arXiv:2602.01559v1 [cs.CV] 2 Feb 2026

屏幕截图中闪烁条带与莫尔纹的联合去除

Libo Zhu [*1] **Zihan Zhou** [*1] **Zhiyi Zhou** [1] **Yiyang Qu** [1] **Weihang Zhang** [2] **Keyu Shi** [2] **Yifan Fu** [2] **Yulun Zhang** [1]

摘要

使用移动设备拍摄显示屏已日益普遍，但所得图像往往会因莫尔´纹与闪烁条带并存而出现严重退化，导致视觉质量显著下降。由于这两种伪影在真实成像过程中高度耦合，针对单一退化设计的现有方法难以泛化到此类复合场景。本文首次系统研究了屏幕截图中莫尔´纹与闪烁条带的联合去除，并提出一种名为 CLEAR 的统一恢复框架。为支持这项任务，我们构建了一个包含莫尔´纹和闪烁条带的大规模数据集，并引入基于图像信号处理器（ISP）的闪烁模拟流程，以稳定模型训练并扩展退化分布。此外，我们设计了频域分解与重组模块，并结合轨迹对齐损失，以增强对复合伪影的建模能力。大量实验表明，所提方法在多项评估指标上始终优于现有图像复原方法，验证了其在复杂真实场景中的有效性。我们的代码和数据集将发布于 https://github.com/libozhu03/CLEAR。

1. 引言

随着移动影像技术的快速发展，智能手机已成为日常摄影和视频录制的主要工具（Zhouetal., 2021）。尽管 Sensors 和图像处理管线不断改进，移动相机在某些实际场景下仍会出现不可忽视的退化（例如，摩尔´é），严重降低视觉质量和实用性。

其中一种场景是在拍摄显示屏时出现的，包括电脑显示器、平板电脑和移动设备。在这些情况下，拍摄的图像通常会在屏幕区域呈现结构化的深色带状伪影，显著降低视觉均匀性并遮挡屏幕内容。鉴于屏幕拍摄在日常应用中的普遍性，理解并解决这一退化问题仍是一项重要但尚未得到充分研究的课题。

这一现象通常称为**闪烁条带**，其成因是卷帘快门成像与基于脉宽调制（PWM）的屏幕亮度控制之间的相互作用。卷帘快门传感器依次曝光图像，导致传感器各行之间存在时间偏移；而 PWM 则通过随时间快速切换像素强度来控制屏幕亮度。当卷帘快门相机拍摄由 PWM 控制的显示屏时，不同传感器行会在不同时间相位对屏幕进行采样，进而导致空间分布的亮度不一致，表现为条带伪影。

在屏幕截图中，闪烁条带往往还伴随着另一种广为人知的退化现象：莫尔´é 图案。莫尔´é 伪影源于显示器像素网格与相机传感器采样晶格之间的空间频率混叠，通常表现为重复纹理或颜色失真。尽管莫尔´é 去除已得到广泛研究（Liu 等人，2020a；Yue 等人，2021a；Yu 等人，2022；Mei 等人，2025；Dong 等人，2025），闪烁条带研究相对不足，主要是由于其时间特性以及形成机制的复杂性。近期研究（Zhu 等人，2025）探索了基于学习的方法，但仅用于去除条带。

更重要的是，在真实场景中，闪烁条带与摩尔纹模式经常共存并相互作用。然而，实验表明，当两种退化同时存在时，直接串联闪烁条带和摩尔纹去除模型会失效。这是因为这两种伪影在空间域和频域中高度耦合。闪烁条带会改变全局亮度分布，进而影响摩尔纹统计特征；而摩尔纹的高频结构则会干扰条带检测与抑制。这些观察结果表明，需要一种能够联合去除闪烁条带和摩尔纹伪影的统一框架。

[1]中国上海上海交通大学 [2]中国华为中央媒体技术研究院。联系人：Yulun Zhang <yulun100@gmail.com>。

预印本。*2026*年*2*月*3*日。



图*1*。 我们数据集（**MIRAGE**）和模型（**CLEAR**）结果概览。左：我们数据集中三种退化类型的示例：闪烁条带、摩尔纹以及闪烁条带与摩尔纹。右：我们提出的模型在真实世界图像上的闪烁条带与摩尔纹去除结果，并与低质量（LQ）图像和真值（GT）图像进行对比。

我们在研究中遇到了以下挑战。***I***，缺乏相关数据集。现有数据集通常只关注单一类型的退化，缺少同时包含闪烁条带和摩尔纹伪影的样本，因此不适用于联合复原。***II***，严重的结构和感知退化。同时受到两种退化影响的图像通常视觉质量极差，呈现出多种条带模式、严重的结构退化和严重的颜色失真。图像复原极具挑战性，现有模型的表现也不尽如人意。***III***，真实世界数据上的训练不稳定。由于退化情况多样，直接使用真实采集的数据训练深度模型极不稳定，经常导致无法收敛或训练崩溃。

为应对这些挑战，我们构建了一个大规模数据集：**M**摩尔纹与闪**I**烁**R** 条带屏幕图**像** 拍摄（**MIRAGE**），通过在多样化的设备、显示屏和拍摄条件下拍摄屏幕显示图像，收集其中的摩尔纹模式和闪烁条带。此外，我们提出了一种名为**C**联合**L**闪**E**烁**A**条带与摩尔纹**R**去除的屏幕拍摄图像复原模型（**CLEAR**）。

为了优化训练数据的分布并扩展闪烁条带与莫尔纹样的多样性，我们引入了基于ISP的闪烁条带仿真流程。ISP是指相机中的图像信号处理器，我们使用预训练的可逆ISP（Xing 等人，2021）来近似RAW与sRGB域之间的变换。该流程在RAW域中模拟不同形式的条带，同时保留真实的莫尔纹特征，从而有助于实现稳定有效的训练。

在模型设计方面，我们引入了一个频域分解模块，将退化输入分解为三个频率分量。由于闪烁条带和莫尔纹伪影主要表现于中频范围，我们有选择地抑制这一频带，同时保留其余分量。由此得到的表征作为下游模型的输入，即使未能完全去除伪影，也能显著提升性能。此外，我们提出轨迹对齐损失，通过对齐退化输入与干净输入之间的特征演化来规范去噪过程，从而稳定复原轨迹。这些设计共同实现了更加稳定有效的联合伪影去除。

总体而言，我们的贡献总结如下：

- 我们构建了一个同时包含摩尔纹和闪烁条带的大规模数据集，从而能够对联合伪影去除进行有效的训练与评估。
- 我们提出了一种基于图像信号处理器的闪烁条带仿真流程，该流程能够稳定并扩展退化分布，从而大幅提升模型性能。
- 我们提出了一种频域分割模块，并结合轨迹对齐损失，显著提升了在复杂摩尔纹和闪烁条带退化条件下的修复性能。
- 我们的实验结果表明，模型在处理闪烁条带与莫尔伪影场景方面具有明显优势，并在实际应用中展现出较高的实用价值。

表1. 与现有屏幕截图数据集的比较。分辨率表示图像的平均分辨率。伪影表示屏幕截图中的退化类型。场景表示所涵盖的视觉内容类别的多样性（DCID/TMM22/UHDM：自然场景、网页、文档；LCDMoir´e：仅文本；RIFLE：广告；MIRAGE：自然场景、文档、卡通、电子游戏、移动用户界面、网页）。我们的 MIRAGE 是首个同时具备**两种伪影类型、更广泛的场景多样性**并涵盖**三种显示技术**的数据集。

数据集	Size	分辨率	场景	伪影		设备		Real -世界
				条带	莫尔´é	相机	显示屏	
DCID (Mei 等人, 2025)	8,959	2133 × 1200	3	×	✓	3	LCD	✓
TMM22 (Xu 等人, 2024)	948	384 × 384	3	×	✓	4	/	✓
UHDM (Yu 等人,2022)	5,000	4328 × 3248	3	×	✓	3	LCD	✓
LCDMoir´e(Zheng 等人,2020)	10,200	1024 × 1024	1	×	✓	/	LCD	×
RIFLE（Zhu 等人，2025）	60	4096 × 3072	1	✓	×	1	LED	✓
MIRAGE	3,000	3706 × 3368	6	✓	✓	**5**	**LCD,LED,OLED**	✓

2. 相关工作

图像去莫尔´纹。早期的图像去莫尔´纹工作采用多分支架构来解决这一问题（Sun 等，2018）。后续方法探索了不同的信号域：基于 sRGB 的方法（Xu 等，2020；Liu 等，2020b；Luo 等，2020；Yue 等，2021b）、RAW 域处理（Yang 等，2025）以及混合 sRGB+RAW 流程（Yue 等，2023a；Xu 等，2024）。从方法角度来看，多分辨率网络（Zheng 等，2022；Peng 等，2024）、结合频率与空间表征的跨域学习（Luo 等，2020；Xu 等，2024）以及显式频域变换（Zheng 等，2022；Xu 等，2020；Liu 等，2025）已得到广泛应用。为增强细节恢复，研究人员还提出了利用广角和超广角镜头（Mei 等，2025）或聚焦与散焦图像对（Dong 等，2025）的多视图融合策略。此外，无监督方法（Yue 等，2021a；Zhong 等，2024）和无需训练的方法（Liu 等，2020a）也已被开发出来，以减少对大规模成对数据集的依赖。

图像去条带。闪烁条带表现为从显示屏拍摄的图像中出现周期性亮度条纹。这种伪影源于相机采集与显示亮度调制之间的时间失配（Zhu 等人，2025）。现代智能手机摄像头通常采用配备电子滚动快门的 CMOS 传感器（Durini，2019），它们按顺序而非同时曝光各传感器行，从而在图像中引入时间偏移。与此同时，显示屏通过随时间变化的机制调节亮度：OLED 面板采用脉冲宽度调制（PWM）（Geffroy 等人，2006），LED 显示屏则采用扫描刷新策略。这些时间动态之间的相互作用会产生具有空间结构的条带伪影。RIFLE（Zhu 等人，2025）是目前唯一专门针对闪烁条带去除的基于学习的方法。然而，当条带与其他伪影同时出现时，其性能会下降，因此亟需统一复原方法。

3. 数据集：MIRAGE

为系统研究闪烁条带与莫尔纹的联合去除问题，我们构建了一个包含多种退化模式的大规模数据集。数据采集与拍摄流程如下所述。

3.1. 数据收集

为确保涵盖广泛的视觉内容，我们汇集了多个现有数据集中的源图像，因为单个数据集通常缺乏足够多样的场景。具体而言，我们从 DocBank（Li 等人，2020）和 PubLayNet（Zhong 等人，2019）中收集文档图像，从 LSDIR（Li 等人，2023）中收集自然图像，从 Danbooru2021 中收集卡通图像，从 VideoGame-Bunny（Taesiri 和 Bezemer，2024）中收集电子游戏图像，并从 Rico（Deka 等人，2017）中收集移动用户界面截图。此外，我们还从 DSCVC（Wang 等人，2025）和 screen-content-dataset（Safonov 等人，2025）中提取网页截图。我们的数据集总共涵盖六种不同的场景。

为获取高质量的源图像，我们采用图像质量评估（IQA）筛选，剔除低质量图像。过暗或噪声过多的图像会被排除，因为这类图像不太可能呈现明显的条带伪影。此外，为保护隐私并遵守伦理标准，我们会排除包含敏感信息的图像。我们还会调整不同来源图像的比例，使其大致反映真实拍摄场景中的分布。

3.2. 数据采集

为准确反映真实世界中的情况，我们使用智能手机相机拍摄显示屏，以获取退化图像。为考虑不同制造商之间传感器特性的差异，我们采用了五种不同的智能手机：vivo X200s、小米17 Pro、华为Mate 50、华为Mate 60 和 iPhone 17 Pro。为覆盖多样的显示技术，我们使用液晶显示器、LED 和 OLED 屏幕。我们系统地采集仅含闪烁条带、仅含摩尔纹，以及同时含有这两种伪影的图像（不包括液晶显示器，因为其不会产生条带伪影）。

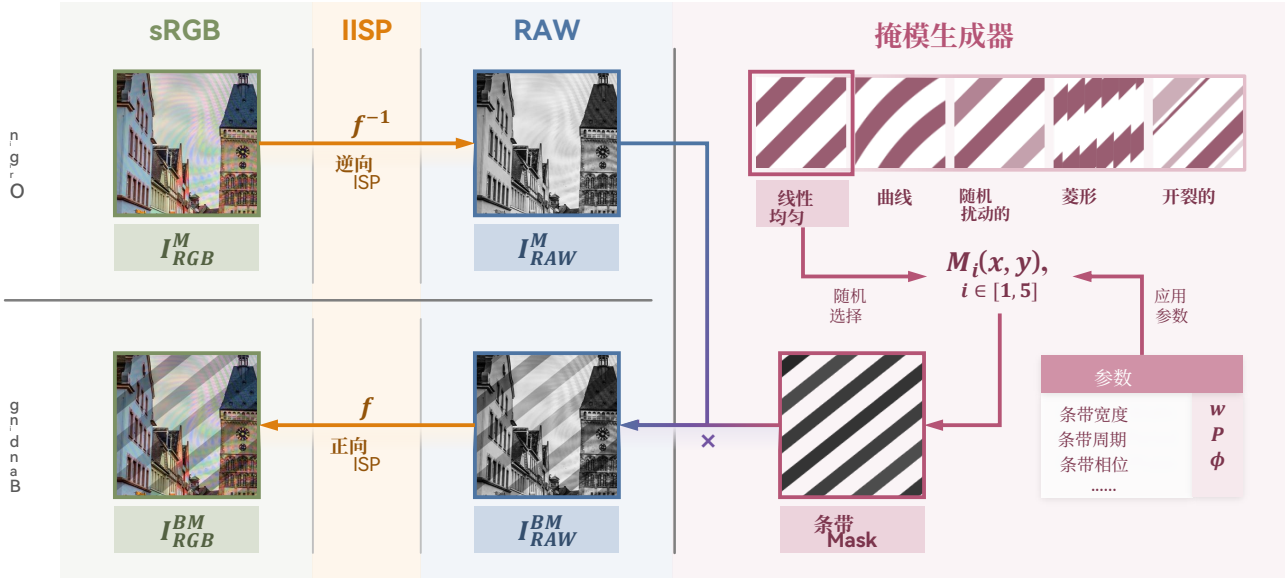


图 2. 仿真流程概览。给定一张带有摩尔纹的 sRGB 图像，使用逆ISP模型将其转换为 RAW 格式。然后生成闪烁条带掩码，并将其应用于 RAW 域，以模拟条带伪影。最后，ISP模型将退化后的 RAW 图像转换回 RGB 空间，生成同时包含摩尔纹和条带伪影的训练对。

对于每张源图像，我们将其以全屏模式显示在目标显示器上，并在不同曝光设置、屏幕亮度级别和观看角度下，使用智能手机相机进行拍摄。干净的真值（GT）图像则通过像素级配准技术，将原始源图像与拍摄得到的照片进行对齐后获得。

最终得到的数据集共包含约 3,000 对图像，每种退化类型各包含 1,000 对（仅闪烁条带、仅摩尔纹以及组合伪影）。我们将每个子集随机划分为 930 对训练对、20 对验证集和 50 对测试对。与现有数据集的比较见表 1。我们数据集的主要特征总结如下：

- **多样化的场景内容。** 该数据集涵盖六类场景：自然图像、网站、文档、卡通、电子游戏和移动用户界面。
- **全面的伪影覆盖范围。** 该数据集包含带有条带、莫尔纹以及两者组合伪影的图像，这些图像是在不同观看角度和距离下拍摄的，以确保伪影形态的多样性。
- **真实世界的拍摄条件。** 所有图像均使用不同类型的消费级智能手机摄像头，在商用液晶显示器、LED 和 OLED 显示屏上拍摄，反映实际使用场景。

4. 方法

基于我们的骨干网络 PiSA-SR（Sun 等人，2025），我们引入以下组件，以提升模型去除闪烁条带和莫尔纹的性能。

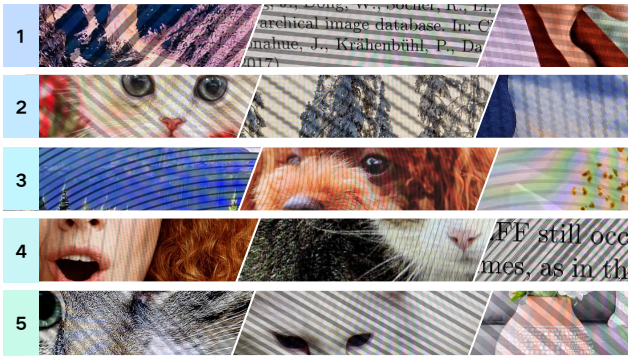


图 3。 模拟条带类型示例。1：简单型；2：菱形；3：曲线；4：开裂的；5：复杂型。更多示例见补充材料。

4.1. 基于ISP的模拟流程（ISPS）

虽然真实世界数据包含多种复合退化，但我们观察到，某些条带模式出现频率较低，妨碍了模型的稳健训练。此外，直接使用伪影高度纠缠的真实数据进行训练，往往会导致收敛不稳定。因此，我们提出一种基于物理原理的 RAW 域模拟流程，在莫尔纹图像上合成闪烁条带，从而能够有控制地增强代表性不足的退化类型，同时保留真实的伪影特征。

RAW 域模拟。 我们方法的一个关键洞见是，闪烁条带源于传感器曝光期间的时间亮度调制。与非线性 sRGB 空间相比，线性 RAW 域能更准确地对其进行建模。

因此，我们采用逆ISP模型 f^{-1} (Xing 等人，2021)，将 UHDM 数据集中的受摩尔纹干扰的 sRGB 图像 I^M_{sRGB}(Yu 等人，2022)转换为伪 RAW 表示：

$$I^M_{RAW} = f^{-1}(I^M_{sRGB}). \tag{1}$$

这使得能够生成符合相机成像流程的物理合理条带。

全面覆盖条带模式。 真实世界中的闪烁条带会因相机、显示屏与拍摄条件之间的相互作用而呈现出多样的形态。为确保充分覆盖，我们设计了一种参数化掩模生成器 $M(x,\ y)$ 可生成五种具有代表性的条带类型，从规则的平行条纹到弯曲、网格状、碎片化以及随机扰动结构（见图 3），并可通过条纹宽度、周期、相位和羽化半径等参数进一步控制。该过程有效覆盖了日常屏幕摄影中遇到的绝大多数条带模式。各类模式的详细数学公式见补充材料。

基于增益的退化模型。 生成的掩模会转换为空间变化的增益系数，用于模拟曝光期间的光强衰减。我们引入基准暗度参数 D 和逐条纹亮度抖动 η_k，以模拟真实条带的随机特性：

$$G(x,y) = \max\left(G_{min},\ 1 - M(x,y)\cdot(1-D)\cdot\eta_k\right), \tag{2}$$

其中 G_{min} 可防止像素完全消失。带条纹的 RAW 图像通过以下方式获得：

$$I^{BM}_{RAW}(x,y) = I^M_{RAW}(x,y)\cdot G(x,y). \tag{3}$$

最终的合成图像由正向图像信号处理器生成：$I^{BM}_{sRGB} = f(I^{BM}_{RAW})$。此模拟扩展了有效的训练分布，使模型能够泛化到罕见但在实践中十分重要的条带模式。

4.2. 频域分割（FS）

摩尔纹´和闪烁条带具有不同的频谱特征：摩尔纹伪影´与周期性或准周期性的中高频干扰有关，而闪烁条带则表现为具有方向结构的低中频亮度调制。当这两种退化同时存在时，直接在空间域对其建模会迫使网络同时抑制高频纹理损坏并恢复全局亮度一致性，这往往会导致优化冲突和训练不稳定。基于这一观察，我们引入了频域分解模块，以便显式操控不同的频谱分量。该模块作为即插即用组件，使网络能够以更有针对性的方式处理各个频带。

给定输入 $\mathbf{x} \in \mathbb{R}^{B\times C\times H\times W}$，我们计算傅里叶变换 $\mathbf{X} = \mathcal{F}(\mathbf{x})$，并在经过宽高比校正的归一化频率平面上定义径向距离 $d(u,v)$。为将频谱划分为多个频带，我们采用n阶巴特沃斯低通掩码：

$$B_{\mathrm{lp}}(d;\rho,n) = \frac{1}{1+\left(d/(\rho+\varepsilon)\right)^{2n}}, \tag{4}$$

它提供平滑且可微的过渡，有效避免了硬截止造成的振铃伪影。

我们将掩码矩阵记为 $\mathbf{B}_b \in \mathbb{R}^{H\times W}$，对应于 $b \in${低、中、高}频带。使用两个截止比率 $\rho_1 < \rho_2$，我们构造三个互补的频带掩码：

$$\begin{cases} \mathbf{B}_{\text{low}}(u,v) &= B_{\mathrm{lp}}(d(u,v);\rho_1,n), \\ \mathbf{B}_{\text{mid}}(u,v) &= B_{\mathrm{lp}}(d(u,v);\rho_2,n) - B_{\text{low}}(u,v), \\ \mathbf{B}_{\text{high}}(u,v) &= 1 - B_{\mathrm{lp}}(d(u,v);\rho_2,n), \end{cases} \tag{5}$$

其中 (u,v) 对频率平面进行索引。这些掩膜逐点满足 $B_{\text{low}} + B_{\text{mid}} + B_{\text{high}} \approx 1$。为确保不同图像尺寸下分区保持一致，我们采用分辨率自适应缩放：$\tilde{\rho}_i = \rho_i \cdot (m_0/m)^{1/2}$，其中$m = \min(H,W)$，$m_0$为参考尺寸。

利用傅里叶线性，我们直接在频域中进行加权重组，并将其变换回像素域。重建图像表示为：

$$\mathbf{I}_{\text{sum}} = \Re\left\{\mathcal{F}^{-1}\left(\mathbf{F}_{\text{sum}}\right)\right\}, \tag{6}$$

其中复合频谱为

$$\mathbf{F}_{\text{sum}} = \sum_b w_b \cdot (\mathbf{X}\odot\mathbf{B}_b), \tag{7}$$

权重 $\{w_{\text{low}}, w_{\text{mid}}, w_{\text{high}}\}$ 使模型能够平衡各频带的贡献。

该模块作为频率感知前端，将退化输入重塑为更结构化、更易学习的表示。通过在频域中进行加权重组并随后进行逆变换，它选择性地抑制受退化影响最严重的频率范围（例如，moir´e与闪烁条带），同时保留稳定的结构与细节信息。此外，分辨率自适应截止缩放可在不同图像尺寸上保持一致的频率划分，从而提升在不同分辨率下的鲁棒性。

尽管该模块本身无法完全消除伪影，但它能部分抑制闪烁条带和莫尔纹伪影，并为后续网络提供条件更优的输入，从而使优化更加稳定，并提升复原性能。

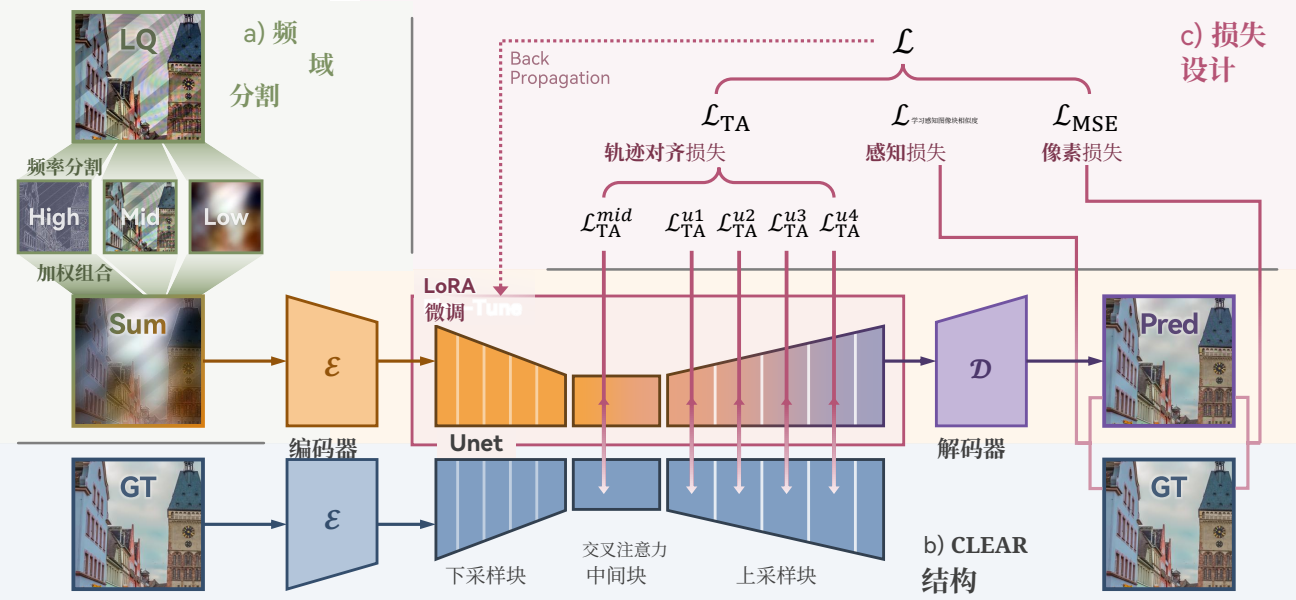


图 4. 所提出的 CLEAR 框架概览。**(a)** 频域分割（FS）模块。**(b)** CLEAR 整体架构。**(c)** 训练目标结合了轨迹对齐损失（TA）、感知损失和像素损失。

4.3. 轨迹对齐损失（TA）

当莫尔纹与闪烁条带共存时，复原过程不仅必须恢复空间细节，还必须在网络层级和扩散步骤中遵循一致的校正轨迹。闪烁条带会扰动亮度相关分量，并引发结构化的强度调制，这可能导致网络在去噪过程中偏向不稳定的中间表征。高频莫尔纹干扰会放大这种偏移，使得仅使用像素级损失进行训练时，优化景观的条件变差。为此，我们引入轨迹对齐损失，约束低质量（LQ）输入的特征演化，使其与相同扩散时间步下真值（GT）目标的特征演化相匹配，从而稳定去噪轨迹。

令 $\mathcal{U}_\theta$ 表示扩散 U-Net。给定时间步 t 的配对输入（$\mathbf{x}^{\mathrm{lq}}$，$\mathbf{x}^{\mathrm{gt}}$），我们从目标层 $\ell \in \mathcal{S}$ 提取特征 $\mathbf{F}^{\ell}_{\mathrm{lq}}(t)$，$\mathbf{F}^{\ell}_{\mathrm{gt}}(t) \in \mathbb{R}^{N\times C\times H\times W}$。为了对齐特征轨迹而非原始幅值，我们采用逐通道余弦相似度，以消除尺度歧义并关注方向一致性。

对于每个样本 n 和通道 c，我们将空间维度向量化并进行 ℓ_2 归一化：

$$\hat{\mathbf{v}}^{\ell}(n,c,t) = \frac{\mathrm{vec}(\mathbf{F}^{\ell}(t))_{n,c,:}}{\|\mathrm{vec}(\mathbf{F}^{\ell}(t))_{n,c,:}\|_2 + \varepsilon}, \tag{8}$$

其中 ε 确保数值稳定性。随后，将逐层轨迹对齐损失定义为低质量表征与真实表征之间余弦距离的均值：

$$\mathcal{L}^{\ell}_{\mathrm{TA}}(t) = \frac{1}{NC}\sum_{n,c}\left(1 - \langle \hat{\mathbf{v}}^{\ell}_{\mathrm{lq}}(n,c,t), \hat{\mathbf{v}}^{\ell}_{\mathrm{gt}}(n,c,t)\rangle\right), \tag{9}$$

其中 $\langle \mathbf{v}_1, \mathbf{v}_2 \rangle$ 表示 $\mathbf{v}_1$ 与 $\mathbf{v}_2$ 之间的余弦相似度。

轨迹对齐损失以权重 $\{\lambda_\ell\}_{\ell\in\mathcal{S}}$ 和全局因子 γ 在选定层上进行聚合：

$$\mathcal{L}_{\mathrm{TA}}(t) = \gamma \sum_{\ell\in\mathcal{S}} \lambda_\ell \, \mathcal{L}^{\ell}_{\mathrm{TA}}(t). \tag{10}$$

通过在表示空间中强制逐通道方向一致，轨迹对齐损失侧重于特征轨迹的结构一致性，而非绝对激活幅值；这对于在保留摩尔纹抑制所需高频细节的同时稳定亮度校正尤为有效。

4.4. 整体训练目标。

完整的训练目标将轨迹对齐损失与标准重建损失相结合：

$$\mathcal{L}_{\mathrm{total}} = \lambda_{\mathrm{TA}}\mathcal{L}_{\mathrm{TA}} + \lambda_{\mathrm{LPIPS}}\mathcal{L}_{\mathrm{LPIPS}} + \lambda_{\mathrm{MSE}}\mathcal{L}_{\mathrm{MSE}}, \tag{11}$$

其中 $\mathcal{L}_{\mathrm{MSE}}$ 是用于像素级重建的均方误差（均方误差）损失，$\mathcal{L}_{\mathrm{LPIPS}}$ 是学习感知图像块相似度（Zhang等人，2018）感知损失，它使用预训练图像评估网络衡量特征级相似度。

我们采用基于 LoRA（Hu 等人，2022）的参数高效微调策略，将低秩适配矩阵插入扩散 U-Net。在训练过程中，仅优化 U-Net 模块中的 LoRA 参数，而编码器和解码器保持冻结。此设计在保留预训练表征能力的同时，使模型能够高效适配联合伪影去除任务。这些互补的目标共同实现了对闪烁条带和莫尔纹伪影的有效联合去除。

表 2. 不同方法在 **裁剪后的** MIRAGE 测试数据集上的定量结果。各对比方法均使用 MIRAGE 训练数据集重新训练。最佳和次佳结果分别以**红色**和 **蓝色**标出。CLEAR 相较于其他方法具有显著优势。

方法	Task	结构相似性指数 ↑	多尺度结构相似性 ↑	学习感知图像块相似度 ↓	深度图像结构与纹理相似度 ↓	特征相似性 ↑	梯度幅值相似性偏差 ↓
LQ	-	0.5244	0.6495	0.5210	0.3003	0.7437	0.2064
NeRD-Rain (Chen 等人，2024)	去雨	0.6685	0.7254	0.5446	0.3130	0.7801	0.1723
ESDNet (Yu 等人，2022)	去摩尔纹	**0.7354**	**0.7704**	0.4983	0.3107	**0.8030**	0.1707
MAT（Xie 等人，2025）	超分辨率	0.6732	0.7203	0.5346	0.3095	0.7835	0.1648
ResShift（Yue 等人，2023b）	超分辨率	0.7099	0.7404	0.4548	**0.2709**	0.7912	0.1812
PiSA-SR（Sun 等人，2025）	超分辨率	0.6598	0.7236	**0.4191**	0.2738	0.7646	0.2045
InvSR(Yue 等人, 2025)	超分辨率	0.7037	0.6988	0.4391	0.3164	0.7576	0.2011
RIFLE(Zhu 等人, 2025)	去色带	0.6391	0.7470	0.4557	0.2790	0.7983	**0.1631**
CLEAR	去色带与去摩尔纹	**0.7163**	**0.8159**	**0.3183**	**0.2354**	**0.8249**	**0.1598**

表3. 与组合模型的比较。

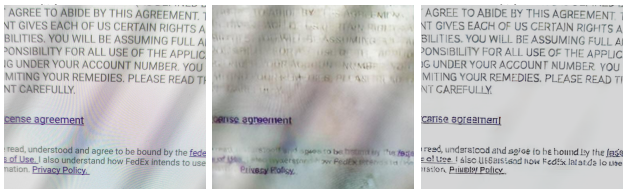
指标	LQ	RIFLE 与 ESDNet	CLEAR
多尺度结构相似性↑	0.6495	0.7395	**0.8159**
学习感知图像块相似度↓	0.5210	0.4438	**0.3183**
深度图像结构与纹理相	0.3003	0.2831	**0.2354**

表4. 仿真流程消融实验。

指标	MIRAGE	ISPS	MIRAGE+ISPS
多尺度结构相似性↑	0.7236	0.7974	**0.8023**
学习感知图像块相似度↓	0.4191	0.3920	**0.3897**
深度图像结构与纹理相	0.2738	0.2611	**0.2592**

表 5. 模型设计消融。

指标	基线	FS	TA +FS
多尺度结构相似性↑	0.8023	0.8093	**0.8159**
学习感知图像块相似度↓	0.3897	0.3610	**0.3183**
深度图像结构与纹理相似度↓	0.2592	0.2489	**0.2354**



LQ　　RIFLE 与 ESDNet　　CLEAR

图 5. 与组合方法的视觉比较。

5. 实验

5.1. 实验设置

数据构建。我们主要用于训练和测试的数据集是我们提出的 MIRAGE 数据集，其中包含闪烁条带与莫尔纹´共存的场景。对于所提出的仿真流程，我们使用 UHDM（Yu 等人，2022）来引入真实世界中的莫尔纹´伪影。值得注意的是，我们将 MIRAGE 测试数据集裁剪为 512×512以突出评估指标之间的差异。

评估指标。主要采用基于参考图像的评估指标进行评估，包括结构相似性指数（Wang 等人，2004a）、多尺度结构相似性（Wang 等人，2004b）、学习感知图像块相似度（Zhang等人，2018）、深度图像结构与纹理相似度（Ding 等人，2020）、特征相似性（Zhang等人，2011）和梯度幅值相似性偏差（Xue 等人，2014）。正如 RIFLE（Zhu 等人，2025）中所述，无参考评价指标不适用于闪烁条带的评估。

实现细节。我们将秩设为 32，并使用 5×10^{-5} 的学习率对 LoRA 进行微调。训练过程使用分辨率为 512×512 的图像。

对比方法。由于同时去除闪烁条带和摩尔纹的研究较少，我们选择了其他图像重建任务中的对比方法（例如去雨、去摩尔纹、去色带和超分辨率）。我们使用所提出的数据集重新训练选定的对比方法，以确保公平比较。所选模型还涵盖了不同的模型结构，包括变换器、多步扩散和单步扩散模型，这些模型常用于图像复原任务。

5.2. 与组合模型的比较

为了证明我们模型的必要性和价值，我们构建了一个组合基线进行比较。具体而言，我们串联了当前最先进的去条纹模型 RIFLE（Zhu 等人，2025）和去摩尔´纹模型 ESDNet（Yu 等人，2022），并在我们的测试数据集上评估该组合模型。定量结果以及与我们方法的视觉对比见表3和图5。实验结果表明，组合模型的性能远不能令人满意，说明简单地将强大的去闪烁模型与强大的去摩尔´纹模型结合起来，不足以处理两种退化同时存在的场景。这表明，我们在去除闪烁条带和摩尔´纹方面的工作具有明确的实际意义。

5.3. 主要结果

定量结果。我们在表2中给出了不同方法在裁剪后的 MIRAGE 测试数据集上的定量结果。显然，在去除闪烁条带和莫尔纹方面，**CLEAR** 在大多数评估指标上始终优于现有方法。´尽管 ESDNet 在结构相似性指数（SSIM）方面略占优势，CLEAR 在更广泛的指标上表现更好，展现出更优越的模型性能。此外，我们还发现，即使模型在去除闪烁条带伪影方面取得了显著提升，定量评估指标的相应增益仍然有限。现有评估指标主要衡量复原图像与干净的真实图像之间的整体差异，但对闪烁条带伪影并不敏感。

视觉比较。视觉性能比较结果见图6。CLEAR 在视觉质量方面具有明显优势。它能够有效去除严重的闪烁条带，同时抑制 moir´e 图案，即使在包含密集条纹和高频内容的困难区域也是如此。对比方法的恢复结果存在各种问题：严重模糊、显著噪声和结构退化，或明显残留的闪烁条带和 moir´e 伪影。

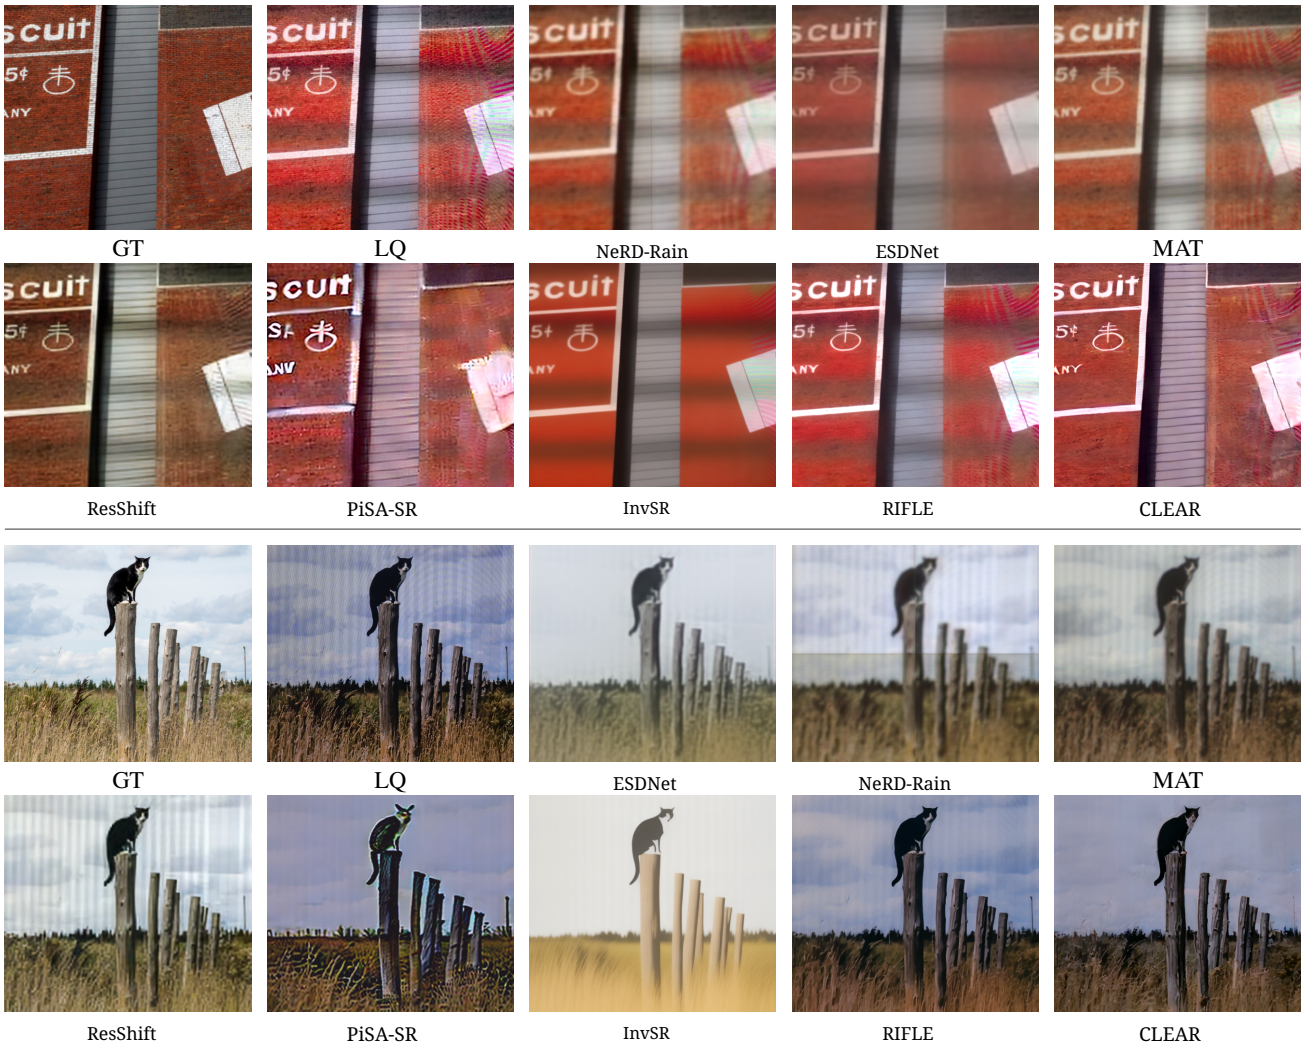


图 *6.* 视觉比较 闪烁条带与莫尔纹图像（低质量）、干净图像（真值）以及其他对比方法的结果（˙） E
测试数据集。对比方法 方法均使用 MIRAGE 的训练数据集重新训练。CLEAR 相较于其他方法具有显著优势 .

5.4. 消融研究

仿真流程。对于基线模型，使用真实世界 MIRAGE 数据集进行训练的性能有限，而引入基于 ISP 的仿真（ISPS）可显著提升所有指标，如表4所示。将 MIRAGE 与 ISPS 相结合可进一步带来持续增益，并在所有指标上取得最佳结果。这表明，更真实且更多样的退化建模对于提升鲁棒性和感知保真度至关重要。

模型设计。表 5 中的结果表明，添加 FS 模块能够带来明显的性能提升，证明了频率感知建模的有效性。进一步引入 TA 损失可在所有指标上持续提升性能，从而取得最佳结果。这些实验证实，每个组件均有积极贡献，而它们的组合对于在联合闪烁条带与摩尔˙纹复原中实现最优性能至关重要。

6. 结论

在本研究中，我们系统地探讨了闪烁条带与摩尔纹伪影共存条件下的图像复原问题。这些问题经常出现在真实世界屏幕拍摄图像中，但很少被联合处理。因此，我们构建了一个真实世界闪烁条带与摩尔纹联合数据集。通过在所提出数据集上进行大量实验，我们发现，现有方法不足以应对这一复合场景，而简单串联强大的去色带和去摩尔纹模型会导致次优结果。为克服这些局限，我们提出了 CLEAR，这是一种统一的端到端框架，可联合执行去色带和去摩尔纹。CLEAR 始终能够取得更优的定量性能，并以更少的残余伪影和更好的结构保真度带来视觉上更清晰的结果。总体而言，CLEAR 为真实世界闪烁条带与摩尔纹复原提供了一种实用且有效的解决方案。

影响声明

本文介绍的研究旨在推动机器学习领域的发展。我们的工作可能带来许多潜在的社会影响，但我们认为其中没有任何影响需要在此特别强调。

参考文献

Chen, X., Pan, J., and Dong, J. 用于图像去雨的双向多尺度隐式神经表示。发表于*CVPR*，2024。

Deka, B., Huang, Z., Franzen, C., Hibschman, J., Afergan, D., Li, Y., Nichols, J., and Kumar, R. Rico：用于构建数据驱动设计应用的移动应用数据集。发表于*UIST*，2017。Ding, K., Ma, K., Wang, S., and Simoncelli, E. P. 图像质量评估：统一结构与纹理相似性。*TPAMI*，2020。Dong, X., Sun, X., Wang, X., Song, J., Li, Y., and Li, W. 使用聚焦-散焦双摄像头系统进行视频去摩尔纹。发表于*TPAMI*，2025。Durini, D. 高性能硅成像：*CMOS*和*CCD*传感器的基础与应用。Woodhead Publishing，2019。Geffroy, B., Le Roy, P., and Prat, C. 有机发光二极管（oled）技术：材料、设备与显示技术。发表于*PI*，2006。Hu, E. J., Shen, Y., Wallis, P., Allen-Zhu, Z., Li, Y., Wang, S., Wang, L., Chen, W., et al. Lora：大语言模型的低秩适配。*ICLR*，2022。Li, M., Xu, Y., Cui, L., Huang, S., Wei, F., Li, Z., and Zhou, M. Docbank：用于文档版面分析的基准数据集。*arXiv*预印本 *arXiv:2006.01038*，2020。Li, Y., Zhang, K., Liang, J., Cao, J., Liu, C., Gong, R., Zhang, Y., Tang, H., Liu, Y., Demandolx, D., Ranjan, R., Timofte, R., and Van Gool, L. Lsdir：用于图像复原的大规模数据集。发表于*CVPRW*，2023。Liu, L., Yuan, S., Liu, J., Bao, L., Slabaugh, G., and Tian, Q. 从聚焦与散焦图像对中自适应学习去摩尔纹。发表于*NIPS*，2020a。Liu, S., Li, C., Nan, N., Zong, Z., and Song, R. Mmdm：用于图像去摩尔纹的多帧多尺度方法。发表于*CVPRW*，2020b。

Liu, Z., Zheng, B., Chen, Q., Zhang, Q., Jia, X., Zhang, J., 和 Yan, C. 用于超高清图像去摩尔纹的金字塔可学习带通滤波器。发表于*TCSVT*，2025。

Luo, X., Zhang, J., Hong, M., Qu, Y., Xie, Y., 和 Li, C. 用于单幅图像去摩尔纹的域适应深度小波网络。发表于*CVPRW*，2020。

Mei, Y.、Zhang, Z.、Wu, X. 和 Zuo, W. 基于双摄像头融合的手机图像去摩尔纹。载于 *ICME*，2025。

Peng, Y.-T.、Hou, C.-H.、Lee, Y.-C.、Yoon, A. J.、Chen, Z.、Lin, Y.-T. 和 Lien, W.-C. 基于多尺度融合网络与摩尔纹数据增强的图像去摩尔纹。载于 *Sensors*，2024。

Safonov, N., Rakhmanov, M., and Vatolin, D. 屏幕内容视频数据集与基准。发表于*ACMMM*，2025。Sun, L., Wu, R., Ma, Z., Liu, S., Yi, Q., and Zhang, L. 像素级与语义级可调超分辨率：一种双 LoRA 方法。发表于 *CVPR*，2025。Sun, Y., Yu, Y., and Wang, W. 使用多分辨率卷积神经网络进行摩尔纹照片复原。发表于 *TIP*，2018。Taesiri, M. R. and Bezemer, C.-P. VideoGameBunny：面向电子游戏视觉助手的探索。*arXiv*预印本 *arXiv:2407.15295*，2024。Wang, F., Shen, L., Tian, Z., Wang, S., Teng, Q., Zhu, Y., and Zhou, C. DSCVC：深度屏幕内容视频压缩。发表于*TCSVT*，2025。Wang, Z., Bovik, A. C., Sheikh, H. R., and Simoncelli, E. P. 图像质量评估：从误差可见性到结构相似性。发表于 *TIP*，2004a。Wang, Z., Simoncelli, E. P., and Bovik, A. C. 用于图像质量评估的多尺度结构相似性。发表于 信号、系统与计算机，*2004*年第三十七届阿西洛马会议论文集，2004b。Xie, C., Zhang, X., Li, L., Fu, Y., Gong, B., Li, T., and Zhang, K. MAT：面向高效图像超分辨率的多范围注意力变换器。发表于 *TCSVT*，2025。Xing, Y., Qian, Z., and Chen, Q. 可逆图像信号处理。发表于 *CVPR*，2021。Xu, D., Chu, Y., and Sun, Q. 通过注意力分形网络去除摩尔纹图案。发表于 *CVPRW*，2020。Xu, S., Song, B., Chen, X., Liu, X., and Zhou, J. RAW 与 sRGB 域中的图像去摩尔纹。发表于 *ECCV*，2024。Xue, W., Zhang, L., Mou, X., and Bovik, A. C. 梯度幅值相似性偏差：一种高效的感知图像质量指数。发表于 *TIP*，2014。

Yang, Q., Zhang, F., Jin, Y., Cheng, Q., Jiang, P., Yue, H., and Yang, J. Dsdnet：通过双颜色空间协同在 RAW 域去除摩尔纹。发表于 *ACMMM*，2025。Yu, X., Dai, P., Li, W., Ma, L., Shen, J., Li, J., and Qi, X. 面向高效且尺度鲁棒的超高清图像去摩尔纹。发表于*ECCV*，2022。Yue, H., Cheng, Y., Liu, F., and Yang, J. 面向翻拍屏幕图像的无监督摩尔纹图案去除。发表于*Neurocomputing*，2021a。Yue, H., Mao, Y., Liang, L., Xu, H., Hou, C., and Yang, J. 翻拍屏幕图像去摩尔纹。发表于*TCSVT*，2021b。Yue, H., Cheng, Y., Mao, Y., Cao, C., and Yang, J. RAW 域中的翻拍屏幕图像去摩尔纹。发表于 *TMM*，2023a。Yue, Z., Wang, J., and Loy, C. C. ResShift：通过残差移位实现图像超分辨率的高效扩散模型。神经信息处理系统进展，36：13294–13307，2023b。Yue, Z., Kang, L., and Loy, C. C. 通过扩散反演实现任意步数图像超分辨率。发表于 *CVPR*，2025。Zhang, L., Zhang, L., Mou, X., and Zhang, D. FSIM：用于图像质量评估的特征相似性指数。发表于*TIP*，2011。Zhang, R., Isola, P., Efros, A. A., Shechtman, E., and Wang, O. 深层特征作为感知度量的惊人效力。发表于*CVPR*，2018。Zheng, B., Yuan, S., Slabaugh, G., and Leonardis, A. 使用可学习带通滤波器进行图像去摩尔纹。发表于 *CVPR*，2020。Zheng, B., Yuan, S., Yan, C., Tian, X., Zhang, J., Sun, Y., Liu, L., Leonardis, A., and Slabaugh, G. 学习用于图像去摩尔纹的频域先验。发表于 *TPAMI*，2022。Zhong, X., Tang, J., and Yepes, A. J. PubLayNet：迄今最大的文档版面分析数据集。发表于 *ICDAR*，2019。Zhong, Y., Zhou, Y., Zhang, Y., Chao, F., and Ji, R. 从未配对的真实数据中学习图像去摩尔纹。发表于 *AAAI*，2024。Zhou, Y., Ren, D., Emerton, N., Lim, S., and Large, T. 屏下摄像头图像复原。发表于 *CVPR*，2021。Zhu, L., Zhou, Z., Liu, X., Zhang, W., Shi, K., Fu, Y., and Zhang, Y. RIFLE：通过潜在扩散增强去除图像闪烁条带。*arXiv*预印本 *arXiv:2509.24644*，2025。