

文章编号 1004-924X(2026)07-1156-14

用于物料混合均匀性检测的高光谱图像 散焦模糊去除

钱 斐¹, 胡 凡¹, 苟晓东², 朱启兵^{1*}

(1. 江南大学 物联网工程学院, 江苏 无锡 214122;

2. 北京理工大学 机电学院, 北京 100081)

摘要: 物料混合均匀性检测是实现产品质量在线监控与工艺优化的关键。针对高光谱成像(Hyperspectral Imaging, HSI)技术在材料混合均匀性检测中出现的图像散焦模糊,以及由此导致的均匀性评估失效问题,提出了一种自监督物理约束非配对高光谱图像去模糊算法(Physics-Constrained Self-Supervised Learning for Unpaired Hyperspectral Image Deblurring, PC-SSL-HSI Deblurring)。该算法采用融合 SimAM 注意力机制的 Uformer 作为去模糊网络,并借助对抗训练促使去模糊结果在特征空间内与清晰图像对齐,与此同时,算法还设计了一个基于经典退化模型的模糊核预测模块,用于构造伪样本对,再利用伪样本对的自监督学习引导去模糊网络聚焦于高光谱图像的局部细节恢复。实验结果表明,所提出的方法能够有效恢复图像细节,减少伪影,有助于物料混合均匀性的准确评估;在仿真数据集上高光谱图像的 PSNR 达到 34.970, SSIM 达到 0.900, 浓度预测误差为 0.022 8~0.031 2。所提方法在 KL 散度、CV 变异系数等混合均匀性指标上均优于比较算法,展现出良好的工程应用价值。

关键词: 高光谱图像;去散焦模糊;混合均匀性;自监督学习;物理约束

中图分类号: TP391.4 **文献标识码:** A

doi: 10.37188/OPE.20263407.1156

CSTR: 32169.14.OPE.20263407.1156

Defocus deblur of hyperspectral image for material mixing uniformity detection

QIAN Fei¹, HU Fan¹, GOU Xiaodong², ZHU Qibing^{1*}

(1. School of Internet of Things Engineering, Jiangnan University, Wuxi 214122, China;

2. School of Mechatronics Engineering, Beijing Institute of Technology, Haidian 100081, China)

* Corresponding author, E-mail: zhuqibing@jiangnan.edu.cn

Abstract: Detection of material mixing uniformity is critical for enabling online quality monitoring and process optimization. This study addresses the degradation of uniformity evaluation caused by defocus blur in hyperspectral imaging (HSI). A physics-constrained self-supervised learning framework for unpaired hyperspectral image deblurring (PC-SSL-HSI) is proposed. A Uformer-based architecture incorporating the SimAM attention mechanism is employed as the deblurring network, while adversarial training is introduced to align deblurred outputs with clear images in the feature space. In addition, a blur kernel prediction module is designed based on a classical degradation model to construct pseudo-sample pairs, enabling

收稿日期:2025-12-01;修订日期:2026-12-31.

基金项目:国家自然科学基金资助项目(No. 62273166)

self-supervised learning that guides the network to emphasize local detail restoration in hyperspectral images. Experimental results demonstrate that the proposed method effectively enhances image detail, suppresses artifacts, and improves the accuracy of material mixing uniformity evaluation. On a simulated dataset, the peak signal-to-noise ratio (PSNR) reaches 34.970 and the structural similarity index (SSIM) reaches 0.900, with concentration prediction errors ranging from 0.022 8 to 0.031 2. Furthermore, hyperspectral imaging experiments for material mixing uniformity indicate that the proposed method outperforms comparative approaches in metrics such as Kullback - Leibler divergence and coefficient of variation, highlighting its strong potential for engineering applications.

Key words: hyperspectral image; defocus deblur; mixing uniformity; self-supervised learning; physics-constrained

1 引言

物料混合是制药、食品、化工等领域的一个重要工艺环节。混合均匀性直接决定了最终产品的质量、安全性与有效性,对其进行快速、精准评估,是实现产品质量在线监控与工艺优化的关键^[1-3]。传统的混合均匀性评价多采用抽样化学分析法,存在着检测周期长,检测精度依赖于采样点选择的问题^[4]。高光谱成像技术是一种“图谱合一”技术,可以同时获得样品组分的空间信息和光谱信息,从而为混合均匀性的快速精确评估提供有效的途径^[5-6]。高光谱成像仪通常通过推扫或面阵列成像方式获取数据,由于景深有限,当待测物料表面存在起伏或与相机焦平面不平行时,就会导致图像的散焦模糊。散焦模糊会降低高光谱图像的空间分辨率,导致空间像素光谱产生“混合”,影响均匀性评估的准确性。

在图像退化模型中,散焦模糊可建模为清晰图像与模糊核(点扩散函数)之间的卷积操作。目前,利用各类算法对模糊图像进行复原(去模糊)已被广泛报道。在这些算法中,面向实际应用中模糊核未知的盲去模糊算法受到广泛的关注。从方法学角度看,现有去模糊方法可进一步划分为基于迭代优化的传统方法与基于深度学习的数据驱动方法。传统方法通常基于最大后验概率框架,结合图像先验构建目标函数并进行迭代求解。Fang等^[7]利用高光谱图像相邻波段间的光谱相关性,提出了一种融合光谱-空间全变差先验与显式非负约束的去模糊方法,能够在保留空间边缘的同时维持光谱不连续性。Guo

等^[8]则改进现有分数阶导数模型,提出基于三维分数阶全变差的正则化方法,并采用交替方向乘子法高效求解。这类方法具备良好的可解释性与灵活性,但通常依赖大量迭代,实时性较差,且复原效果受限于先验假设的合理性^[9],易引入振铃伪影等失真。随着深度学习的发展,大量的基于监督学习的图像去模糊算法被提出。在RGB图像领域,NAFNet^[10]通过简化非线性激活函数设计出高效网络结构,Uformer^[11]与Restormer^[12]则分别将视觉Transformer与U-Net架构融合,显著提升了复原性能。在高光谱图像领域,Geng等^[13]结合维纳滤波与深度卷积网络,有效利用高光谱图像中的空谱信息。Wang等^[14]基于3D DnCNN从数据中自适应学习光谱-空间特征。Xie等^[15]通过设计2D-3D混合卷积与多头注意力机制,实现深层光谱特征的精准提取与保留。这类方法虽复原精度高,但严重依赖大量的清晰-模糊成对样本进行训练,而在实际工业场景中,成对样本数据获取困难。为缓解监督学习算法对成对样本数据的依赖,部分研究开始探索无监督深度学习路径。CycleGAN^[16]通过对抗训练与循环一致性学习实现清晰与模糊图像间的映射,但其训练过程的稳定性较差,容易导致去模糊后图像的伪影现象^[17]。Tang等^[18]融合深度先验与传统先验,提出一种无监督盲去模糊模型,可在模糊核不准确情况下复原图像,但计算成本较高。

为解决高光谱图像散焦模糊对混合均匀性评估带来的挑战,本文提出了一种自监督物理约束非配对高光谱图像去模糊算法(Physics-Constrained Self-Supervised Learning for Unpaired

Hyperspectral Image Deblurring, PC-SSL-HSI Deblurring)。该算法利用经典的图像退化模型作为物理约束,设计一个模糊核预测模块用于构造伪样本对,从而利用自监督学习增强模型对图像局部细节的恢复能力。针对高光谱图像的高维数据特点,设计了融合 SimAM 模块的 Uformer 去模糊模块,并基于对抗学习思想引导去模糊图像向清晰域图像特征对齐。仿真和真实实验证明,PC-SSL-HSI Deblurring 算法的性能显著优于比较算法,在基于高光谱图像的混合均匀性检测中具有良好的性能。

2 算法原理

在实际工业场景中,像素级对应的清晰-模糊样本对通常难以大量获取。虽然基于对抗学习的无监督方法能够在非配对条件下进行训练,但其优化目标主要停留在图像的整体分布匹配与宏观内容一致性层面,缺乏对高频边缘、细微纹理及局部结构等关键细节的显式监督与引导,容易导致恢复结果出现过度平滑或伪影等问题。因此,PC-SSL-HSI Deblurring 算法通过引入符合物理先验的伪样本对作为监督信号,使得模型在训练过程中图像的每一个局部区域都能获得明确的、像素级对应的恢复目标,从而增强细节恢复能力。通过物理约束构

造伪样本对,遵循图像模糊退化规律生成高质量配对样本,为去模糊模块提供丰富的自监督训练伪样本对基础。而为了适配高光谱特性,精准学习伪样本中模糊-清晰特征映射,去模糊模块采用 SimAM+Uformer。去模糊模块的良好训练有助于模糊核预测网络预测出更加准确的模糊核,从而提高构造伪样本对的质量。二者通过“数据支撑-模型学习”互补,相互促进,共同提升算法在无配对样本下条件的高光谱图像去模糊性能。

算法的整体框架如图 1 所示,该框架主要包含了模糊核预测模块 G_A 、去模糊模块 G_B 和鉴别器 D 。在模型训练过程中,首先以模糊图像 y_{real} 为输入,利用模糊核预测网络 G_A 预测模糊向量,对该向量进行插值运算以产生各向同性的模糊核 K 。模糊核 K 与清晰图像 x_{real} (和模糊图像 y_{real} 非成对) 进行卷积运算获得模糊图像 x_{blur} , x_{real} 和 x_{blur} 将作为伪样本对用于训练去模糊网络 G_B 。模糊图像 y_{real} 经过 G_B 生成去模糊图像 y_{fake} 。该模糊图像和清晰图像 x_{real} 作为鉴别器 D 的输入,利用对抗学习训练 G_B 。与此同时,去模糊图像 y_{fake} 和模糊核做卷积后得到重模糊图像 y_{reblur} ,可以和 y_{real} 构成损失训练模糊核预测模块 G_A 。在模型测试阶段,只需要保留去模糊模块 G_B 对模糊图像进行去模糊操作。

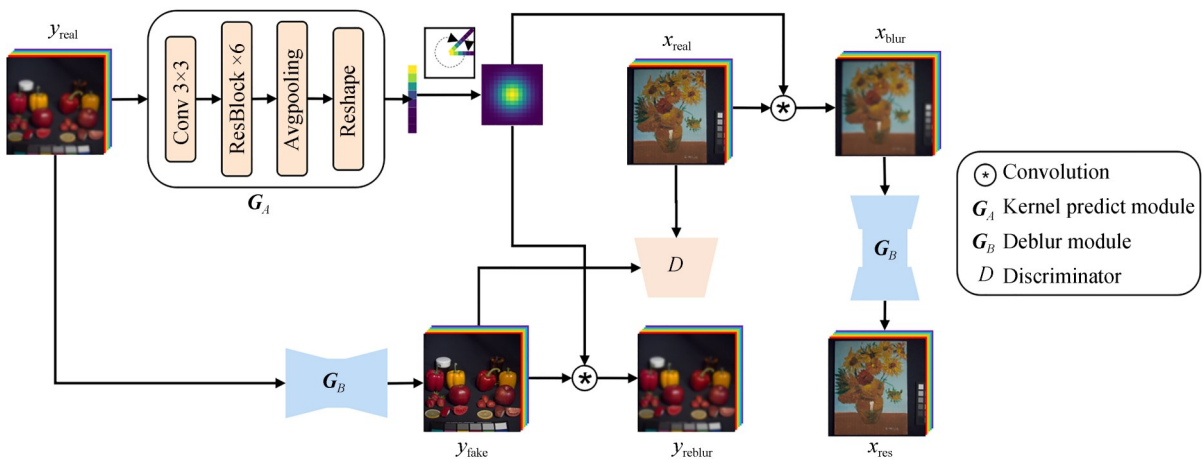


图 1 自监督物理约束非配对高光谱图像去模糊网络整体框架

Fig. 1 Overall network framework of physics-constrained self-supervised learning for unpaired hyperspectral image deblurring

2.1 去模糊模块

本文主要参考 Uformer 网络^[11]设计去模糊模块,如图 2 所示。Uformer 采用对称编码器-解码器架构,左侧编码器通过 LeWin Blocks 和下采样获得图像的多尺度语义信息,右侧解码器通过 LeWin Blocks 和上采样逐步恢复图像分辨率,编码器各阶段的特征图与解码器对应阶段的上采样特征图进行跳跃连接实现特征复用。LeWin Blocks 由若干个 LeWin Transformer 模块串联而成,该模块是由基于窗口的多头自注意力和局部增强前馈网络串联而成。基于窗口的多头自注意力在不重叠的局部窗口内执行自注意力,从而显著降低了计算成本,局部增强前馈网络在基于 Transformer 的结构中的前馈网络中加入了深度可分离卷积块,相比于传统 Transformer,提高了利用局部上下文的能力。

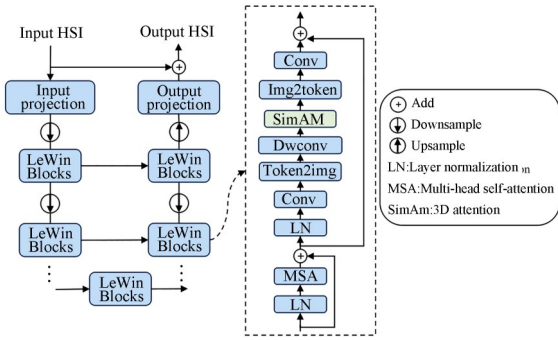


图 2 去模糊模块 G_B 网络结构

Fig. 2 Network structure of deblurring module G_B

高光谱图像包含数十乃至上百个连续光谱通道,容易造成通道的高度冗余和波段特异性噪声^[19]。传统的 Uformer 网络仅在空间上具备注意力机制,缺乏通道注意力,这将导致传统的 Uformer 网络难以有效应对高光谱图像的高度冗余通道和波段特异性噪声,从而影响模型的去模糊性能。本文将 SimAM 模块^[20]引入到前馈网络部分,利用其 3D 注意力模块实现精细化的通道和空间特征调控,从特征显著性的角度出发,差异化地评估所有特征位置(含光谱维度)的信息,引导模型聚焦于重要性高的特征,冗余特征则被相对弱化,从而提升网络在复杂退化条件下的特征利用效率与稳定性。该模块基于神经科学理论获得与神经元重要性相关的能量函数解析解,

在无需引入额外参数条件下实现 3D 注意力权值的快速求解:

$$e_t^* = \frac{4(\hat{\sigma}^2 + \lambda)}{(t - \hat{\mu})^2 + 2\hat{\sigma}^2 + 2\lambda}, \quad (1)$$

$$\tilde{X} = \text{Sigmoid}\left(\frac{1}{E}\right) \odot X. \quad (2)$$

式(1)和式(2)是 SimAM 模块计算 3D 注意力的核心步骤:输入 $X \in \mathbb{R}^{c \times m \times n}$, c, m, n 分别代表特征图通道数,长和宽。 t 是 X 中任意目标神经元。式(1)首先计算 t 所在通道所有神经元的均值 $\hat{\mu}$ 和方差 $\hat{\sigma}^2$, 然后利用能量函数闭式解计算每个神经元的最小能量值 ($\lambda = 10^{-4}$ 是正则化系数)。式(2)构造 $E \in \mathbb{R}^{c \times m \times n}$ 表示 X 中所有神经元的能量最小值,通过 $1/E$ 得到每个神经元的重要性,并用 Sigmoid 函数缩放得到 3D 注意力权值,最后将权值和输入 X 对应元素相乘得到输出 $\tilde{X} \in \mathbb{R}^{c \times m \times n}$ 。

2.2 模糊核预测模块 G_A

模糊核预测模块 G_A 主要基于 Resnet 架构,首先,使用 3×3 大小的卷积核以及 6 个残差模块进行特征提取,得到深层特征图。然后,通过池化层和变形得到向量 $l \in \mathbb{R}^{c \times m}$, 其中 c 代表通道数, m 代表向量长度,且满足 $m = (ks + 1)/2$, ks 为奇数,代表模糊核大小,其数值根据任务需要决定。

在散焦模糊中,常见的理想化模糊核模型包括各向同性的圆盘模糊核和高斯模糊核。基于这一特性,本文假设预测的散焦模糊核满足各向同性。

图 3 中给出了利用模糊向量生成 5×5 模糊核的例子。首先,通过 G_A 预测出 l 长度为 3 (图 3 中 l_0, l_{10}, l_{20}), 对 l 进行线性插值得到共 21 个值




图 3 模糊核生成示意图

Fig. 3 Blur kernel generation

(实际调整为 $m \times 20$), 然后根据核内每个位置到中心的距离与最大距离之比计算对应的下标 idx , 最后根据 idx 到左右两端整数插值点下标的距离分配权重进行加权。

所有通道上的点填充后将其数值缩放到每个通道上和为 1, 得到预测的模糊核 $K \in \mathbf{R}^{c \times ks \times ks}$ 。本文为每个通道都预测一个模糊核, 而不是所有通道共享一个模糊核, 精确匹配高光谱图像不同波段可能存在的不同模糊特性。

2.3 鉴别器

鉴别器 D 利用对抗学习促使 G_B 能够学习清晰图像的本质特征, 恢复出贴近清晰域的图像, 从而保障模型训练的有效性。训练过程中, D 学习区分生成的去模糊图像与真实清晰图像的差异, 并将判别误差反馈给生成器, 驱动其生成更贴合真实光谱-空间特征、更难被分辨的清晰图像, 提升去模糊效果真实性。鉴别器 D 的结构采用 PatchGan^[21], 以加强鉴别器对局部细节的关注。

2.4 损失函数

所提出去模糊框架的损失由判别器损失 \mathcal{L}_D 以及 G_A 和 G_B 的联合损失 \mathcal{L}_s 两大部分组成。判别器 D 采用最小二乘 Gan 来增强训练过程的稳定性(式(3))。最小二乘 Gan 将判别问题从“真/假”二分类转变为“拟合到特定目标值(真实数据标签为 1, 生成数据标签为 0)”。即使鉴别器能够很好地区分真假样本, 其对生成样本的惩罚仍然存在, 从而能为生成器提供持续且非饱和的梯度, 提高了训练过程的稳定性。

$$\mathcal{L}_D = E_{y \in y_{\text{real}}} \left[D(G_B(y))^2 \right] + E_{x \in x_{\text{real}}} \left[(D(x) - 1)^2 \right]. \quad (3)$$

G_A 和 G_B 的联合损失 \mathcal{L}_s 包含了模糊核预测模块 G_A 损失 \mathcal{L}_k 和去模糊模块 G_B 损失 \mathcal{L}_B 两部分:

$$\mathcal{L}_s = \mathcal{L}_k + \mathcal{L}_B, \quad (4)$$

其中: \mathcal{L}_k 利用重模糊图像 y_{reblur} 和输入模糊图像 y_{real} 之间构成的 L1 损失优化 G_A 的参数(式(5)); 而去模糊模块 G_B 的损失 \mathcal{L}_B 由 $\mathcal{L}_{\text{cycle}}$, \mathcal{L}_{sam} 和 \mathcal{L}_G 三部分组成:

$$\mathcal{L}_k = \lambda_k E_{y \in y_{\text{real}}} \|y - G_B(y) * G_A(y)\|_1, \quad (5)$$

$$\mathcal{L}_B = \lambda_1 \mathcal{L}_{\text{cycle}} + \lambda_2 \mathcal{L}_{\text{sam}} + \lambda_3 \mathcal{L}_G, \quad (6)$$

其中: $\lambda_k, \lambda_1, \lambda_2$ 和 λ_3 是权重系数。

$\mathcal{L}_{\text{cycle}}$ 代表恢复图像 $x_{\text{res}} = G_B(x_{\text{real}} * G_A(y_{\text{real}}))$ 和清晰图像 x_{real} 之间的 L1 范数损失:

$$\mathcal{L}_{\text{cycle}} = E_{x_1 \in x_{\text{real}}, x_2 \in x_{\text{res}}} \|x_1 - x_2\|_1. \quad (7)$$

\mathcal{L}_{sam} 为光谱角损失函数, 用于度量去模糊图像与清晰图像的光谱一致性:

$$\mathcal{L}_{\text{sam}} = E_{x_1 \in x_{\text{real}}, x_2 \in x_{\text{res}}} E_{p \in x_1, q \in x_2} \arccos \frac{p \cdot q}{\|p\| \times \|q\|}, \quad (8)$$

其中: $p, q \in R^c$ 分别是清晰图像和恢复图像上每个像素点上的光谱向量。

\mathcal{L}_G 损失是 Gan 损失, 用于度量去模糊图像和清晰图像在宏观内容方面的一致性:

$$\mathcal{L}_G = E_{y \in y_{\text{real}}} \left[(D(G_B(y)) - 1)^2 \right]. \quad (9)$$

训练过程中交替执行 \mathcal{L}_D 和 \mathcal{L}_s 的反向传播。 \mathcal{L}_s 进行反向传播时, 为了避免 G_A 和 G_B 的优化过程相互干扰, 在 \mathcal{L}_k 的反向传播过程中, 将去模糊模块 G_B 设为梯度冻结状态(仅参与前向计算, 不参与梯度回传); 在 \mathcal{L}_B 的反向传播过程中, 同样将模糊核预测模块 G_A 设为梯度冻结状态, 确保两损失各自的优化目标互不冲突。遵循 GAN 的训练过程, \mathcal{L}_G 中冻结了 D 的权重, 在 \mathcal{L}_D 中冻结了 G_B 的权重。

3 实验与结果分析

3.1 实验配置

本文在 PyTorch 深度学习框架中实现了所提出的方法。仿真实验和真实实验都采用了相同的参数配置, 初始学习率为 2×10^{-4} , 并随着 epoch 增加线性递减至 0, 优化器采用 Adam, batch size 为 16, 共迭代 150 个 epoch; 损失函数中的参数设置为: $\lambda_k = 2, \lambda_1 = 10, \lambda_2 = 0.1, \lambda_3 = 1$, 预测模糊核大小 $k = 15$ 。

3.2 仿真实验

3.2.1 仿真数据集构造

根据混合物光谱是其组分光谱线性加权(加权系数为各组分的浓度)这一假设^[22], 将真实采集的 A, B 两种物质的光谱按照一定浓度比例叠加生成高光谱图像数据集, 如图 4 所示。在构造高光谱图像数据集时, 考虑到实际物料混合过程中的浓度分布具有空间相关性和平滑性, 采用高斯随机场(Gaussian Random Field, GRF)采样生

成浓度分布^[23],其表达式为:

$$k(x_i, x_j) = \sigma_j^2 \exp\left(-\frac{1}{2l^2} \|x_i - x_j\|^2\right), \quad (10)$$

其中: $k(x_i, x_j)$ 表示二维平面上两点之间的浓度协方差, $\|x_i - x_j\|$ 是空间上两点之间的距离; σ_j 是浓度波动标准差,设置为0.05,0.10和0.15(如图5所示),以控制浓度分布的起伏程度,值越大代表均匀性越差, l 是长度尺度,代表浓度变化的平缓程度,取1.5,设置组分A的平均浓度为 $\mu = 0.6$ 。将 $k(x_i, x_j)$ 作为协方差, μ 作为均值采样生成浓度分布。

在采样生成组分A的浓度分布 C_A 后,B组分的浓度 C_B 为 $1 - C_A$,以满足各组分浓度和为1的约束。根据生成的浓度分布对两种物质的光谱曲线进行线性叠加,并添加均值为0,标准差为0.01的高斯噪声,以模拟实际测量中的仪器噪声、环境干扰等随机误差。最后得到大小




图4 两种物质的光谱曲线

Fig. 4 Spectral curves of two substances

为 64×64 ,波段数为85的混合物清晰高光谱合成图像。利用模糊核对合成的混合物清晰高光谱图像进行卷积操作,以构造模糊高光谱图像。




图5 不同均匀性样本的浓度分布等高图

Fig. 5 Contour map of concentration distribution of samples with different uniformity

选择高斯模糊核作为模糊核,该模糊核具有连续可微、各向同性的特性,能够拟合光学成像系统中的散焦模糊现象,是模拟图像模糊退化的经典模糊核。实验中,分别选取1.8,2.2和2.6三组标准差参数,对应生成轻度、中度和重度三种模糊等级的退化图像(3种不同模糊程度对浓度预测的影响大小见表2中Blur一行)。将模糊核的尺寸固定为15,该尺寸可充分覆盖所选标准差参数下高斯模糊的实际影响区域,同时避免因核尺寸过大引入冗余计算量。

按照上述方法生成300张清晰图像,其中

150张作为训练集中的清晰图像(3种均匀性各50张),剩余150张图像与3种模糊核组合得到训练集模糊图像450张。另外再生成30张清晰图像,经过模糊化处理后,得到90张模糊图像作为测试集样本。

3.2.2 评价方法

本文用峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)、结构相似性(Structural Similarity, SSIM)和光谱角(Spectral Angle Mapper, SAM)作为评价指标来评估模型的去模糊效果:

PSNR反映了信号与噪声之间的比例,计算

公式为:

$$PSNR = 10 \cdot \log_{10} \frac{MAX_1^2}{MSE}, \quad (11)$$

其中: MAX_1 是图像像素的最大可能值, 在归一化后为 1, MSE 是清晰图像和恢复图像的均方误差。

SSIM 用于衡量两幅图像在亮度、对比度和结构上的相似度, 计算公式为:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)}, \quad (12)$$

其中: x 和 y 分别代表清晰图像和恢复图像, μ_x 和 μ_y 分别是 x 和 y 的均值, σ_x 和 σ_y 分别是 x 和 y 的标准差, σ_{xy} 是 x 和 y 的协方差, C_1 和 C_2 是常数, 用于避免分母为 0 的情况, 取 $C_1 = 1 \times 10^{-4}$, $C_2 = 9 \times 10^{-4}$ 。

SAM 反映了恢复图像和真实图像之间光谱曲线的一致性, 计算公式为:

$$SAM(x, y) = E_{p \in x, q \in y} \arccos \frac{p \cdot q}{\|p\| \times \|q\|}, \quad (13)$$

其中: p 和 q 代表 x 和 y 每个像素上的光谱向量。

对于仿真数据集, 由于其浓度分布已知, 利用偏最小二乘回归 (Partial Least Squares Regression, PLSR) 构建浓度预测模型, 用于评价采用不同去模糊方法后, 浓度预测结果与其真实值的差异性。具体而言, 在训练集的清晰图像中随机选择 2 张图像训练 PLSR 模型, 并利用该 PLSR 模型对测试集去模糊图像的浓度值进行预测, 以图像去模糊后的浓度预测值和真实浓度之间的平均绝对误差作为评价指标。

3.2.3 实验结果对比与分析

本文选择了 4 种无监督去模糊方法作为对比, 分别为 CycleGAN^[24], 1Shot-MaxPol^[25], RGTV^[26] 和 BIRD^[27]。其中, CycleGAN 是无监督深度学习模型; 1Shot-MaxPol 和 RGTV 是传统的迭代优化方法, 具有稳定性、抗噪性和适配多模糊场景的特点, 凭借动态约束与强稳定性, 能精准应对图像去模糊的病态逆问题; BIRD 是依托扩散模型的强大生成能力, 把图像恢复中的逆问题转化为潜在优化任务来处理的图像恢复方法, 该方法在 CelebA 和 ImageNet 上针对盲图像去模糊任务取得了先进的结果。本文先通过主

成分分析 (Principal Component Analysis, PCA) 降维至 3 通道以利用预训练的扩散模型, 经 BIRD 去模糊后再进行 PCA 逆变换。

表 1 展示了测试集上不同方法的 PSNR、SSIM 和 SAM 评价指标。从表中可以看出, 所提方法相比于其他方法, 性能都有显著的提高, PSNR, SSIM 分别提高了 3.45%~15.9% 和 1.81%~18.7%, SAM 降低了 6.67%~39.1%。

表 1 不同方法在仿真数据集上的性能指标对比

Tab. 1 Comparison of performance of different methods on simulation dataset

Method	PSNR ↑	SSIM ↑	SAM ↓
CycleGAN	30.177	0.758	0.046
1Shot-MaxPol	32.845	0.869	0.039
RGTV	32.622	0.878	0.037
BIRD	33.803	0.884	0.030
Ours	34.970	0.900	0.028

注: ↑ indicates higher is better, ↓ indicates lower is better.

表 2 列出了不同方法去模糊后的 PLSR 浓度预测值和真实浓度之间的平均绝对误差 (模糊程度 1~3 分别对应轻度、中度和重度模糊)。

表 2 不同去模糊算法得到的浓度平均绝对误差

Tab. 2 Mean absolute error of concentration obtained by different deblurring methods

Method	Deblur degree		
	1	2	3
Blur	0.038 3	0.046 3	0.052 5
CycleGAN	0.043 4	0.049 3	0.054 5
1Shot-MaxPol	0.032 2	0.044 4	0.052 4
RGTV	0.031 8	0.036 9	0.048 6
BIRD	0.032 6	0.038 1	0.041 2
Ours	0.023 9	0.022 8	0.031 2

从表 2 中可以看出, 相比于模糊图像的浓度预测, 经过 CycleGAN 去模糊处理后的浓度预测结果反而进一步恶化。其原因在于 CycleGAN 的循环一致性约束侧重保持内容结构, 对去模糊所需的细节恢复和模糊核精准建模能力不足, 导致其预测浓度分布与真实值差异较大。1Shot-Max-

Pol 和 RGTV 能一定程度减小浓度预测误差,但效果有限,其原因在于这两个算法在高频细节的恢复效果上较差,梯度变化还原不足,从而导致了局部浓度预测不准。物料浓度的准确预测依赖于物料在特定波段下的吸收(关键波段),尽管 BIRD 去模糊性能指标(PSNR, SSIM, SAM)与本文方法最为接近,但由于缺乏波段注意力机制, BIRD 无法聚焦于关键特征波段的恢复,影响浓度预测的准确性。此外,由于 BIRD 需要迭代

优化,计算时间长,因此难以应用于实际生产。对比结果表明,本文所提出的方法在不同的模糊程度下恢复出的浓度都更接近真实浓度,为后续均匀性指标的计算提供了更加准确的数据支撑。

图 6 给出了某模糊图像经过不同去模糊处理后的浓度分布图。模糊后,浓度峰值向中心偏移,浓度梯度趋于平缓。相比于其他算法,所提出去模糊方法对浓度峰值和浓度梯度的还原最为准确,进一步验证了其有效性。

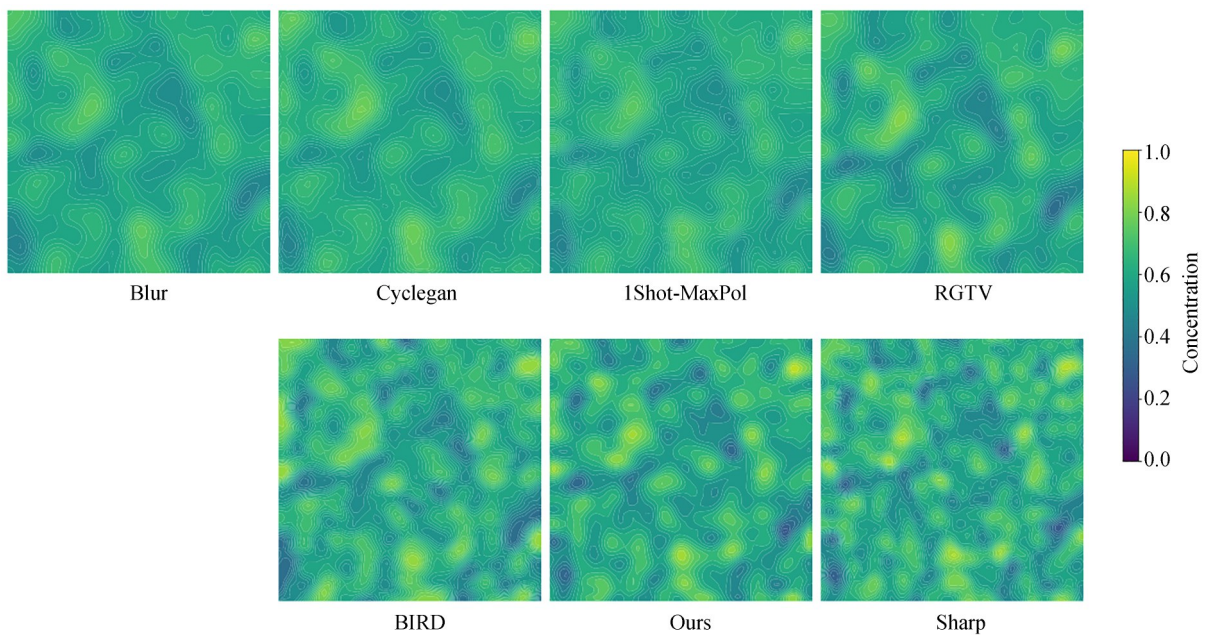


图 6 不同方法去模糊后浓度分布等高线图

Fig. 6 Contour map of concentration distribution after deblurring by different methods

3.3 消融实验

为了评估在 Uformer 中引入 SimAM 模块是否有效,以及预测模糊核的参数 k_s 设置对去模糊效果的影响,本文将预测模糊核的参数分别设置为 11, 15 和 19,对引入 SimAM 模块后的性能进行对比。

表 3 是消融实验的结果,从表 3 中可以看出, SimAM 能够有效地利用其 3D 注意力实现精细化的通道级特征调控, PSNR 和 SSIM 相较于没有加入时分别提高了 1.737 和 0.028, SAM 降低了 0.005。同时从表中可以看出,尽管预测模糊核参数 k_s 的选择对模型去模糊性能有一定的影响,但这一影响较小,表明所提出的方法对于预测模糊核参数的设定具有较好的稳

表 3 消融实验结果

Tab. 3 Ablation experiment results

SimAM	Kernel size			PSNR	SSIM	SAM
	11	15	19			
		✓		33.233	0.872	0.033
✓	✓			34.369	0.893	0.029
✓			✓	33.057	0.891	0.034
✓		✓		34.970	0.900	0.028

定性。

为了进一步对比 SimAM 模块对去模糊的影响,对某中度模糊图像在表 3 中条件 1, 4 下分别去模糊处理,并取两个像素点绘制光谱曲线(图 7

所示)。加入 SimAM 模块后,去模糊图像的光谱曲线与清晰图像的光谱曲线更为贴合,充分证明

SimAM 模块可有效提升高光谱图像的光谱特征恢复精度。

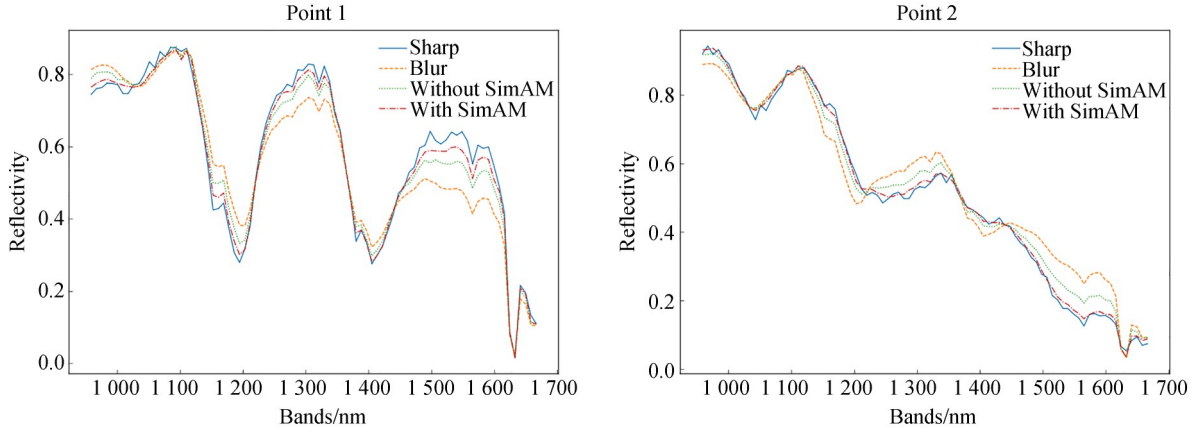


图 7 有无 SimAM 模块光谱曲线对比

Fig. 7 Comparison of spectral curves with and without SimAM module

3.4 真实实验

3.4.1 样本制备和数据采集

为了进一步验证所提出方法在实际应用中的表现,本文设计了一个有两种纯净物:端羟基聚丁二烯(Hydroxyl-terminated polybutadiene, HTPB)和硫酸铵混合搅拌的场景。按总质量 50 g,HTPB 和硫酸铵质量占比分别为 6:4,5:5 和 4:6 称量两种纯净物。将称量后的两种纯净物放入直径为 60 mm 培养皿中,用玻璃棒均速搅拌,以模拟实际生产的混合过程(图 8 所示)。




图 8 实验场景

Fig. 8 Experiment scene

利用推扫式近红外高光谱相机(型号: HIS-SWIR-1700 nm,产地:台湾五环光学)采集不同搅拌时间(1, 2, 3, 5, 7, 10 min)下的混合物高光谱数据。该相机的光谱响应为 900~1 700 nm,

光谱分辨率为 1.67 nm,光谱波段数为 512。在高光谱图像采集时,卤素灯光源功率设置为 50 W,曝光时间设置为 15 ms。为消除环境光的干扰,实验在暗箱中进行。实验共采集 3 种质量比、6 个搅拌时间下的清晰图像 18 张,以及代表三种模糊程度的高光谱模糊图像 54 张(通过调整相机焦距获得)。

对所有图像进行黑白板校正和归一化处理,并选取原始光谱的 984~1 689 nm 波段作为目标波段区间,以去除低信噪比波段的影响。为了在光谱曲线形状与特征基本不变的前提下减少计算量,以 5 个波段为步长进行均匀采样,得到 85 个波段的光谱数据。对预处理后的高光谱图像进行 64×64 的随机裁剪,共得到训练集图像 1 538 张(其中模糊图像 1 157 张,清晰图像 381 张)和测试集模糊图像 355 张。

3.4.2 评价方法

不同于仿真实验,HTPB 的流动特性导致无法获得与模糊图像相对应的清晰图像,因此无法用传统图像恢复的指标来评估模型的性能。为此,本文采用 KL 散度(Kullback-Leibler Divergence)和变异系数(Coefficient of Variation, CV)两个指标来评估算法性能^[4, 28]。

KL 散度是衡量两个分布之间的相似性的度量,其数值越小代表两个分布之间的相似性越

高。其计算公式为:

$$KL(P||Q) = \frac{1}{N} \sum_{x \in \chi} P(x) \log \left(\frac{P(x)}{Q(x)} \right), \quad (14)$$

其中: P, Q 分别代表清晰图像和模糊图像的分布, $\chi = \{1, 2, 3, \dots, m\}^n$, m 为变量的分箱数,取10; n 为随机变量个数,即光谱通道数; χ 表示多维随机变量的联合分箱空间, $N = m^n$ 是总联合分箱数。

由于高光谱通道数较多,直接计算KL散度时间复杂度高。考虑到高光谱通道间存在相关性和信息冗余,利用PCA提取光谱主成分以保留光谱主要特征。为了公平比较,避免因降维过程不同导致的分布偏差,随机选择50张训练集清晰图像训练PCA得到投影矩阵(此PCA模型的累计方差解释率达到97.5%,能有效保留原始光谱的主要信息),然后将其统一应用于所有方法得到的去模糊图像做预处理。在评估时,将高光谱图像上的像素投影到主元空间中,计算清晰图像和模糊图像,清晰图像和去模糊图像之间的KL散度。

变异系数CV是评价均匀性的常用指标。

本文利用HTPB和硫酸铵的标准光谱,基于非负最小二乘方法反演图像上每个像素点的硫酸铵浓度,并借助式(15)计算出图像的CV值:

$$CV = \frac{\sqrt{\frac{1}{N} \sum_{i=1}^N (R_i - \bar{R})^2}}{\bar{R}}, \quad (15)$$

其中: R_i 表示第*i*个像素的浓度, \bar{R} 为平均浓度, N 为像素总数。

3.4.3 实验结果分析

图9展示了各种方法在真实高光谱数据集上的去模糊效果伪彩图(场景1~3分别代表轻度、中度和重度模糊场景)。对于CycleGAN,由于缺乏“清晰→模糊”这一退化过程的物理约束,其模糊化生成器难以学习到真实的散焦退化模型,导致去模糊图像无法向真实清晰域对齐^[29],且在缺乏配对监督的情况下,生成器中的反卷积操作会产生伪影^[30],这种伪影在对抗训练中可能被误判为“清晰纹理”。1Shot-MaxPol、RGTV和BIRD难以恢复真实的细节。而所提出方法在不同模糊场景下均能展现出良好的效果,能够更好地还原细节且没有引入伪影。




图9 不同方法在实际采集数据集上的可视化结果

Fig. 9 Visualization results of different methods on actual collected datasets

表4给出了清晰图像与不同算法恢复图像的主元分布KL散度。由于CycleGAN侧重空间域整

体分布的对齐,缺乏对光谱维度的约束,不可避免地产生光谱失真,因此相比于模糊图像,经过

CycleGAN 去模糊化处理后 KL 散度反而加大;而 1Shot-MaxPol 与 RGTV 虽然能一定程度缩小恢复图像与清晰图像的分布差异,但在重度模糊场景下,光谱细节信息缺失严重,KL 散度较大;BIRD 在真实数据集上相较于传统方法并无优势。从数据分布的角度看,BIRD 中所用扩散模型的预训练数据集为自然图像,真实物料混合数据分布和自然图像有可能存在较大的域差异,导致泛化性能大幅下降,因此其 KL 散度较高。所提出的方法对 3 种不同程度模糊图像处理后,其 KL 散度均低于其他方法,表明所提出方法在去除模糊图像的同时,能够保留图像的光谱细节信息。

图 10 展示了 50% 浓度下的均匀性指标——CV 随时间变化的曲线。从图中可以看出,随着搅拌时间的延长,清晰图像的 CV 值逐渐下降并趋于稳定。由于 CycleGAN 去模糊效果微弱,导致其计算出的 CV 和模糊图像比较接近。1Shot-MaxPol 和 RGTV 在轻度模糊场景下存在过度锐

表 4 清晰图像和不同方法去模糊图像主元的 KL 散度
Tab. 4 KL divergence of sharp image and different methods for deblurring image principal components

Method	Scene 1	Scene 2	Scene 3
Blur	3.858	5.293	6.848
CycleGAN	7.632	8.059	8.535
1Shot-MaxPol	2.621	4.332	6.010
RGTV	2.092	3.712	5.525
BIRD	4.113	4.402	5.774
Ours	1.814	2.320	2.052

化的情况,导致其 CV 值偏高;而在重度模糊场景中去模糊不彻底,细节恢复不到位,导致其 CV 值偏小。BIRD 恢复图像失真,其 CV 值整体偏小。而本文所提出方法的去模糊结果,其均匀性指标变化规律与清晰图像基本一致,且数值上更为接近,表明所提出方法能够适应不同程度的模糊,从而有效地处理混合均匀性检测中的图像模糊问题。




图 10 不同方法去模糊后的 CV 值随时间变化曲线

Fig. 10 Time varying curves of CV after deblurring using different methods

4 结 论

为了解决高光谱成像检测混合均匀性中存在的散焦模糊问题,本文提出了一种自监督物理约束非配对高光谱图像去模糊算法(PC-SSL-HSI Deblurring)。该算法利用融合了 SimAM 模块的 Uformer 架构作为去模糊网络,并采用对抗学习促使去模糊结果与清晰图像特征对齐;同时,设计了一个基于模糊退化模型的模糊核预测模块用于构造伪样本对,利用自监督学习引导去模糊网络聚焦于高光谱图像的局部细节恢复。

在仿真数据集上,PSNR 达到 34.970,SSIM 达到 0.900,证明了其出色的图像细节恢复能力和伪影抑制效果。在真实采集的物料混合均匀性评估实验中,本方法在 KL 散度和 CV 指标上均优于对比算法,显著提升了混合均匀性评估的准确性。PC-SSL-HSI Deblurring 算法充分展现了其良好的工程应用潜力,为无成对样本下的深度学习去模糊问题提供了一种有效且实用的新技术路径,为工业生产中基于视觉的在线质量监控与工艺优化提供了可靠的技术支持。

本文假设模糊核满足各向同性,此假设可

有效简化模糊核的建模与预测过程,提升模块的计算效率。但该假设在真实复杂成像场景下存在一定局限性:实际成像存在像差串扰(如彗差、像散、场曲等)和光学系统非均匀畸变等,可能使实际模糊呈现各向异性特征,导致基于各向同性假设的模糊核预测结果与真实模糊核存在差异,影响模型性能。后续工作中可以考虑增加模糊核的自由度,增强其对非各向同性散焦模糊的表征能力,优化模块在实际复杂成像

工况下的性能。

作者贡献声明:

钱斐:方法论,实验设计,模型改进,论文构思与撰写;

胡凡:数据采集与分析,结果可视化;

苟晓东:数据采集与分析;

朱启兵:方法论,论文写作与审阅,项目分析与

参考文献:

- [1] 吴晓东,刘畅,李俊,等. 基于高光谱检测的烟丝加香均匀性表征方法[J]. 轻工学报, 2024, 39(5): 95-101.
WU X D, LIU CH, LI J, *et al.* Characterizing flavoring uniformity in tobacco based on hyperspectral detection[J]. *Journal of Light Industry*, 2024, 39(5): 95-101. (in Chinese)
- [2] 石吉勇,胡雪桃,朱瑶迪,等. 高光谱图像技术定量检测香醋醋醅水分分布均匀性[J]. 中国食品学报, 2018, 18(2): 250-255.
SHI J Y, HU X T, ZHU Y D, *et al.* Quantitative detection of homogeneity of moisture content distribution in vinegar culture by hyperspectral imaging technique[J]. *Journal of Chinese Institute of Food Science and Technology*, 2018, 18(2): 250-255. (in Chinese)
- [3] 白玉莹,王石,张博涵,等. MicroNIR技术在配方奶粉干混均匀性上的应用[J]. 现代食品科技, 2025, 41(7): 20-28.
BAI Y Y, WANG SH, ZHANG B H, *et al.* Application of MicroNIR technology in evaluating the homogeneity of dry-mixed formula powder[J]. *Modern Food Science and Technology*, 2025, 41(7): 20-28. (in Chinese)
- [4] 黄子淇,吴玉章,刘彝,等. 近红外技术在含能材料领域的应用研究进展[J]. 兵器装备工程学报, 2022, 43(7): 58-66, 77.
HUANG Z Q, WU Y ZH, LIU B, *et al.* Development of near infrared technology application research in the field of energetic materials[J]. *Journal of Ordnance Equipment Engineering*, 2022, 43(7): 58-66, 77. (in Chinese)
- [5] 张蕾,乔凯,吴银花,等. 利用光谱解混合的目标检测[J]. 光学精密工程, 2023, 31(21): 3156-3166.
ZHANG L, QIAO K, WU Y H, *et al.* Target detection using spectral unmixing[J]. *Optics and Precision Engineering*, 2023, 31(21): 3156-3166. (in Chinese)
- [6] 刘敬,李洋,刘逸. 基于分数阶微分的高光谱图像特征提取与分类[J]. 光学精密工程, 2023, 31(21): 3221-3236.
LIU J, LI Y, LIU Y. Hyperspectral images feature extraction and classification based on fractional differentiation [J]. *Optics and Precision Engineering*, 2023, 31(21): 3221-3236. (in Chinese)
- [7] FANG H Z, LUO C N, ZHOU G, *et al.* Hyperspectral image deconvolution with a spectral-spatial total variation regularization[J]. *Canadian Journal of Remote Sensing*, 2017, 43(4): 384-395.
- [8] GUO L, ZHAO X L, GU X M, *et al.* Three-dimensional fractional total variation regularized tensor optimized model for image deblurring[J]. *Applied Mathematics and Computation*, 2021, 404: 126224.
- [9] REN D W, ZHANG K, WANG Q L, *et al.* Neural blind deconvolution using deep priors[C]. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 13-19, 2020, Seattle, WA, USA. IEEE, 2020: 3338-3347.
- [10] CHEN L Y, CHU X J, ZHANG X Y, *et al.* Simple baselines for Image restoration [C]. *Computer Vision-ECCV 2022*. Cham: Springer, 2022: 17-33.
- [11] WANG Z D, CUN X D, BAO J M, *et al.* Uformer: a general U-shaped transformer for image restoration[C]. 2022 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 18-24, 2022, New Orleans, LA, USA.

- IEEE, 2022: 17662-17672.
- [12] ZAMIR S W, ARORA A, KHAN S, *et al.* Restormer: efficient transformer for high-resolution image restoration [C]. *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 18-24, 2022, New Orleans, LA, USA. IEEE, 2022: 5718-5729.
- [13] GENG P F, ZHANG M, LI X F. Hyperspectral image deblurring based on joint utilization of spatial-spectral information [C]. *2023 16th International Symposium on Computational Intelligence and Design (ISCID)*. December 16-17, 2023, Hangzhou, China. IEEE, 2024: 156-160.
- [14] WANG X H, CHEN J, RICHARD C, *et al.* Learning spectral-spatial prior via 3DDNCNN for hyperspectral image deconvolution [C]. *ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. May 4-8, 2020, Barcelona, Spain. IEEE, 2020: 2403-2407.
- [15] XIE H Y, YANG M Y, HUANG H S, *et al.* Hyperspectral image reconstruction based on blur-kernel-prior and spatial-spectral attention [J]. *Remote Sensing*, 2025, 17(8): 1401.
- [16] ZHU J Y, PARK T, ISOLA P, *et al.* Unpaired image-to-image translation using cycle-consistent adversarial networks [C]. *2017 IEEE International Conference on Computer Vision (ICCV)*. October 22-29, 2017, Venice, Italy. IEEE, 2017: 2242-2251.
- [17] LU B Y, CHEN J C, CHELLAPPA R. Unsupervised domain-specific deblurring via disentangled representations [C]. *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 15-20, 2019, Long Beach, CA, USA. IEEE, 2020: 10217-10226.
- [18] TANG X L, ZHAO X L, LIU J, *et al.* Uncertainty-aware unsupervised image deblurring with deep residual prior [C]. *2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 17-24, 2023, Vancouver, BC, Canada. IEEE, 2023: 9883-9892.
- [19] LI J H, DONG X Y, HE W, *et al.* Wavelength- and depth-aware deep image prior for blind hyperspectral imagery deblurring with coarse depth guidance [C]. *2025 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)*. February 26-March 6, 2025, Tucson, AZ, USA. IEEE, 2025: 3162-3171.
- [20] YANG L X, ZHANG R Y, LI L D, *et al.* SimAM: a simple, parameter-free attention module for convolutional neural networks [C]. *International Conference on Machine Learning*, 2021.
- [21] ISOLA P, ZHU J Y, ZHOU T H, *et al.* Image-to-image translation with conditional adversarial networks [C]. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. July 21-26, 2017, Honolulu, HI, USA. IEEE, 2017: 5967-5976.
- [22] MAYERHÖFER T G, POPP J. Beyond beer's law: spectral mixing rules [J]. *Applied Spectroscopy*, 2020, 74(10): 1287-1294.
- [23] LIU Y, LI J F, SUN S Y, *et al.* Advances in Gaussian random field generation: a review [J]. *Computational Geosciences*, 2019, 23(5): 1011-1047.
- [24] LIM S, PARK H, LEE S E, *et al.* CycleGAN with a blur kernel for deconvolution microscopy: optimal transport geometry [J]. *IEEE Transactions on Computational Imaging*, 2020, 6: 1127-1138.
- [25] HOSSEINI M S, PLATANIOTIS K N. Convolutional deblurring for natural imaging [J]. *IEEE Transactions on Image Processing*, 2020, 29: 250-264.
- [26] BAI Y C, CHEUNG G, LIU X M, *et al.* Graph-based blind image deblurring from a single photograph [J]. *IEEE Transactions on Image Processing*, 2019, 28(3): 1404-1418.
- [27] CHIHAOUI H, FAVARO P, LEMKHENTER A. Blind image restoration via fast diffusion inversion [C]. *Advances in Neural Information Processing Systems 37*. December 10-15, 2024. Vancouver, BC, Canada. *Neural Information Processing Systems Foundation, Inc. (NeurIPS)*, 2024: 34513-34532.
- [28] OTSUKA M, YAMANE I. Prediction of tablet properties based on near infrared spectra of raw mixed powders by chemometrics: Scale-up factor of blending and tableting processes [J]. *Journal of Pharmaceutical Sciences*, 2009, 98(11): 4296-4305.
- [29] CHEN Y, LIN H P, ZHANG W, *et al.* ICycleGAN: Improved cycle generative adversarial net-

works for liver medical image generation[J]. *Bio-medical Signal Processing and Control*, 2024, 92: 106100.

[30] ODENA A, DUMOULIN V, OLAH C. Deconvolution and checkerboard artifacts [J]. *Distill*, 2016, 1(10): e3.

作者简介:



钱 斐(2002—),男,江苏常州人,硕士研究生,2024年于江南大学获得学士学位,主要从事光学检测技术、图谱智能解析的研究。E-mail: 2622874252@qq.com

通讯作者:



朱启兵(1973—),男,安徽合肥人,教授,博士生导师,2006年于东北大学获得博士学位,主要从事传感与检测技术、信息感知与智能处理、物联网技术等领域的研究。E-mail: zhuqib@163.com