

基于空频域协同学习的轻量级红外偏振图像质量提升方法

王秉路^{1, 2}, 武剑珍¹, 汪顺舟³

(1. 西安建筑科技大学信息与控制工程学院, 陕西 西安 710399; 2. 西北工业大学航天学院, 陕西 西安 710129; 3. 河南大学人工智能学院, 河南 郑州 450046)

摘要: 复杂背景的目标识别是物联网边缘感知体系中很重要的任务, 而红外偏振图像在安防, 伪装检测领域展现出优越的目标背景对比度。然而, 由于成像系统计算速度慢以及传感器硬件缺陷问题, 长波红外焦平面分割偏振成像系统在实际应用中难以高效获取高质量的图像, 阻碍下游检测等任务的精度。为此, 提出一种基于空频域协同的轻量级红外偏振图像联合去噪与去马赛克方法, 该方法通过构建三阶段学习网络, 在保证低计算复杂度的同时提升偏振图像重建质量。所设计的双域交互去噪模块充分利用频域信息的统计性特征, 有效抑制噪声并保留偏振特性; 同时, 在粗糙去马赛克之后引入轻量化精细重建模块, 通过深度分组卷积压缩模型参数量并提升重建性能。实验结果表明, 所提方法在 IR-DoT 与 IR-DoFP 数据集上在保持低计算开销的前提下取得了优于现有方法的重建效果, 为物联网边缘终端提供了一种低功耗、高质量的感知数据预处理方案。

关键词: 物联网边缘智能; 红外偏振成像; 去噪去马赛克; 频率学习; 轻量化模型设计

doi: 10.11959/j.issn.2096-3750.XXXX.

Lightweight infrared polarization image enhancement method via spatial-frequency collaborative learning

WANG Binglu^{1,2}, WU Jianzhen¹, WANG Shunzhou³

1. College of Information and Control Engineering, Xi'an University of Architecture and Technology, Xi'an 710054, China

2. School of Astronautics, Northwestern Polytechnical University, Xi'an 710072, China

3. School of Artificial Intelligence, Henan University, Zhengzhou 450046, China

Abstract: Object recognition in complex scenes is an important task in the Internet of Things (IoT) based edge perception systems. Infrared polarization images show superior foreground - background contrast in security monitoring and camouflage detection. However, due to the limited hardware resources of imaging systems, it is difficult for long-wave infrared division-of-focal-plane (DoFP) polarization imaging systems to achieve high-quality images in practical applications, which adversely affects edge perception performance. To this end, a lightweight joint denoising and demosaicking network for infrared polarization images is developed via spatial-frequency collaborative learning. The proposed method employs a three-stage learning network to enhance the quality of polarization image reconstruction while maintaining low computational complexity. The dual-domain interactive denoising block leverages the statistical properties of the frequency domain to suppress noise while preserving polarization features. After coarse demosaicking, a lightweight fine reconstruction module is adopted to generate the final results. Depthwise grouped convolutions are used to reduce model parameter count and improve reconstruction quality. Extensive experiments are performed on the IR-DoT and IR-DoFP datasets. The results show that the proposed method achieves superior performance compared with other leading approaches

收稿日期: XXXX-XX-XX; 修回日期: XXXX-XX-XX

通信作者: 汪顺舟, shunzhouwang@henu.edu.cn

基金项目: 国家自然科学基金项目 (No.62401447); 陕西省重点研发计划项目 (No.2024GX-YBXM-051); 陕西省自然科学基金基础研究计划资助项目(No.2025JC-YBQN-877); 河南省科技攻关项目 (No. 262102210162)

Foundation Items: The National Natural Science Foundation of China (No.62401447), Key Research and Development Program of Shaanxi Province (No.2024GX-YBXM-051), Natural Science Basic Research Program of Shaanxi (No.2025JC-YBQN-877), Key R&D and Promotion Projects of Henan Province (No. 262102210162)

while maintaining low computational overhead, making it a low-power, high-quality data preprocessing approach for IoT-based edge devices.

Key words: internet of things edge intelligence, infrared polarization imaging, denoising and demosaicking, frequency learning, lightweight model design

0 引言

随着物联网 (Internet of Things, IoT) 技术的快速发展, 视觉信息的高效获取与智能处理已成为智慧边防、智能监控、目标探测等应用领域必不可少的步骤^[1]。在复杂干扰环境下, 传统红外热图在没有温度差异时的目标背景区分存在明显局限。与传统红外热成像仅利用辐射强度信息不同, 红外偏振成像通过获取目标的偏振态信息, 能够反映物体表面材质和结构特性, 从而在伪装目标检测、复杂背景下的人造目标检测中表现出更强的视觉效果^[2]。在常见的偏振成像传感器中, 焦平面分割 (Division of Focal Plane, DoFP) 传感器由于具备结构紧凑、实时性强、易于系统集成等优势, 更适合部署在资源受限的物联网感知节点用来实时获取红外偏振数据^[3]。

DoFP 传感器在焦平面上集成微偏振器阵列, 每个 2×2 超像素仅能采集一个偏振方向的信息, 四个微偏振器分别对应 0° 、 45° 、 90° 和 135° 偏振方向, 从而实现多偏振信息的同步获取^[4]。由于 DoFP 偏振成像技术的成像模式, 空间分辨率降低为原来的四分之一, 所以需要对其他三个方向的偏振信号进行恢复, 以避免严重的瞬时视场误差^[5]。在物联网智能感知系统中, 对 DoFP 红外偏振图像进行高质量重建是提升系统感知性能首要考虑的问题, 而图像去噪又是红外偏振图像重建过程中的必要环节, 去噪结果直接影响后续线偏振度 (Degree of Polarization, DoLP) 和偏振角 (Angle of Polarization, AoP) 等图像偏振特性参数的计算精度。传统去噪方法通过改进自然图像去噪方法来适配偏振特性^[6]。近年来, 深度学习方法^{[7][8][9]}多采用融合了物理偏振先验的数据驱动的方式实现去噪。尽管基于深度学习的方法取得了优异的性能表现, 但这类方法往往模型参数量大、计算复杂度高, 难以直接部署在算力与能耗受限的端侧物联网设备。当前方法多数研究可见光偏振成像, 对红外偏振场景的直接适用性不足。同时, 现代相机传感器采用彩色滤光

片阵列 (Color Filter Array, CFA) 在单个像素位置捕获色度信息, 通过去马赛克算法重建完整图像^[10]。受此启发, 研究人员通过对微偏振器阵列 (Micro-Polarizer Array, MPA) 采样数据进行去马赛克处理, 以恢复多偏振方向图像。然而, 由于 MPA 与 CFA 在排列结构和成像机理上的差异, 现有去马赛克方法^{[11][12]}难以直接适用于红外偏振成像。为此, 研究人员开始探索联合去噪和去马赛克方法。文献^[13]采用具有渐进卷积神经网络的混合噪声估计来解决真实场景中的复杂噪声和低信噪比问题并重建多偏振图像。但目前智能终端设备受到计算资源、存储容量的限制很难将上述联合算法进行部署与应用^[14]。如何实现去噪与去马赛克方法轻量化是当前研究领域的重要挑战。

本文提出了一种轻量级的双域协同去噪与重建网络提升红外偏振图像的重建质量。整体网络采用三阶段网络框架实现。大多数现有偏振去噪方法仅关注空间域特征, 忽略了频域特征在分离噪声成分方面的优势。受文献^[15]启发, 本文在第一阶段设计了空频域融合块来改进现有的偏振图像去噪方法。在第二阶段, 本文采用嵌套残差密集模块 (Residual-in-Residual Dense Block, RRDB)^[16]模块进行去马赛克。在第三阶段, 本文受文献^[17]的启发设计了一种参数量更少的轻量级精细化模块, 优化前两阶段的重建结果。本文方法在两种常用的红外偏振数据集上进行了大量的实验。实验结果表明, 本文方法在低计算开销下重建性能优于当前领先的去噪去马赛克方法, 为物联网边缘终端提供了一种低功耗、高质量的感知数据预处理方案。

1 相关工作

1.1 图像去噪

图像去噪是提升图像质量的关键步骤, 它去除与图像信号无关的噪声杂质, 使图像在视觉上更清晰。去噪技术的发展从经典的信号处理方法演进到现代的基于神经网络的解决方案。由于偏振图像在像素级别与常规图像存在相似性, 许多为强度图像

开发的去噪方法可为偏振图像去噪提供有价值的参考。因此，本文首先简要概述通用的图像去噪方法。对于常规图像处理，传统技术可分为三类：空间域滤波、变换域方法和稀疏表示。空间域滤波如高斯滤波^[18]、双边滤波^[19]和非局部均值滤波^[20]，通过局部或全局像素相似性抑制噪声，但难以在细节保留和噪声去除之间取得平衡；变换域方法如小波变换^[21]和BM3D^[22]利用频域特性，其中BM3D通过非局部块匹配和三维协同滤波成为经典算法；稀疏表示如K-SVD^[23]通过学习完备字典实现稀疏重建，但计算复杂度高。然而，由于真实采集图像中噪声分布的多样性和复杂性，这些传统方法的灵活性和有效性受到限制^{[24][25]}。2014年以来，深度学习方法取得了令人瞩目的进展：DnCNN^[26]、ResNet^[27]通过残差学习和密集连接提升性能；结合Transformer的网络如PSDNet^[28]、HWformer^[29]建模长程依赖；自监督方法如Noise2Noise^[30]减少了对成对数据的依赖，促进在低光等复杂场景中的应用。

对于偏振图像，其斯托克斯参数、偏振度和偏振角等多种物理特性对噪声高度敏感^[31]，传统方法通过改进经典算法来适配偏振特性。例如，基于主成分分析的去噪算法^[32]保留偏振通道的主成分，但细节损失显著。文献^[6]结合K-SVD和OMP算法^[33]恢复物理信息，但偏振角恢复不足。另一方面，深度学习深度融合物理偏振先验，彩色偏振图像通过3DCNN^[8]结合空间-颜色-偏振维度，或通过Transformer建模全局相关性^[9]，迁移学习复用预训练模型减少数据需求^[34]，自监督方法Pol2Pol通过斯托克斯关系生成训练对^[35]，接近有监督学习效果。对于红外偏振图像，PJDNDMNet^[13]用混合噪声估计解决真实红外偏振场景中的复杂噪声和低信噪比问题。尽管基于深度学习的去噪方法有明显的效果，但计算量和网络参数较大，且虽然在可见光偏振成像中已广泛探索，但针对红外偏振特性的方法较少。

1.2 图像去马赛克

图像去马赛克是从传感器捕获的稀疏像素数据中重建全分辨率图像的过程。分时（Division of time, DoT）传感器已被用于克服DoFP传感器的限制，可以采集每个像素位置的全偏振信息，但会导致成像时间长，无法实现实时成像。由于广泛使用的DoFP传感器的固有缺陷，原始的四个方向偏振

信息仅能按照MPA模式在一个方向上捕获。虽然DoFP允许实时成像，但对于使用MPA的偏振成像系统，去马赛克是重建全分辨率偏振图像的必要步骤。当前方法分为基于物理模型和基于深度学习的技术。基于物理模型的方法^{[36][37]}利用空间光谱域的数学模型和图像先验知识恢复图像。基于深度学习的方法^[38]是目前最先进的方法，利用特征融合学习图像特征。由于CFA和MPA排列模式的根本差异，这些方法不适用于偏振图像。偏振图像去马赛克方法也有一定发展^{[39][40][41]}，但都以牺牲参数量为代价，并且在处理红外偏振数据存在局限性。

1.3 联合去噪与去马赛克

在实际的图像恢复任务中，多任务协同执行是高效提升感知数据质量的更常见的方式^[42]，传统先去马赛克后去噪的分步处理容易导致误差累积，所以去噪与去马赛克联合算法逐渐成为研究热点，这也符合边缘智能对高精度数据获取的需求，有利于与下游检测任务的效果。普通彩色图像领域，深度学习联合优化已见成效^[43]。然而，针对红外偏振图像的更高精度的去噪与去马赛克联合算法有待进一步研究。

2 联合去噪去马赛克方法

为实现红外偏振图像的去噪和去马赛克目的，本文提出了一种称为双域协同去噪与重建网络（Dual-domain Collaborative Denoising and Reconstruction network, DCDRnet）的方法。其结构如图1所示。整个过程由三部分组成。首先，为了避免后续重建过程中引入更多的误差，提出空频域融合块（Spatial-Frequency Domain Fusion Block, SFFB）进行噪声去除之后再重建，给定输入的DoFP图像 $x_{NoisyDoFP} \in \mathbf{R}^{B \times C \times H \times W}$ ，得到 $x_{dn} \in \mathbf{R}^{B \times C \times H \times W}$ ，如下：

$$x_{dn} = SFFB(x_{NoisyDoFP}) \quad (1)$$

去噪后的图像首先根据MPA模式进行上采样得到一幅图像，使其与全分辨率偏振图像的尺寸匹配。通过双线性插值生成粗略的全分辨率偏振图像 $x_{Bl} \in \mathbf{R}^{B \times C \times H \times W}$ 。然后采用RRDB^[16]对粗略去马赛克图像相对于真实值的重建误差进行建模，得到 $x_{dm} \in \mathbf{R}^{B \times 4C \times H \times W}$ 。为了更好地重建包括精细纹理和锐利边缘在内的高频成分，第二阶段的输入通过将边缘相关引导图（记为 *edge1*）与通过双线性插值得到的粗略全分辨率偏振图像 x_{Bl} 相结合来构建。

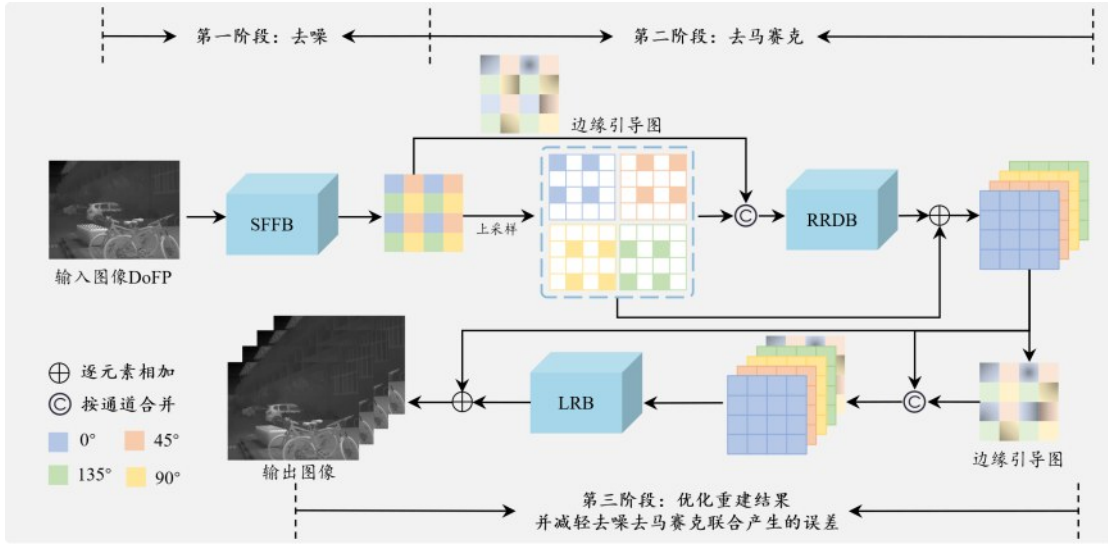


图1 所提出的用于长波红外焦平面分割偏振图像的双域协同去噪与重建网络架构。

在该阶段，边缘引导图通过计算第一阶段输出的边缘检测结果得到：

$$edge1 = Edgeuidace(x_{dm}) \#(2)$$

$$x_{BI} = BICConv(Upsampling_{MPA}(x_{dm})) \#(3)$$

$$x_{dm} = RRDB([edge1, x_{BI}]) \#(4)$$

边缘引导图采用传统 Sobel 算子计算得到。首先对各偏振通道进行求和并归一化，以获得结构强度图；随后分别利用水平和垂直方向的 Sobel 卷积核计算梯度响应，并对梯度幅值进行求和。为突出显著结构信息并抑制弱响应，进一步对梯度幅值进行阈值化处理，从而生成二值边缘引导图。

最后，为进一步去噪并精细化全分辨率偏振图

像的质量，同时最小化分步去噪和去马赛克引入的误差，提出了轻量级精细化块（Lightweight Refinement Block, LRB）。与第二阶段类似，第三阶段的输入也包括边缘引导图 $edge2 \in \mathbf{R}^{B \times C \times H \times W}$ ，该阶段的边缘引导图通过第二阶段的输出 x_{dm} 和 x_{BI} 计算得到。第三阶段的输入通过将 $edge2$ 、 x_{BI} 和 x_{dm} 拼接得到。经过 LRB 后，得到最终的全分辨率偏振图像 $x_{dndm} \in \mathbf{R}^{B \times 4C \times H \times W}$ ：

$$edge2 = EdgeGuidance(x_{BI} + x_{dm}) \#(5)$$

$$x_{dndm} = LRB([edge2, (x_{BI} + x_{dm})]) \#(6)$$

3 空频域融合块

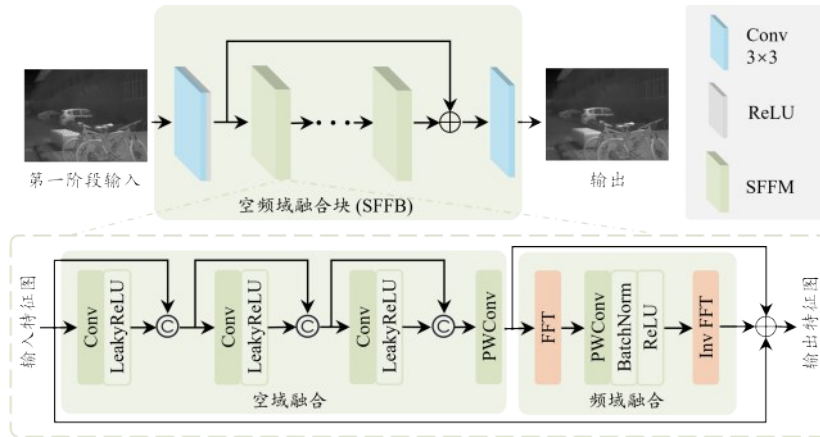


图2 所提出的空频域融合块(SFFB)的架构。

空频融合块由若干个空频域融合模块（Spatial-Frequency Domain Fusion Module, SFFM）组成，其整体结构如图2所示，主要包括空域特征融合与

频域特征融合两个部分。空域特征融合主要由三个卷积层以特征拼接的形式实现，用于获取输入特征的局部纹理、边缘与空间结构信息。给定输入图像

x ，整个特征学习过程如下：

$$x_1 = \sigma(W_1^{conv3 \times 3} * x) \# (7)$$

$$x_2 = \sigma(W_2^{conv3 \times 3} * [x, x_1]) \# (8)$$

$$x_3 = \sigma(W_3^{conv3 \times 3} * [x, x_1, x_2]) \# (9)$$

其中 $*$ 表示卷积操作 $W_i^{conv3 \times 3}$ 表示学习到的权重。符号 $\#$ 表示按通道维度的特征拼接操作， σ 表示Leaky ReLU激活函数。之后， x_3 送入逐点卷积 W_{pconv} ，获得融合不同通道的特征图 x_{pw} ：

$$x_{pw} = W_{pconv} * [x, x_1, x_2, x_3] \# (10)$$

紧接着，空域信息增强的特征 x_{pw} 送入频域融合模块，利用傅里叶变换将图像中的局部纹理细节转换为频率成分，从而使图像的全局结构和光谱分布更加突出，保留图像的偏振结构信息，再将频域特征表示分解为实部 $Real(\mathcal{F}(x_{pw}))$ 和虚部 $Imag(\mathcal{F}(x_{pw}))$ 后拼接，将拼接后的频域特征进行卷积与归一化增强。整个操作过程如下：

$$F(x_{pw}) = rfft2(x_{pw}, norm = 'ortho') \# (11)$$

$$F_{cat} = [Real(\mathcal{F}(x_{pw})), Imag(\mathcal{F}(x_{pw}))] \# (12)$$

$$\mathcal{F}'(x) = ReLU(BN(W_{pconv} * F_{cat})) \# (13)$$

其中 $rfft2(\cdot)$ 表示二维实数快速傅里叶变换， $\mathcal{F}(x_{pw})$ 为频域复数特征表示， $norm = 'ortho'$ 表示采用正交归一化，使变换保持能量一致。频域特征表示的实部和虚部再拼接得到 F_{cat} ， $\mathcal{F}'(x)$ 表示频域特征进行卷积与归一化增强后得到的特征。

随后，融合后的光谱表示经过快速傅里叶逆变换 $irfft2(\cdot)$ 重建为空间域特征：

$$x_{fft} = irfft2(\mathcal{F}'(x), norm = 'ortho') \# (14)$$

这一过程使频域中提取的全局信息能够有效回馈到空间域特征表示中，同时避免细节信息在重建过程中被过度平滑。通过快速傅里叶逆变换得到的特征，分别与频域融合部分的输入特征 x_{pw} 以及 SFFM 的原始输入特征 x 进行融合作为 SFFM 模块的输出：

$$SFFM(x) = x + x_{pw} + x_{fft} \# (15)$$

输出张量进入下一个 SFFM 模块进行处理，最终 SFFB 的计算过程为：

$$x = \sigma(W_{conv3 \times 3} * x_{NoisyDoFP}) \# (16)$$

$$SFFB(x) = W_{conv3 \times 3} * (x + \alpha \cdot$$

$$SFFM_3(SFFM_2(SFFM_1(x)))) \# (17)$$

其中 $x_{NoisyDoFP}$ 是 SFFB 的输入张量， σ 是 ReLU 激活函数， α 是残差缩放因子，根据经验设置为 0.2， $SFFM_i$ 表示第 i 个 SFFM 子模块， $SFFB(x)$ 表示第一阶段 SFFB 模块的最终输出。通过这种在空域和频域的多阶段联合处理，模型能够更全面地捕获图像中的结构性特征和光谱分布，同时学习到空间域和频域的特征。对去噪而言，空域信息有助于恢复局部纹理和细节，同时抑制噪声的局部随机扰动；频域分支关注图像的全局频谱分布，能够分离低频平滑区域和高频纹理噪声。仅利用空域信息难以捕捉图像整体频谱分布和周期性纹理信息，去噪时容易过度平滑，影响 AoP 和 DoLP 的精度。本文引入的空频域融合块，可以同时利用空域局部纹理信息和频域全局结构特征，实现噪声抑制与细节保留。

4 轻量级精细化块

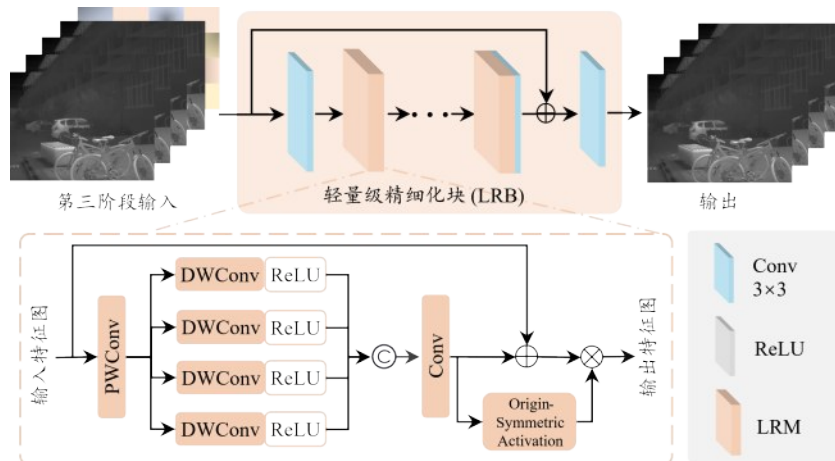


图3 所提出的轻量级精细化块(LRB)的架构。

针对前两个阶段的粗糙重建结果, 本文提出轻量级精细化块, 由四个轻量级精细化模块 (Light-weight Refinement Module, LRM) 依次堆叠而成, 其结构如图 3 所示。考虑到偏振图像的成像特点, 该结构在参数规模受限的情况下对重建结果进行逐步优化。具体而言, 首先对输入特征图 x 施加点卷积操作, 以促进通道间特征信息的融合, 为后续处理提供基础特征表示:

$$x_{pw} = W_{conv} * x \# (18)$$

融合特征沿通道维度均匀划分为四组, 与偏振成像中不同偏振方向的采样形式保持一致, 对应 $I(0^\circ)$ 、 $I(45^\circ)$ 、 $I(90^\circ)$ 和 $I(135^\circ)$ 四个方向, 其物理含义可通过斯托克斯参数关系进行说明。

$$I(\theta) = \frac{1}{2} [S_0 + S_1 \cos 2\theta + S_2 \sin 2\theta] \# (19)$$

其中 θ 表示线偏振器的方向, S_0 、 S_1 和 S_2 为斯托克斯参数。划分后的特征会分别送入四个并行卷积分支进行特征学习。各分支独立提取特征后再进行融合, 以获得更为完整的特征表示。

$$x_1, x_2, x_3, x_4 = \text{split}(x_{pw}) \# (20)$$

$$x_i^{dw} = \text{ReLU}(W_{3 \times 3}^{dw} * x_i), i = 1, 2, 3, 4 \# (21)$$

之后, 各分支的输出特征按特征维度进行拼接, 并送入一个 3×3 卷积层进一步融合。同时, 在 LRM 中引入关于原点对称的激活函数, 并与特征图进行逐元素相乘, 以增强特征响应从而有利于细节和局部结构的恢复。

$$x_{out} = \text{ReLU}(W_{conv 3 \times 3} * \text{concat}(x_1^{dw}, x_2^{dw}, x_3^{dw}, x_4^{dw})) \# (22)$$

$$\alpha = \text{Sigmoid}(x_{out}) - 0.5 \# (23)$$

$$x_{out} = \alpha(x_{out} + x) \# (24)$$

其中 x_{out} 表示 LRM 的输出。经过轻量级精细化块处理, 前两个阶段的粗糙的图像重建质量得到了进一步提升。

5 损失函数

本文对网络三个阶段输出进行优化。具体而言, 第一阶段使用 L1 损失函数 \mathcal{L}_1 , 使 SFFB 能够输出去噪后的 DoFP 图像 I_{dn}^{DoFP} :

$$\mathcal{L}_1 = \lambda_1 \|I_{dn}^{DoFP} - I^{DoFP}\|_1 \# (25)$$

第二阶段同样采用 L1 损失函数 \mathcal{L}_2 , 使 RRDB 专注于去噪图像 I_{dn}^{DoFP} 的初始去马赛克:

$$\mathcal{L}_2 = \lambda_2 \| \hat{I}_2 - I_{im} \|_1 \# (26)$$

第三阶段则对最终重建结果、DoLP 图像、AoP 图像和冗余误差项进行约束:

$$\begin{aligned} \mathcal{L}_3 = & \omega_1 \| \hat{I}_3 - I_{im} \|_1 + \omega_2 \| \hat{I}_{DoLP} - I_{DoLP} \|_1 \\ & + \omega_3 \min \left(\| \hat{I}_{AoP} - I_{AoP} \|_1, 1 - \| \hat{I}_{AoP} - I_{AoP} \|_1 \right) + \\ & \omega_4 \| \hat{R} \|_1 \# (27) \end{aligned}$$

通过多阶段约束聚合, 网络损失函数形式如下:

$$\mathcal{L}_{total} = \mathcal{L}_1 + \mathcal{L}_2 + \mathcal{L}_3 \# (28)$$

其中 L_1 、 L_2 和 L_3 分别是 DCDRnet 各阶段的损失。总损失函数组合了这些成分, 定义为 L_{total} 。这里, I^{DoFP} 和 I_{dn}^{DoFP} 分别表示真实值和去噪后的 DoFP 图像, I_{im} 是 IR-DoT 数据集。 \hat{I}_2 和 \hat{I}_3 分别表示第二阶段和第三阶段生成的重建图像。 I_{DoLP} 和 I_{AoP} 表示真实的 DoLP 和 AoP 图像, 而它们的重建对应项 \hat{I}_{DoLP} 和 \hat{I}_{AoP} 由 I_3 计算得到。偏振冗余误差 \hat{R} 由第三阶段输出计算得到。采用 L_1 范数是因为它在联合去噪-去马赛克中有效^[11]。阶段平衡超参数 $\lambda_1 = 2.5$ 、 $\lambda_2 = 0.5$ 调节不同阶段对 L_{total} 的贡献, 而特定超参数 $\omega_1 = 1.5$ 、 $\omega_2 = 1.64$ 、 $\omega_3 = 0.2$ 和 $\omega_4 = 0.5$ 调整 L_3 中各成分的相对重要性。损失函数中的超参数通过大量实验所得, 实验说明及结果见章节 6.5 消融研究中的第六项。

6 实验结果及分析

6.1 数据集

本文使用的两个红外偏振数据集来自^[13], 它们是使用 DoT 和 DoFP LWIR 偏振成像系统采集的。IR-DoT 数据集由 83 个不同的户外场景组成, 每组包含四个不同方向的偏振图像, 每个图像的高分辨率为 640×480 像素。IR-DoT 用于生成合成的 DoFP 并作为真实值。IRDoFP 数据集由 200 个不同的户外场景组成, 是需要去马赛克的 640×512 像素单通道图像。

本文比较了红外偏振 S_0 、DoLP 和 AoP 图像的重建质量, 其中 S_0 图像反映整体场景亮度, DoLP 反映目标背景对比度, AoP 反映材料表面特性和差异。 S_0 、DoLP 和 AoP 通过以下公式由四通道高分辨率图像计算得到。在线偏振成像系统中, 线偏振器的方向通常设置为 0° 、 45° 、 90° 和 135° , 因为这种配置的测量信噪比 (SNR) 最大且系统误差最

小^{[44][45]}。每个偏振器方向对应的强度测量表示如式(29-32)所示：

$$I(0^\circ) = \frac{1}{2}[S_0 + S_1] \#(29)$$

$$I(45^\circ) = \frac{1}{2}[S_0 + S_2] \#(30)$$

$$I(90^\circ) = \frac{1}{2}[S_0 - S_1] \#(31)$$

$$I(135^\circ) = \frac{1}{2}[S_0 - S_2] \#(32)$$

$I(0^\circ)$ 、 $I(45^\circ)$ 、 $I(90^\circ)$ 、 $I(135^\circ)$ 分别表示偏振器方向为 0° 、 45° 、 90° 和 135° 时的强度测量^[3]。基于式(29-32)，可以推导出入射光的前三个斯托克斯参数 (S_0, S_1, S_2):

$$S_0 = \frac{1}{2}[I(0^\circ) + I(45^\circ) + I(90^\circ) + I(135^\circ)] \#(33)$$

$$S_1 = I(0^\circ) - I(90^\circ) \#(34)$$

$$S_2 = I(45^\circ) - I(135^\circ) \#(35)$$

随后，得到的斯托克斯参数可进一步用于计算

入射光的主要偏振参数 DoLP 和 AoP^[3]:

$$DoLP = \frac{\sqrt{S_1^2 + S_2^2}}{S_0} \#(36)$$

$$AoP = \frac{1}{2} \arctan\left(\frac{S_2}{S_1}\right) \#(37)$$

6.2 数据预处理

原始的四通道 IR-DoT 图像通过 MPA 模式下采样为单通道 DoFP 图像，然后加混合噪声以生成本文的训练数据。基于 MPA 的下采样通过选择性保留四个偏振方向的强度值来模拟 DoFP 传感器的采样过程，如图4所示，每个像素仅记录一个偏振方向的光强度。加入的混合噪声是贴近真实红外偏振图像的混合高斯-条纹-加性噪声^[13]，泊松噪声参数限制在 $[0.02, 0.1]$ 范围内，考虑到加性噪声对系统的主要影响，加性噪声水平直接配置在 $[0, 4.5]$ 范围内。为考虑条纹噪声通常有较大的估计误差，条纹噪声参数设置在更宽的 $[0, 7.5]$ 范围内。




图4 生成训练数据的过程

最终生成的训练数据为83个 640×480 分辨率的单通道图像，分为63个训练样本和20个测试样本。为增强数据多样性，在训练期间，每张 640×480 图像被分为16个 160×120 像素的无重叠补丁，得到1008个训练样本。测试数据不裁剪，保留原始的 640×480 分辨率。

6.3 实验设置

在训练过程中，从合成的带噪声 DoFP 图像中随机裁剪 64×64 大小的补丁作为输入张量，并用随机垂直和水平翻转以及旋转 (90° 、 180° 和 270°)增强训练数据的多样性。使用 ADAM 优化器^[46]进行网络优化，其中 $\beta_1 = 0.9, \beta_2 = 0.999$ ，优化过程以 3×10^{-4} 的初始学习率开始，每2000个 epoch 衰减因子为0.1。模型训练共5000个 epoch，批次大小为16。所有实验均使用 PyTorch 2.5 实现，并在 NVIDIA RTX 4090 GPU 上运行。

6.4 联合去噪去马赛克方法比较

为了验证本文方法在图像恢复方面的效果，将

本文提出的方法与 $1D_GF^{[47]} + Anscombe^{[48]} + itPD^{[49]}$ 以及四种深度学习方法 CDNDMnet^[43]、JDMDNSR^[10]、MGCC^[50]和 PJDNDMnet^[13]进行比较。CDNDMnet 是一个包含两个子网的两阶段框架，用于对彩色图像进行联合去噪和去马赛克，适合本文的任务。JDMDNSR 是一种彩色图像联合去噪去马赛克算法，在不修改架构的情况下可以用于偏振图像联合去噪去马赛克任务。MGCC 是目前最先进的彩色图像联合去噪去马赛克方法之一，它采用了颜色通道的相互引导策略，以综合利用所有颜色通道的优势。我们将 MGCC 网络扩展为四个分支，由于每个偏振通道的空间采样率相同，因此原 MGCC 模型中针对绿色通道设计的分支不再适合本文的任务。所以对改进的 MGCC 中的四个相互引导的分支进行同等对待，从而恢复出四个偏振通道。PJDNDMnet 是专用于红外偏振图像的去噪去马赛克联合网络，与这个网络的对比更能体现本文方法的有效性。以上网络与本文方法使用相同数据训练

测试并用相同的训练数据生成方法。

本文采用峰值信噪比 (PSNR) 和结构相似性指数 (SSIM) 作为图像重建质量的评估指标, 分别评估了几种算法在 S_0 、DoLP 和 AoP 图像上的性能, 所有定量结果均基于 100 次测试运行的平均值, 以确保稳健性; 在模型性能方面用参数量和单帧运行时间作为评估指标, 实验结果如表 1 所示。可以看到 DCDRnet 重建 S_0 图像 PSNR 数值取得了 46.59 dB, 相比次优的 MGCC 方法提高了 0.54 dB, 表征偏振物理特性的 DoLP 图像的 PSNR 也取得了

39.18 dB 的最优值。上述结果表明了 DCDRnet 在去除偏振马赛克的同时, 能够较好地保持图像的偏振信息。与 PJDNDMnet 相比, DCDRnet 在参数量减少 39.3% 的情况下, 重建的 S_0 PSNR 数值仍然提升了 1.14 dB。DCDRnet 的单帧运行时间也优于 PJDNDMnet。上述实验结果表明 DCDRnet 在重建精度、模型参数量与推理时间之间取得了较好的平衡, 更适合物联网端侧的红外偏振成像系统应用场景。

表 1 不同方法在 IR-DOT 上的性能比较。

| 方法 | S_0 PSNR/SSIM | DoLP PSNR/SSIM | 运行时间/s | 参数量/M |
|-------------------------|-----------------------|-----------------------|---------------|-------------|
| 1D_GF + Anscombe + itPD | 38.69 / 0.9390 | 34.22 / 0.8148 | 0.5123 | - |
| CDNDMnet | 44.05 / 0.9956 | 37.25 / 0.8368 | 0.0102 | 8.32 |
| JDMDNSR | 45.39 / 0.9971 | 38.53 / 0.8783 | 0.3892 | 6.34 |
| MGCC | 46.05 / 0.9976 | 38.82 / 0.8814 | 0.8747 | 20.02 |
| PJDNDMnet | 45.45 / 0.9982 | 39.15 / 0.9636 | 0.0904 | 4.07 |
| DCDRnet | 46.59 / 0.9987 | 39.18 / 0.9603 | 0.0655 | 2.47 |

图 5、图 6 分别显示了六个场景的合成数据的 DoLP 图像和 AoP 图像的重建结果。从中可以看出, 本文提出的 DCDRnet 在视觉效果上的重建细节更

丰富, 这些实验结果验证了本文方法的在性能和偏振信号恢复质量上的平衡。




图 5 不同方法在合成的 DoFP 图像上对 DoLP 图像的重建结果。从上到下依次为:(a)真实值,(b)PJDNDMnet,(c)本文提出的方法。

此外, 本文还使用真实的 IR-DoFP 数据集来评估本文提出的方法, 用 APMR^[49]来评估图像重建质量, 值越高表示重建结果越好。如表 2 所示, 表中的数据是所有 200 幅图像的平均 APMR 值。图 7、图 8 是在真实 DoFP 上的视觉重建结果。定性和定量结果均表明, DCDRnet 在真实 DoFP 数据集上的重建质量仍然优于其他方法。

6.5 消融研究

1) 为评估第一阶段 SFFM 中频域融合的效果,

本文设计了一个移除快速傅里叶变换和快速傅里叶逆变换的实验。从表 3 的第一行可以看出, 移除傅里叶变换相关步骤之后, S_0 、DoLP 和 AoP 的 PSNR 和 SSIM 都有明显下降。该实验证明了将空间域特征值转换为频域特征的有效性。

2) 为验证 SFFM 中空间特征融合的低级细节提取能力, 本文移除了 SFFM 前半部分的特征拼接操作, 该步骤对空间域特征进行粗略提取。这一步骤的移除导致原始信息丢失并减少空间特征。如表 3




图6 不同方法在合成的 DoFP 图像上对 AoP 图像的重建结果。从上到下依次为：(a)真实值，(b)PJDNDMnet，(c)本文提出的方法。

表2 每种方法在 IR-DoFP 的全部 200 个场景上的平均 APMR 得分。

| 方法 | APMR/dB |
|-------------------------|--------------|
| Without any processing | 31.83 |
| 1D_GF + Anscombe + itPD | 56.86 |
| CDNDMnet | 64.09 |
| JDMDNSR | 67.98 |
| MGCC | 67.36 |
| PJDNDMnet | 69.86 |
| DCDRnet | 72.89 |

的第二行所示，移除拼接步骤极大地降低了图像重建质量，特别是偏振参数 DoLP 和 AoP 的重建质量。这凸显了原始偏振信息和低级细节对于全分辨率偏振图像恢复的重要性。PWConv 模块压缩通道数量，以尽可能的压缩频域变换的计算成本，同时保留关键信息。当频域特征融合结构中不包含前置 PWConv 时，特征图在未进行通道压缩的情况下直接参与频域变换，计算复杂度相应增加，冗余通道

和低频噪声未被有效抑制，浅层特征在频域分支中的作用受到一定限制，整体噪声抑制性能随之下降。表3的第三行展示了移除点卷积后的实验结果，可以看到 S_0 和 AoP 的 PSNR 数值都有明显下降。

3) 为验证 SFFB 中使用不同设置对最终重建质量的影响，本文设置了相应的消融实验对比重建效果和参数量，如表4所示。可以看到当卷积块数量设置为3时，模型在参数规模与重建性能之间表现出较为合理的折中，当卷积块数量增加至5时，重建质量有所提升，但参数量随之明显增加。进一步对比发现，采用3个和4个卷积块时，其重建性能没有明显的差异，所以本文在网络设计中选取3个卷积块作为默认配置。表4第3到6行给出了不同数量 SFFM 的对比结果，可以看出当 SFFM 数量为3和5时，模型的 PSNR 较高但差异不大。考虑到3个 SFFM 在保持较好重建性能的同时具有更低的参数开销，本文最终采用3个 SFFM 作为网络框




图7 不同方法在真实 DoFP 图像上对 DoLP 图像的重建结果。从上到下依次为：(a) S_0 图像，(b)PJDNDMnet，(c)本文提出的方法。

架的配置方案。




图8 不同方法在真实 DoFP 图像上对 AoP 图像的重建结果。从上到下依次为:(a) S_0 图像,(b) PJDNDMnet,(c) 本文提出的方法。

表3 DCDRnet 第一阶段不同网络设置在 IR-DOT 测试集上的评估结果。

| 实验设置 | S_0 | DoLP | AoP |
|--------------|---------------------|---------------------|---------------------|
| | PSNR/SSIM | PSNR/SSIM | PSNR/SSIM |
| w/o FFT IFFT | 44.99/0.9980 | 38.85/0.9584 | 20.58/0.6229 |
| w/o concat | 44.51/0.9976 | 36.08/0.9275 | 18.74/0.5503 |
| w/o PWConv | 46.21/0.9987 | 39.19/0.9651 | 20.74/0.6307 |
| DCDRnet | 46.59/0.9987 | 39.18/0.9603 | 21.21/0.6509 |

4) 针对本文网络第三阶段引入的轻量级精细化模块, 采用与第一阶段一致的消融方式, 对其中关键结构进行逐一移除或替换, 以分析各组成部分对整体性能的影响, 实验结果如表 5 所示。将四个并行的深度可分离卷积替换为标准卷积后, 模型性能出现明显下降, DoLP 和 AoP 的 PSNR 分别降低约 1.2 dB 和 0.24 dB, SSIM 也出现不同程度的下降, 这表明标准卷积在通道维度上的融合不利于偏振特征的独立建模, 容易导致斯托克斯参数之间的相互

干扰, 从而影响偏振信息的表达与恢复, 而且该替换还带来了额外的计算开销。在移除 LRM 中的初始点卷积后, 跨通道信息交互能力明显减弱, S_0 、DoLP 和 AoP 在 PSNR 和 SSIM 指标上均出现下降, 这表明点卷积在特征压缩与通道信息重组过程中具有重要作用。

5) 为验证本文算法中三阶段架构的有效性, 本文设计了模块替换实验, 结果如表 6 所示。当使用包含所有阶段的完整架构时, PSNR 和 SSIM 指标达到最优值, 证实了本文提出方法的整体有效性。当第一和第二阶段都使用 RRDB 模块时, 尽管 DoLP 指标达到局部最优值, 但伴随着 S_0 和 AoP 指标的显著下降, 平均 PSNR 下降 0.69 dB, 揭示了使用单个模块进行优化的局限性。从最后两个实验中可以看出, 第三阶段仅增加 0.045M 的参数, 就使总 PSNR 提升 0.33 dB, 这证明了该阶段在少量参数增加下的性能增益。

表4 不同模块数量对 IR-DOT 测试集上重建质量的影响比较。

| 实验设置 | 数量 | S_0 | DoLP | AoP | 参数量/ M |
|--------------|-----|---------------------|---------------------|---------------------|--------------|
| | | PSNR/SSIM | PSNR/SSIM | PSNR/SSIM | |
| Conv in SFFM | 2 | 45.38/0.9983 | 38.13/0.9555 | 20.39/0.6286 | 2.429 |
| Conv in SFFM | 4 | 46.55/0.9987 | 39.29/0.9624 | 21.14/0.6535 | 2.933 |
| Conv in SFFM | 5 | 47.11/0.9988 | 40.06/0.9702 | 21.41/0.6609 | 3.498 |
| SFFM | 2 | 45.77/0.9984 | 38.64/0.9546 | 20.53/0.6167 | 2.224 |
| SFFM | 4 | 46.13/0.9987 | 38.68/0.9518 | 20.99/0.6508 | 2.732 |
| SFFM | 5 | 46.65/0.9987 | 39.15/0.9603 | 21.29/0.6643 | 2.987 |
| DCDRnet | 3,3 | 46.59/0.9987 | 39.18/0.9603 | 21.21/0.6509 | 2.478 |

表5 DCDRnet 第三阶段不同网络设置在 IR-DOT 测试集上的评估结果。

| 实验设置 | S_0 | DoLP | AoP |
|--------------------------|---------------------|---------------------|---------------------|
| | PSNR/SSIM | PSNR/SSIM | PSNR/SSIM |
| Replace DWconv with conv | 45.12/0.9983 | 37.98/0.9542 | 19.96/0.6248 |
| w/o the first PWConv | 45.74/0.9984 | 38.60/0.9559 | 20.58/0.6266 |
| DCDRnet | 46.59/0.9987 | 39.18/0.9603 | 21.21/0.6509 |

6) 为了得到损失函数中最合适的参数, 我们针对不同阶段的损失设计了大量实验。对于第一阶段 λ_1 , 结果如表7所示, 第一阶段去噪权重 λ_1 对偏振信息恢复具有显著影响。适当增强去噪有助于提升 S_0 重建质量, 但过大的权重会削弱结构细节恢复能力, 从而影响 DoLP 和 AoP 的精度。综合各指标表现与多阶段优化平衡关系, 最终采用 $\lambda_1 = 2.5$ 作为最优参数。对第二阶段的参数 λ_2 设置了4个对比实验, 结果如表7第6至10行所示, 第二阶段去马赛克权重 λ_2 对结构恢复与偏振信息重建之间的平衡具有重要影响。适度增强结构约束有助于提升 S_0 重建质量, 但当权重过大时, 会削弱第三阶段对 DoLP 和 AoP 的物理一致性优化能力; 当权重过小时, 则无法有效稳定初始去马赛克结果, 导致整体性能下降。综合各指标表现与多阶段梯度协同关系, 最终选取 $\lambda_2 = 0.5$ 作为最佳权重设置。

对第三阶段参数 ω_1 的实验结果如表8所示。可以看到, 第三阶段中不同的强度重建权重 ω_1 对最终图像质量和偏振参数精度具有显著影响。适当增强最终强度约束有助于提升整体重建稳定性, 但若权重过小会导致强度恢复不足, 而权重过大则可能限制 DoLP 和 AoP 的优化空间。结合平均 PSNR 指标, 最终采用 $\omega_1 = 1.5$ 作为最优参数。

对损失函数第三阶段各参数的实验如表9所示。第三阶段中 DoLP 约束权重 ω_2 、AoP 约束权重 ω_3 以及偏振冗余误差权重 ω_4 的联合调节对最终性能具有协同影响。过强的 DoLP 约束会压制强度与物理一致性项的优化, 而冗余误差项权重过大则

可能限制网络对细节结构的表达能力。通过对不同组合的对比分析发现, 在适度平衡偏振一致性与强度重建约束的条件下, 可获得更优的整体性能。综合实验结果与稳定性考虑, 最终采用 $\omega_2 = 1.64, \omega_3 = 0.2, \omega_4 = 0.5$ 作为最优超参数组合。

7 结论

针对物联网终端设备的高精度高效率要求, 本文提出了一种用于 LWIR DoFP 红外偏振图像的轻量级空频域协同去噪与重建网络, 旨在提升红外偏振重建质量并减少计算要求。具体来说, 本文设计了三阶段渐进式网络, 分为去噪, 粗糙去马赛克和精细化步骤。首先, 本文设计了双域交互去噪块, 将特征图转换到频域中不仅让网络学习到偏振特性, 相比于仅利用空域特征, 空频域交互在极少的参数量下实现与空域中更多参数量的去噪效果。其次, 在密集残差块进行粗糙去马赛克后, 本文提出了一种轻量级精细化块, 通过深度分组卷积压缩精细化阶段的模型参数量, 同时细化重建质量, 实现效率与精度的平衡。与现有方法的对比实验和消融实验结果证明了本文方法在效率和图像恢复质量方面达到了平衡, 为智能物联网设备在红外偏振感知领域提供了具有部署潜力的图像质量提升方法。

然而, 本文方法在边缘区域仍然存在一定伪影和过渡平滑现象, 这主要是由于模型在重建过程中采用的全局约束与正则化策略更侧重于结构一致性与噪声抑制, 从而在高极化变化的边界区域可能导致细节表达能力有所下降。未来工作将考虑引入结构感知与引导的细节恢复机制, 以进一步提升 AoP 图像的重建质量。

表6 DCDRnet 三阶段不同网络设置在 IR-DOT 测试集上的评估结果。

| 实验设置 | S_0 | DoLP | AoP | 参数量/M |
|---------------|---------------------|---------------------|---------------------|--------------|
| | PSNR/SSIM | PSNR/SSIM | PSNR/SSIM | |
| SFFB-SFFB-LRB | 45.38/0.9983 | 38.05/0.9497 | 20.59/0.6305 | 1.581 |
| RRDB-SFFB-LRB | 45.33/0.9982 | 38.95/0.9612 | 20.63/0.6262 | 2.478 |
| RRDB-RRDB-LRB | 45.77/0.9983 | 39.52/0.9650 | 20.91/0.6407 | 3.375 |
| SFFB-RRDB | 46.03/0.9986 | 39.41/0.9635 | 21.22/0.6528 | 2.433 |
| SFFB-RRDB-LRB | 46.59/0.9987 | 39.18/0.9603 | 21.21/0.6509 | 2.478 |

表7 损失函数参数 λ_1, λ_2 的不同设置在 IR-DOT 测试集上的评估结果。

| λ_1 | λ_2 | S_0 PSNR | DoLP PSNR | AoP PSNR | 平均 PSNR |
|-------------|-------------|------------|-----------|----------|---------|
| 0.5 | 0.5 | 46.2838 | 39.1326 | 21.0964 | 35.5043 |
| 1.0 | 0.5 | 46.3354 | 39.5977 | 21.3085 | 35.7472 |
| 1.5 | 0.5 | 46.4387 | 39.2709 | 21.2692 | 35.6596 |
| 2.0 | 0.5 | 46.1500 | 39.3996 | 21.2706 | 35.6067 |
| 3.0 | 0.5 | 46.2526 | 39.0322 | 20.9335 | 35.4061 |
| 2.5 | 0.1 | 46.5234 | 39.0535 | 21.2109 | 35.5959 |
| 2.5 | 0.3 | 46.1214 | 38.9665 | 20.8866 | 35.3248 |
| 2.5 | 0.8 | 46.5267 | 39.0365 | 20.9322 | 35.4985 |
| 2.5 | 1 | 46.6352 | 39.0208 | 21.1821 | 35.6127 |
| 2.5 | 0.5 | 46.5975 | 39.1830 | 21.2070 | 35.6625 |

表8 参数 ω_1 的不同设置在 IR-DOT 测试集上的评估结果。

| ω_1 | S_0 PSNR | DoLP PSNR | AoP PSNR | 平均 PSNR |
|------------|------------|-----------|----------|---------|
| 0.5 | 46.3057 | 39.0438 | 20.9022 | 35.4172 |
| 1 | 46.0317 | 39.0962 | 20.9833 | 35.3704 |
| 1.5 | 46.5975 | 39.183 | 21.207 | 35.6625 |
| 2 | 46.4261 | 39.3057 | 21.0837 | 35.6052 |

表9 损失函数第三阶段参数 $\omega_2, \omega_3, \omega_4$ 的不同设置在 IR-DOT 测试集上的评估结果。

| ω_2 | ω_3 | ω_4 | S_0 PSNR | DoLP PSNR | AoP PSNR | 平均 PSNR |
|-------------|------------|------------|------------|-----------|----------|---------|
| 1 | 0.2 | 0.5 | 46.6567 | 39.2309 | 21.2920 | 35.7266 |
| 2 | 0.2 | 0.5 | 46.6376 | 39.1103 | 21.0972 | 35.6150 |
| 1.5 | 0.2 | 0.5 | 45.9182 | 39.1937 | 20.8355 | 35.3158 |
| 1.64 | 0.1 | 0.5 | 46.2844 | 39.0551 | 21.2265 | 35.5220 |
| 1.64 | 0.3 | 0.5 | 46.2575 | 39.3589 | 21.1575 | 35.5913 |
| 1.64 | 0.2 | 0.3 | 46.4324 | 39.5433 | 21.2500 | 35.7419 |
| 1.64 | 0.2 | 0.8 | 46.5271 | 39.0522 | 21.2495 | 35.6096 |
| 1.64 | 0.2 | 0.5 | 46.5975 | 39.183 | 21.207 | 35.6625 |

参考文献:

[1] 李磊磊, 黄海霞, 郭阳, 等. 基于红外辐射偏振成像的目标三维重建方法[J]. 红外与毫米波学报, 2021, 40(3): 413.
LI L L, HUANG H X, GUO Y, et al. 3D reconstruction method of target based on infrared radiation polarization imaging[J]. Infrared Millim. Waves, 2021, 40(3): 413.

[2] 赵永强, 李宁, 潘泉. 分焦平面红外偏振摄像技术[M]. 北京: 科学出版社, 2022: 7-11.
ZHAO Y Q, LI N, PAN Q. Division of focal plane infrared polarization photography[M]. Beijing: Science Press, 2022: 7-11.

[3] 赵永强, 乔新博, 李宁, 等. 偏振视觉[J]. 中国科学: 信息科学, 2024, 54(7): 1620-1645.

ZHAO Y Q, QIAO X B, LI N, et al. Polarization vision[J]. Scientia Sinica (Informationis), 2024, 54(7): 1620-1645.

[4] 周强国, 黄志明, 周炜. 偏振成像技术的研究进展及应用[J]. 红外技术, 2021, 43(9): 817-828.
ZHOU Q G, HUANG Z M, ZHOU W. Research Progress and Application of Polarization Imaging Technology[J]. Infrared Technology, 2021, 43(9): 817-828.

[5] SARGENT G C, RATLIFF B M, ASARI V K. Conditional generative adversarial network demosaicing strategy for division of focal plane polarimeters[J]. Optics Express, 2020, 28(25): 38419-38443.

[6] YE W, LI S, ZHAO X, et al. AK times singular value decomposition based image denoising algorithm for DoFP polarization image sensors with Gaussian noise[J]. IEEE Sensors Journal, 2018, 18(15): 6138-6144.

[7] LIU H, ZHANG Y, CHENG Z, et al. Attention-based neural network for polarimetric image denoising[J]. Optics Letters, 2022, 47(11): 2726-2729.

[8] LIU J, DUAN J, HAO Y, et al. Polarization image demosaicing and RGB image enhancement for a color polarization sparse focal plane array[J]. Optics Express, 2023, 31(14): 23475-23490.

[9] LI Z, JIANG H, CAO M, et al. Polarized color image denoising [C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2023: 9873-9882.

[10] XING W, EGIAZARIAN K. End-to-end learning for joint image demosaicing, denoising and super-resolution[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2021: 3507-3516.

[11] GO J, SOHN K, LEE C. Interpolation using neural networks for digital still cameras[J]. IEEE Transactions on Consumer Electronics, 2000, 46(3): 610-616.

[12] KAPAH O, HEL-OR H Z. Demosaicking using artificial neural networks[C]//Applications of Artificial Neural Networks in Image Processing V. SPIE, 2000, 3962: 112-120.

[13] LI N, WANG B, GOUDAIL F, et al. Joint denoising-demosaicking network for long-wave infrared division-of-focal-plane polarization images with mixed noise level estimation[J]. IEEE Transactions on Image Processing, 2023, 32: 5961-5976.

[14] 赵军辉, 李怀城, 王东明, 等. 物联网中模型剪枝技术: 现状、方法和展望[J]. 物联网学报, 2024, 8(04): 1-13.
ZHAO J H, LI H C, WANG D M, et al. Model pruning techniques in the Internet of things: state of the art, methods and perspectives[J]. Chinese Journal on Internet of Things, 2024, 8(04): 1-13.

[15] GAO N, JIANG X, ZHANG X, et al. Efficient frequency-domain image deraining with contrastive regularization[C]//European Conference on Computer Vision. Cham: Springer Nature Switzerland, 2024: 240-257.

[16] WANG X, YU K, WU S, et al. Esrgan: Enhanced super-resolution generative adversarial networks[C]//Proceedings of the European conference on computer vision (ECCV) workshops. 2018: 1-10.

- [17] WAN C, YU H, LI Z, et al. Swift parameter-free attention network for efficient super-resolution[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2024: 6246-6256.
- [18] USMANI K, O'CONNOR T, SHEN X, et al. Three-dimensional polarimetric integral imaging in photon-starved conditions: performance comparison between visible and long wave infrared imaging[J]. *Optics Express*, 2020, 28(13): 19281-19294.
- [19] LEFKIMMIATIS S, Non-local color image denoising with convolutional neural networks[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2017: 3587-3596.
- [20] BUADES A, COLL B, MOREL J M. A non-local algorithm for image denoising[C]//2005 IEEE computer society conference on computer vision and pattern recognition (CVPR'05). Ieee, 2005, 2: 60-65.
- [21] PORTILLA J, STRELA V, WAINWRIGHT M J, et al. Image denoising using scale mixtures of Gaussians in the wavelet domain [J]. *IEEE Transactions on Image processing*, 2003, 12(11): 1338-1351.
- [22] 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.
- [23] GUO Q, ZHANG C, ZHANG Y, et al. An efficient SVD-based method for image denoising[J]. *IEEE transactions on Circuits and Systems for Video Technology*, 2015, 26(5): 868-880.
- [24] JIANG B, LU Y, WANG J, et al. Deep image denoising with adaptive priors[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2022, 32(8): 5124-5136.
- [25] REN C, HE X, WANG C, et al. Adaptive consistency prior based deep network for image denoising[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2021: 8596-8606.
- [26] ZHANG K; ZUO W; CHEN Y, 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.
- [27] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2016: 770-778.
- [28] ZHANG Q, XIAO J, TIAN C, et al. A parallel and serial denoising network[J]. *Expert Systems with Applications*, 2023, 231: 120628.
- [29] TIAN C, ZHENG M, LIN C W, et al. Heterogeneous window transformer for image denoising[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2024, 54(11): 6621-6632
- [30] LEHTINEN J, MUNKBERG J, HASSELGREN J, et al. Noise2Noise: Learning image restoration without clean data[J]. *arXiv preprint arXiv:1803.04189*, 2018.
- [31] 杜永生, 蒿琳, 石秦峰. 低质量红外偏振图像热像特征提取方法[J]. *激光杂志*, 2022, 43(11): 159-163.
- DU YS, HAO I, SHI QF. Thermal image feature extraction method of low-quality infrared polarization image[J]. *Laser Journal*, 2022, 43(11): 159-163.
- [32] ZHANG L, DONG W, ZHANG D, et al. Two-stage image denoising by principal component analysis with local pixel grouping[J]. *Pattern recognition*, 2010, 43(4): 1531-1549.
- [33] CAI T T, WANG L. Orthogonal matching pursuit for sparse signal recovery with noise[J]. *IEEE Transactions on Information theory*, 2011, 57(7): 4680-4688.
- [34] HU H, JIN H, LIU H, et al. Polarimetric image denoising on small datasets using deep transfer learning[J]. *Optics & Laser Technology*, 2023, 166: 109632.
- [35] LIU H, LI X, CHENG Z, et al. Pol2Pol: self-supervised polarimetric image denoising[J]. *Optics Letters*, 2023, 48(18): 4821-4824.
- [36] HIRAKAWA K, PARKS T W. Adaptive homogeneity-directed demosaicing algorithm[J]. *IEEE Transactions on Image Processing*, 2005, 14(3): 360-369.
- [37] SU C Y. Highly effective iterative demosaicing using weighted-edge and color-difference interpolations[J]. *IEEE Transactions on Consumer Electronics*, 2006, 52(2): 639-645.
- [38] SYU N S, CHEN Y S, CHUANG Y Y. Learning deep convolutional networks for demosaicing[J]. *arXiv preprint arXiv:1802.03769*, 2018.
- [39] DONG Y, XIONG R, ZHAO J, et al. Learning a deep demosaicing network for spike camera with color filter array[J]. *IEEE Transactions on Image Processing*, 2024, 33: 3634-3647.
- [40] WU F, HUANG T, XU J, et al. Joint spatial and frequency domain learning for lightweight spectral image demosaicing[J]. *IEEE Transactions on Image Processing*, 2025.
- [41] GUO Y, DAI X, WANG S, et al. Attention-based progressive discrimination generative adversarial networks for polarimetric image demosaicing[J]. *IEEE Transactions on Computational Imaging*, 2024, 10: 713-725.
- [42] 朱洪波, 尹浩. 智能化时代的物联网科技与产业发展分析及策略[J]. *物联网学报*, 2025, 9(03): 1-16.
- ZHU H B, YIN H. Analysis and strategies of IoT technology and industrial development in the intelligent era[J]. *Chinese Journal on Internet of Things*, 2025, 9(03): 1-16.
- [43] MA J, WANG G, ZHANG L, et al. Restoration and enhancement on low exposure raw images by joint demosaicing and denoising [J]. *Neural Networks*, 2023, 162: 557-570.
- [44] TYO J S. Optimum linear combination strategy for an N-channel polarization-sensitive imaging or vision system[J]. *Journal of the Optical Society of America A*, 1998, 15(2): 359-366.
- [45] TYO J S. Design of optimal polarimeters: maximization of signal-to-noise ratio and minimization of systematic error[J]. *Applied optics*, 2002, 41(4): 619-630.
- [46] ADAM K D P B J. A method for stochastic optimization[J]. *arXiv preprint arXiv:1412.6980*, 2014, 1412(6).
- [47] CAO Y, YANG M Y, TISSE C L. Effective strip noise removal for low-textured infrared images based on 1-D guided filtering[J]. *IEEE transactions on circuits and systems for video technology*,

2015, 26(12): 2176-2188.

- [48] MAKITALO M, FOI A. Optimal inversion of the generalized Anscombe transformation for Poisson-Gaussian noise[J]. IEEE transactions on image processing, 2012, 22(1): 91-103.
- [49] LI N, LE T B, BOFFETY M, et al. No-reference physics-based quality assessment of polarization images and its application to demosaicking[J]. IEEE Transactions on Image Processing, 2021, 30: 8983-8998.
- [50] ZHANG Y, SUN W, CHEN Z. Joint image demosaicking and denoising with mutual guidance of color channels[J]. Signal Processing, 2022, 200: 108674.

[作者简介]



王秉路（1992年11月），男，2021年获西北工业大学自动化学院控制科学与工程博士学位。2022年至2024年，任北京理工大学信息与电子学院博士后研究员。现为西北工业大学航天学院教授、西安建筑科技大学兼职教授。研究方向包括计算机视觉、数字信号

处理与深度学习。



武剑珍（2001年8月），女，现就读于西安建筑科技大学计算机科学与技术专业，攻读硕士学位。研究方向包括图像超分辨率与图像重建。



汪顺舟（1992年10月），男，2023年在北京理工大学获博士学位，现为河南大学人工智能学院讲师，硕士生导师，研究方向包括光场图像超分辨率与视图合成。