺度与空间调制机制的去摩尔纹网络。引入空间密度感知的加权卷积（WCL）以提升复杂纹理区域的表征能力；设计多尺度特征增强模块（MCFE）以同时建模不同频率与感受野下的摩尔纹模式；结合空间特征调制模块（SFM）以自适应突出干扰集中的关键位置。在 UHDM、FHDMi 与 TIP 这三个公开数据集上进行统一设置的训练与测试。为系统评估各组件的有效性，本文构建了覆盖单模块与多模块的消融体系，并实验结果表明，所提方法在 PSNR、SSIM 与 LPIPS 等指标上均取得了更优的表现。消融实验进一步验证了三类模块的互补性：WCL 有助于细节一致性与纹理还原，MCFE 有效抑制多尺度周期性伪影，SFM 提升空间关注与区域选择性；三者联合能获得最优的综合表现。

参考文献

[1] 亓文法, 刘宇鑫, 郭宗明. 摩尔纹图案自动去除技术综述 [J]. 计算机研究与发展, 2024, 61(03): 728-747.

[2] Sun B, Li S, Sun J. Scanned image descreening with image redundancy and adaptive filtering [J]. IEEE transactions on image processing, 2014, 23(8): 3698-3710.

[3] Wei Z, Wang J, Nichol H, et al. A median-Gaussian filtering framework for Moiré pattern noise removal from X-ray microscopy image [J]. Micron, 2012, 43(2-3): 170-176.

[4] Sidorov D N, Kokaram A C. Removing moire from degraded

video archives [C] // 2002 11th European Signal Processing Conference. IEEE, 2002: 1-4.

[5] Kimmel R. Demosaicing: Image reconstruction from color CCD samples [J]. IEEE Transactions on image processing, 1999, 8(9): 1221-1228.

[6] 邱菊. 基于插值算法的去彩色摩尔纹效应的研究 [D]. 南京理工大学, 2009.

[7] 邱香香. 基于 CCD 静态图像的摩尔纹去除算法研究 [D]. 南京理工大学, 2012.

[8] Sun Y, Yu Y, Wang W. Moiré photo restoration using multi-resolution convolutional neural networks [J]. IEEE Transactions on Image Processing, 2018, 27(8): 4160-4172.

[9] Gao T, Guo Y, Zheng X, et al. Moiré pattern removal with multi-scale feature enhancing network [C] // 2019 IEEE International Conference on Multimedia & Expo Workshops (ICMEW). IEEE, 2019: 240-245.

[10] Zheng B, Yuan S, Slabaugh G, et al. Image demoireing with learnable bandpass filters [C] // Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2020: 3636-3645.

[11] He B, Wang C, Shi B, et al. Mop moire patterns using mopnet [C] // Proceedings of the IEEE/CVF international conference on computer vision. 2019: 2424-2432.

[12] Dong C, Loy C C, He K, et al. Learning a deep convolutional network for image super-resolution [C] // European conference on computer vision. Cham: Springer International Publishing, 2014: 184-199.

[13] Kim J, Lee J K, Lee K M. Accurate image super-resolution using very deep convolutional networks [C] // Proceedings of the IEEE conference on computer vision and pattern recognition. 2016: 1646-1654.

[14] Ledig C, Theis L, Huszár F, et al. Photo-realistic single image super-resolution using a generative adversarial network [C] // Proceedings of the IEEE conference on computer vision and pattern recognition. 2017: 4681-4690.

[15] He B, Wang C, Shi B, et al. FHDe²Net: Full high definition demoireing network [C] // European Conference on Computer Vision. Cham: Springer International Publishing, 2020: 713-729.

[16] Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation [C] // International Conference on Medical image computing and computer-assisted intervention. Cham: Springer international publishing, 2015: 234-241.

[17] Cammarasana S, Patanè G. Optimal Weighted Convolution for Classification and Denosing [J]. arXiv preprint arXiv: 2505.24558, 2025.

- [18] Zhang K, Li Y, Liang J, et al. Practical blind image denoising via Swin-Conv-UNet and data synthesis [J]. Machine Intelligence Research, 2023, 20(6): 822-836.
- [19] Fan C M, Liu T J, Liu K H. SUNet: Swin transformer UNet for image denoising [C] // 2022 IEEE International Symposium on Circuits and Systems (ISCAS). IEEE, 2022: 2333-2337.
- [20] Gurrola-Ramos J, Dalmau O, Alarcon T E. A residual dense u-net neural network for image denoising [J]. IEEE Access, 2021, 9: 31742-31754.
- [21] Shi X P, Lin S Y, Yang M L, et al. Image deblurring by multi-scale modified U-Net using dilated convolution [J]. Science Progress, 2024, 107(1): 00368504241231161.
- [22] Szegedy C, Liu W, Jia Y, et al. Going deeper with convolutions [C] // Proceedings of the IEEE conference on computer vision and pattern recognition. 2015: 1-9.
- [23] Hu J, Shen L, Sun G. Squeeze-and-excitation networks [C] // Proceedings of the IEEE conference on computer vision and pattern recognition. 2018: 7132-7141.
- [24] Sun L, Dong J, Tang J, et al. Spatially-adaptive feature modulation for efficient image super-resolution [C] // Proceedings of the IEEE/CVF international conference on computer vision. 2023: 13190-13199.
- [25] Yu X, Dai P, Li W, et al. Towards efficient and scale-robust ultra-high-definition image demoir âng [C] // European Conference on Computer Vision. Cham: Springer Nature Switzerland, 2022: 646-662.