

文章编号:1007-2780(XXXX)XX-0001-12

基于扩散模型的多时相遥感影像的 相对辐射归一化

宋丽瑶¹, 刘纯焱¹, 李海巍^{2*}

(1. 西安工业大学 计算机科学与工程学院, 陕西 西安 710021;

2. 中国科学院 西安光学精密机械研究所, 陕西 西安 710119)

摘要: 相对辐射归一化是多时相遥感分析的基础技术,但传统方法在处理非线性畸变、异常值干扰及异质地表覆盖条件时往往存在局限性。针对这些挑战,本文提出了一种基于扩散的概率框架,将辐射不一致性建模为确定性残差与随机扰动的组合。在该框架中,前向过程通过结构化噪声与随机噪声的叠加模拟辐射畸变的多源特性,而后向过程则依托双目标变分优化策略,在重建辐射一致性的同时保留原始影像的细节特征,从而在数学层面上实现了对复杂辐射畸变的精细化建模。其核心设计是空间-光谱注意力网络,该网络通过融合空间与光谱双注意力模块,在特征提取过程中动态强化关键波段响应与局部纹理结构,实现对跨波段依赖关系和多尺度空间上下文的高效捕获。为进一步提升模型在复杂场景下的适应能力,研究设计了基于结构相似性指数的预处理策略,通过自动筛选稳定伪不变区域引导模型训练,有效降低地物变化带来的干扰,增强训练样本的代表性与模型收敛的稳定性。基于多时相哨兵2号数据集的综合实验表明,所提出的方法在定量评价指标上持续优于现有对比方法,不仅具备更高的辐射校正精度和光谱保真度,还在植被指数一致性和纹理细节保留方面展现出显著优势。综上,该扩散驱动网络为大规模遥感影像相对辐射归一化提供了一种实践适应性的解决方案,未来可进一步拓展至多传感器融合与时间序列分析等应用场景。

关键词: 相对辐射归一化; 扩散模型; 注意力机制; 深度学习

中图分类号: TP751 **文献标识码:** A **doi:** 10.37188/CJLCD.2026-0028 **CSTR:** 32172.14.CJLCD.2026-0028

收稿日期: 2026-03-06; **修订日期:** 2026-04-13.

基金项目: 2024年省级大学生创新计划项目(No.S202410702086); 中国国家重点研发计划(No.2022YFF1300201); 陕西省教育厅一般专项科研项目(No.24JK0481); 陕西省自然科学基金(No.2025JC-YBQN-366, No.2025JC-YBMS-256); 陕西省光学遥感与智能信息处理重点实验室开放研究基金(No.KF20250402); 西安市自然科学基金项目-面上项目(No.2025JH-ZRXX-0150)

Supported by 2024 Provincial-Level Approval of College Students' Innovation Program Project (No. S202410702086), National Key Research and Development Program of China (No.2022YFF1300201), General Special Scientific Research Program Project of the Shaanxi Provincial Department of Education (No. 24JK0481) and the Natural Science Foundation of Shaanxi Province (No. 2025JC-YBQN-366, No.2025JC-YBMS-256), the Open Research Fund of Shaanxi Key Laboratory of Optical Remote Sensing and Intelligent Information Processing (No.KF20250402), Xi'an Natural Science Foundation Project - General Project (No.2025JH-ZRXX-0150)

*通信联系人, E-mail: lihawei@opt.ac.cn

Diffusion-based relative radiometric normalization for multi-temporal remote sensing imagery

SONG Liyao¹, LIU Chunyan¹, LI Haiwei^{2*}

(1. School of Computer Science and Engineering, Xi'an Technological University, Xi'an 710021, China;
2. Xi'an Institute of Optics and Precision Mechanics, Chinese Academy of Sciences, Xi'an 710119, China)

Abstract: Relative radiometric normalization is a fundamental technique in multi-temporal remote sensing analysis, yet traditional methods often face limitations when dealing with nonlinear distortions, outlier interference, and heterogeneous land-cover conditions. To address these challenges, this paper proposes a diffusion-based probabilistic framework that models radiometric inconsistency as a combination of deterministic residuals and stochastic perturbations. Within this framework, the forward process simulates the multi-source characteristics of radiometric distortions through the superposition of structured and random noise, while the reverse process relies on a dual-objective variational optimization strategy to reconstruct radiometric consistency while preserving the detailed features of the original imagery, thereby achieving refined modeling of complex radiometric distortions at the mathematical level. Its core design is a spatial-spectral attention network, which integrates spatial and spectral attention modules to dynamically enhance key spectral band responses and local texture structures during feature extraction, enabling efficient capture of cross-band dependencies and multi-scale spatial context. To further improve the model's adaptability in complex scenes, a preprocessing strategy based on the structural similarity index (SSIM) is designed. By automatically selecting stable pseudo-invariant regions to guide model training, it effectively reduces interference from land-cover changes and enhances the representativeness of training samples and the stability of model convergence. Comprehensive experiments on multi-temporal Sentinel-2 datasets demonstrate that the proposed method consistently outperforms existing comparative approaches in quantitative evaluation metrics. It not only achieves higher radiometric correction accuracy and spectral fidelity but also exhibits significant advantages in vegetation index consistency and texture detail preservation. In summary, this diffusion-driven network provides a practically adaptable solution for large-scale relative radiometric normalization of remote sensing imagery and can be further extended to applications such as multi-sensor fusion and time series analysis in the future.

Key words: relative radiometric normalization; diffusion model; attention mechanism; deep learning

1 引 言

随着先进光学成像系统与对地观测技术的快速发展,亚米级高分辨率遥感影像已广泛应用于城市规划、灾害评估及生态监测等领域^[1-3]。相对辐射归一化(Relative Radiometric Normalization, RRN)作为其中关键的预处理步骤,旨在消除或减弱多时相影像间因大气条件、光照变化及传感器差异等因素引起的辐射不一致性,为后续

的变化检测、时间序列分析等量化应用提供辐射基准^[4-6]。

近年来,结合统计特征与机器学习的RRN方法已成为研究主流^[7-9]。尽管基于伪不变特征(Pseudo-Invariant Features, PIF)选择、多元变化检测(Multivariate Alteration Detection, MAD)及其迭代加权变体(Iteratively Reweighted Multivariate Alteration Detection, IRMAD)等方法在自动化程度上取得了显著进展,但仍面临两大瓶颈:首先是非线性畸变下的建模能力不足。现有

方法多基于线性回归或全局单调性假设,难以有效处理真实场景中由复杂大气和物候变化引起的非线性辐射差异,导致归一化精度受限^[10-11]。其次是特征耦合与异常值干扰问题。传统方法依赖人工设计的统计特征或经验阈值,难以在辐射校正过程中有效分离系统性辐射偏差与地物真实变化,且在异质地表或存在噪声时易受异常值影响,造成光谱失真或细节丢失^[12-18]。

针对上述问题,本文提出了一种基于扩散驱动的相对辐射归一化网络。本文的主要工作如下:利用结构相似性指数(Structural Similarity Index, SSIM)构建稳健的预处理策略,自动筛选稳定区域用于训练;设计空间-光谱注意力模块,通过双注意力机制捕获跨波段依赖与多尺度空间上下文;引入扩散模型将辐射差异建模为确定性残差与随机扰动的组合,并通过迭代精炼过程恢复辐射一致性。

本文的创新点主要体现在三个方面:(1)提出了一种辐射畸变分解式扩散概率框架,区别于已有扩散模型直接生成目标影像的做法;(2)设计了面向遥感影像多波段特性的空间-光谱双注意力网络,实现了光谱保真与空间结构保持的联合优化;(3)引入了基于SSIM的自适应训练样本筛选策略,克服了传统PIF方法对经验参数的依赖。实验证明,该方法在多时相哨兵2号数据集上均优于当前主流方法。

2 预备知识

2.1 相对辐射归一化映射

若 x 与 y 表示同一地物,仅因大气和光照条件影响存在差异,则二者关系可描述为:

$$y = f(x) + \epsilon, \quad (1)$$

其中, f 表示相对辐射归一化的映射函数。

2.2 扩散模型

扩散模型是一类概率生成模型,旨在捕获数据随时间演化的内在动态过程^[17, 19, 32, 33]。凭借其强大的生成能力,扩散模型在图像生成与复原等各类任务中受到了广泛关注^[20, 34]。典型的扩散过程包含 T 步的前向过程与 T 步的反向过程。前向过程从清晰图像开始,逐步添加噪声至 T 步;反向过程则沿相反方向操作。给定噪声调度

器 $\{\bar{\alpha}_t\}_{t=1}^T$ 和清晰数据 x_0 , 通过迭代 t 次向 x_0 添加高斯噪声可得:

$$x_t = \sqrt{\bar{\alpha}_t} x_0 + \left(\sqrt{1 - \bar{\alpha}_t} \right) \epsilon, \epsilon \sim \mathcal{N}(0, I). \quad (2)$$

训练扩散模型 ϵ_θ 以预测噪声:

$$\epsilon_\theta(x_t, t) \approx \epsilon = \frac{x_t - \sqrt{\bar{\alpha}_t} x_0}{\sqrt{1 - \bar{\alpha}_t}}. \quad (3)$$

反向过程从随机噪声开始,经过 T 步逐步精炼样本。近期研究提出了众多加速扩散模型采样的方法,其中典型的是去噪扩散隐式模型^[21-22], 其将前向过程建模为非马尔可夫过程。该模型按如下方式预测起始点:

$$\hat{x}_0 = \frac{x_t - \left(\sqrt{1 - \bar{\alpha}_t} \right) \epsilon_\theta(x_t, t)}{\sqrt{\bar{\alpha}_t}}. \quad (4)$$

进而采样 x_{t-1} :

$$x_{t-1} = \sqrt{\bar{\alpha}_{t-1}} \hat{x}_0 + \left(\sqrt{1 - \bar{\alpha}_{t-1}} \right) \epsilon_\theta. \quad (5)$$

3 研究方法

相对辐射归一化过程可视为两幅影像间伴随噪声添加的退化过程。在扩散模型中,单步前向过程可表示为:

$$x_t = x_{t-1} + x'_{\text{residual}}, \quad (6)$$

其中, x'_{residual} 表示从状态 x_{t-1} 到状态 x_t 的组合残差与随机噪声扩散项,其分布为 $x'_{\text{residual}} \sim \mathcal{N}(\gamma_t x_{\text{residual}} | \delta_t^2 I)$ 。此处, $x_{\text{residual}} = x_{in} - x_0$ 表示输入影像与参考影像之间的系统性辐射差异。系数序列 $\{\gamma_t\}_{t=1}^T$ 与 $\{\delta_t\}_{t=1}^T$ 是预定义的独立调度系数,用于控制每一步 t 中确定性残差与随机噪声成分的注入。

$$\begin{aligned} x_t &= x_{t-1} + \gamma_t x_{\text{residual}} + \delta_t \epsilon_{t-1}^{\text{noise}} = \\ &= x_{t-2} + (\gamma_{t-1} + \gamma_t) x_{\text{residual}} + \\ &\quad \sqrt{\delta_{t-1}^2 + \delta_t^2} \epsilon_{t-2}^{\text{noise}} = \\ &\dots = x_0 + \gamma_t x_{\text{residual}} + \delta_t \epsilon_{\text{noise}}, \end{aligned} \quad (7)$$

其中, $\epsilon_{t-1}^{\text{noise}} \sim \mathcal{N}(0, I)$, $\gamma_t = \sum_{i=1}^t \gamma_i$ 且 $\delta_t =$

$\sqrt{\sum_{i=1}^t \delta_i^2}$ 。当 $t=T$ 时, $\gamma_T=1$ 且 $x_T=x_{in} + \delta_T \epsilon_{\text{noise}}$ 。 δ_T 可控制噪声扰动的强度。前向过程中的联合概率分布可定义为:

$$q(x_{1:T} | x_0, x_{\text{residual}}) := \prod_{t=1}^T q(x_t | x_{t-1}, x_{\text{residual}}), \quad (8)$$

$$q(x_t | x_{t-1}, x_{\text{residual}}) := \mathcal{N}(x_t; x_{t-1} + \gamma_t x_{\text{residual}}, \delta_t^2 I). \quad (9)$$

在前向过程中,残差 x_{residual} 与噪声 ϵ_{noise} 被逐步添加到 x_0 中以合成 x_t ; 而反向过程则需从 x_t 估计所添加的残差与噪声。残差网络 $x_{\text{residual}}^{\theta}(x_t, t, x_{in})$ 与噪声网络 $\epsilon_{\text{noise}}^{\theta}(x_t, t, x_{in})$ 可分别预测 x_{residual} 与 ϵ_{noise} 。根据上述方程,影像 x_t 可用 x_0 、 x_{residual} 与 ϵ_{noise} 表示如下: $x_t = x_{in} + (\gamma_t - 1)x_{\text{residual}} + \delta_t \epsilon_{\text{noise}}$ 。若已知 x_0^{θ} 与 x_{residual} , 则相对辐射归一化过程定义为:

$$p_{\theta}(x_{t-1} | x_t) := q_{\zeta}(x_{t-1} | x_t, x_0^{\theta}, x_{\text{residual}}^{\theta}), \quad (10)$$

$$q_{\zeta}(x_{t-1} | x_t, x_0, x_{\text{residual}}) = \mathcal{N} \left(x_{t-1}; x_0 + \gamma_{t-1} x_{\text{residual}} + \sqrt{\delta_{t-1}^2 - \zeta_t^2} \cdot \frac{x_t - \left(x_0 + \gamma_t x_{\text{residual}} \right)}{\delta_t}, \zeta_t^2 I \right), \quad (11)$$

其中, $\zeta_t^2 = \eta \delta_t^2 \delta_{t-1}^2 / \delta_t^2$, η 是控制生成过程的因子。我们通过联合残差信息与噪声执行相对辐射归一化,并训练空间-光谱注意力网络。训练过程中,前向扩散的每一步均添加新的随机高斯噪声。

实验采用专为相对辐射归一化设计的深度架构进行噪声与特征预测(图1(a))。该架构基于深度网络构建,融入双注意力机制与特征学习策略,采用编码器-解码器结构,通过跳跃连接实现编码器与解码器对应层级的特征融合,可有效缓解深层网络训练中的梯度消失问题,同时保留低层细节特征与高层语义特征的协同表达。

该架构的输入为扩散过程中的中间态影像

x_t 、扩散时间步 t 的嵌入向量以及待校正影像 x_{in} , 输入特征维度为 $[B, C, H, W]$ (其中 B 为批次大小, C 为光谱波段数, H 、 W 分别为影像高度与宽度)。编码器部分由4个特征提取阶段组成,每个阶段均集成一个如图1(d)所示的基础模块,该模块由组归一化(Group Normalization, GN)、SiLU激活函数及 3×3 卷积层构成;组归一化将特征图按通道分组进行归一化处理,避免单一样本归一化带来的噪声干扰,提升模型稳定性;SiLU激活函数通过非线性变换增强特征表达能力,缓解梯度饱和问题; 3×3 卷积层用于提取局部特征,同时将特征通道维度逐步提升,实现特征的深层挖掘。

该设计的核心在于编码器与解码器路径中分别嵌入专用的光谱注意力模块(Spectral Attention Module, SAM)(图1(b))与空间注意力模块(Spatial Attention Module, SPA)(图1(c)),二者协同作用实现跨波段依赖与多尺度空间上下文的高效捕获,具体实现方式如下:

光谱注意力模块(图1(b))针对遥感影像多波段的特性设计,旨在强化关键波段响应、抑制冗余波段干扰,具体实现流程为:首先对编码器输出的特征图进行全局平均池化(Global Average Pooling, GAP),将每个通道的特征压缩为 1×1 的特征向量,消除空间维度影响,得到维度为 $[B, C, 1, 1]$ 的通道特征;随后将该特征输入两个全连接层(Fully Connected Layer, FC),中间层采用SiLU激活函数进行非线性变换,输出维度与输入通道数保持一致;最后通过Sigmoid激活函数生成通道维度的注意力权重(维度为 $[B, C, 1, 1]$),将该权重与原始特征图进行逐通道相乘,完成对不同光谱波段的自适应重标定,增强关键波段(如植被敏感波段、水体敏感波段)的特征表示能力,特征维度在经过该模块后保持不变。

空间注意力模块(图1(c))聚焦于影像局部纹理与全局空间结构的协同建模,解决遥感影像中异质地表覆盖区域的特征耦合问题,具体实现流程为:首先对编码器输出的特征图进行层归一化(Layer Normalization, LN),标准化特征分布以提升训练稳定性;随后采用缩放点积自注意力机制,将特征图转换为查询(Query, Q)、键(Key,

K)、值(Value, V)三个向量,通过Q与K的点积运算计算像素间的空间依赖关系,经过Softmax激活函数得到空间注意力权重矩阵(维度为 $[B, H \times W, H \times W]$);最后将注意力权重矩阵与V向量进行矩阵乘法,重构得到包含长距离空间依赖的特征图,再通过残差连接与原始特征图融合,确保特征不丢失,特征维度仍保持 $[B, C, H, W]$ 不变。

解码器部分与编码器呈对称结构,同样包含4个特征恢复阶段,每个阶段也集成图1(d)所示的基础模块,通过转置卷积将特征通道维度逐步降维(从512维依次降至256维、128维、64维、C维),同时恢复影像的空间分辨率,最终输出与输入尺寸一致的辐射残差预测图与噪声预测图。

此外,扩散时间步 t 采用正弦编码进行嵌入,将一维时间步转换为高维特征向量(维度为 $[B, 128]$),并通过多层感知器进行特征变换,所得的条件向量通过特征级线性调制集成到每个基础模块中,实现时间依赖动态的有效建模,使模型能够自适应不同扩散阶段的辐射畸变特性。各模块之间通过残差连接与特征融合,形成完整的特征传递链路,确保梯度稳定传播与高效特征变换,为基于扩散的RRN框架中复杂的辐射不一致性反演过程提供了强大而稳健的基础支撑。




图1 空间-光谱注意力网络架构示意图

Fig. 1 Overall architecture of spatial-spectral attention network

4 实验与结果

4.1 数据集描述

为验证所提相对辐射归一化方法的有效性,本研究收集了覆盖中国多个地理区域的八对配准后的双时相哨兵2号影像,涵盖水体、城市区域、农业用地及植被等多种地表覆盖类型。每景

影像覆盖范围达 $10\,944 \times 10\,944$ 像素或 $10\,980 \times 10\,980$ 像素的高分辨率区域,所有影像均经过预处理以确保严格的几何与辐射一致性,处理过程中舍弃了卷云波段(第10波段),并采用最近邻重采样方法保持原始像素值。

数据对1包含中国新疆西部地区的哨兵2B MSI L1C级影像,分别获取于2024年7月20日与30日,云量极少,包含13个光谱波段(分辨率包括10米、20米和60米),处理时舍弃卷云波段,并使用SNAP软件中的Sen2Res模型将低分辨率波段增强至10米。数据对2采用宁夏与内蒙古地区的哨兵2B L1C级产品,获取时间为2024年5月5日与7月4日,待校正影像云量较高,参考影像存在轻微积雪覆盖,采用相同流程处理。数据对3包含新疆西部地区的哨兵2B L1C级影像,获取时间为2023年11月2日与2024年7月29日,云量适中且无明显积雪,进行相同的分辨率增强处理。数据对4覆盖内蒙古-甘肃交界区域,影像获取于2023年10月21日与2024年7月17日,特点为完全无云且积雪极少,处理为统一的10米分辨率。数据对5来自上海地区,获取时间为2023年10月17日与2024年8月2日,待校正影像云量极低,参考影像云量较高,无积雪,采用标准预处理流程。数据对6由蒙古-华北边境地区的哨兵2 L2A级产品构成,待校正影像为2023年7月29日的哨兵2A影像,参考影像为2024年8月7日的哨兵2B影像,云量较低且近乎无雪,所有波段均重采样至10米。数据对7涉及中蒙边境地区的哨兵2A L2A级影像,获取于2023年7月19日与2024年7月23日,云量和积雪覆盖均极低,处理至10米分辨率。数据对8包含内蒙古-河北边境地区的哨兵2A L2A级产品,获取时间为2023年7月19日与2023年7月23日,同样具有极低的云量和积雪比例,所有粗分辨率波段均采用Sen2Res模型锐化至10米。所有数据集均采用地理坐标进行地理配准,分析过程中始终排除卷云波段。

本文方法所收集的数据集及相应的归一化后待校正影像的假彩色合成如图2所示。在实验设置中,图2中的数据对1至7用于模型训练,数据对8则保留用于测试。所有训练数据均通过裁剪处理为不重叠的 256×256 像素影像块。训练




图2 可视化排列在 2×4 矩阵中的8个数据对。对于每对数据,上面的图像代表参考数据,下面的图像代表不同时间点的待处理数据。

Fig. 2 Visualize 8 pairs of data arranged in a 2×4 matrix. For each pair of data, the image above represents the reference data, and the image below represents the data to be processed at different time points.

集所选用的影像块基于参考影像与待校正影像对应块之间计算的SSIM进行筛选。根据经验,将SSIM阈值设定为0.75,以识别适用于训练的影像块对。该特定阈值的选择旨在平衡训练样本规模与辐射对应精度之间的关系:阈值过高将保留较少但近乎完全一致的影像块,可能限制训练集的多样性与数量;而阈值过低则会纳入更多变异性较大的影像块,存在引入非期望光谱变化或配准误差的风险。0.75的阈值确保了大量高质量样本的获取,这些样本在表现出强辐射一致性的同时,仍能容纳自然变异与轻微配准偏差,从而在保障足够数据量以支持有效学习的同时,实现高精度的辐射归一化。这些经过精心筛选与预处理的数据集涵盖了多样的获取场景与环境条件,为评估方法的泛化能力奠定了坚实基础。所有实验的训练与测试均在NVIDIA GTX 4090平台上进行。

4.2 相对辐射归一化精度评估

为评估相对辐射归一化方法的性能,我们采

用以下定量指标。

首先,利用平均均方根误差评估辐射归一化的精度:

$$RMSE = \sqrt{\mathbb{E}_{(I_{\text{subject}}|I_{\text{ref}})}(f(I_{\text{subject}}) - I_{\text{ref}})^2}, \quad (12)$$

其中, I_{subject} 表示待校正影像, I_{ref} 表示参考影像。RMSE值越小,表明辐射归一化性能越优。

其次,采用平均相对偏差(RMD)对测试数据进行评估,定义如下:

$$RMD = \frac{|I_{\text{ref}} - I_{\text{subject}}|}{I_{\text{ref}}} \times 100. \quad (13)$$

通过RRN获得的理想归一化影像质量表现为较低的RMD值。

此外,采用SSIM和峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)两个定量指标,评估所提方法生成的归一化影像相对于参考影像的质量。这两个指标在测试数据集上针对每个光谱波段分别计算。SSIM和PSNR值越高,表明辐射归一化结果精度更高。

4.3 方法对比

为验证所提相对辐射归一化方法的性能,本文将其与以下主流方法进行对比:直方图匹配法(Histogram Matching, HM)^[23];最小-最大法(Min-Max, MM)^[14];简单回归法(Simple Regression, SR)^[24];伪不变特征法(Pseudo-Invariant Features, PIF)^[20];主成分分析法(Principal Component Analysis, PCA)^[21];基于线性回归与未变化像素法(Unchanged pixels based Linear Regression, UCLR)^[25];基于人工神经网络法(Artificial Neural Network, ANN)^[16];基于方向梯度直方图的方法(HOG-based)^[26];迭代加权多元变化检测法(Iteratively Reweighted MAD, IRMAD)^[27];变化向量分析法(Change Vector Analysis, CVA)^[28];二阶正交校正法(Orthogonal Correction-2nd order, OC2)^[29];多任务卷积神经网络辐射校正方法(Multi-Task Convolutional Neural Network, MT-CNN)^[30];Cycle-GAN^[31]。

从表1和表2的最后一列(各波段均值)可见,本文方法在12个光谱波段上取得了最低的平均RMSE和RMD,表明其在校正辐射差异与抑制光谱畸变方面具有卓越能力。作为强基线方法,IRMAD同样表现优异,平均RMSE为288.84、平均RMD为4.54,验证了迭代加权策略

在识别未变化像素方面的有效性;本文方法在此基础上进一步降低了辐射残差,凸显了扩散概率框架对非线性畸变的建模优势。变化向量分析法也展现出竞争力,平均RMSE为286.05、平均RMD为4.46,接近IRMAD水平。HM作为全局方法的代表,取得了平均RMSE 315.08、平均RMD 4.60的成绩,甚至优于部分基于稀疏采样的方法,但其无法区分变化与未变化区域的特点限制了精度上限。基于HOG特征的方法、UCLR和PIF等方法同属中等性能梯队,平均RMSE介于326~332之间,平均RMD介于5.32~5.60,表明基于稳定特征或像素选择虽能提升归一化效果,但线性模型与固定系数的组合难以应对复杂辐射变化。ANN平均RMD仅为7.17,表明光谱保持能力尚可,但平均RMSE高达425.70,反映出对异常值敏感且在高差异波段存在不稳定性。主成分分析法PCA的平均RMD达到6.74,为稀疏采样方法中最高,说明其主成分变换可能引入额外光谱失真。简单回归法SR与最小-最大法MM表现较差,MM的平均RMSE高达1042.09、平均RMD达17.56,其全局极值拉伸在部分波段产生严重误差,如第10波段。二阶正交校正法OC2的RMSE与RMD分别为1295.56和21.83,与原始影像水平相当,未

能有效校正辐射差异。Cycle-GAN作为基于GAN的代表性方法,平均RMSE为318.42、平均RMD为5.72,其在空间细节保留方面表现较好,但GAN模型训练过程中易出现模式崩溃问题,导致部分区域出现辐射过度校正的现象,影响整体归一化一致性。MT-CNN方法平均RMSE为295.78、平均RMD为4.68,其多任务模块与时间信息集成的设计,但该方法对训练样本的数量和质量要求较高,在样本较少的场景下泛化能力不足,校正精度出现下降。

如图3示,我们对所列相对辐射归一化方法的PSNR与SSIM结果进行了定量分析。具体而言,本文方法取得了如下PSNR值:波段1为37.45 dB,波段2为40.75 dB,波段3为39.64 dB,波段6为39.72 dB;同时,所有波段的SSIM值均超过0.97,其中波段2达到峰值0.9938,波段8达到0.9913。这些结果表明,本文方法在整个光谱范围内均实现了卓越的信号保真度与结构保持能力。

在对比方法中,IRMAD展现出竞争力,其PSNR在波段1达到37.41 dB,波段2达到40.68 dB,SSIM值普遍高于0.94。CVA在大多数波段上PSNR保持在35 dB以上,SSIM介于0.90至0.98之间,但在波段10下降至0.7456。ANN表现出显著的不稳定性,PSNR波动范围为16.61 dB至31.63 dB,SSIM则从0.008到0.8040剧烈变化。基于方向梯度直方图的方法PSNR介于10.27 dB至19.82 dB之间,SSIM值在0.7192至0.9814范围内。HM持续输出高质量结果,PSNR范围为32.24 dB至39.38 dB,SSIM介于0.9399至0.9952之间。PCA的PSNR处于31~39 dB区间,SSIM在0.8079至0.9680之间。MM结果波动较大,PSNR从12.32 dB到34.95 dB不等,SSIM介于0.7120至0.9711。SR的PSNR介于20.69 dB至35.74 dB,SSIM在0.7222至0.9824之间。相比之下,OC2表现相对较弱,PSNR局限于17.65~25.06 dB,SSIM仅在0.4497~0.7507范围内。MT-CNN的平均PSNR介于33.05~40.82 dB,平均SSIM为0.9653;Cycle-GAN的平均PSNR介于33.20~40.20 dB,平均SSIM为0.9622。总体而言,本文方法在保真度与感知导向指标上均持续优于各类对比方法。

表1 不同方法在数据集上的性能对比

Tab.1 Performance comparison of different methods on the dataset

方法	RMSE	RMD
ANN	425.70	7.17
HOG-based	331.79	5.59
HM	315.08	4.60
CVA	286.05	4.46
UCLR	328.08	5.40
PCA	346.15	6.74
IRMAD	288.84	4.54
MM	1042.09	17.56
PIF	326.89	5.32
OC2	1295.56	21.83
SR	446.56	8.53
MT-CNN	295.78	4.68
Cycle-GAN	318.42	5.72
Ours	284.46	4.42

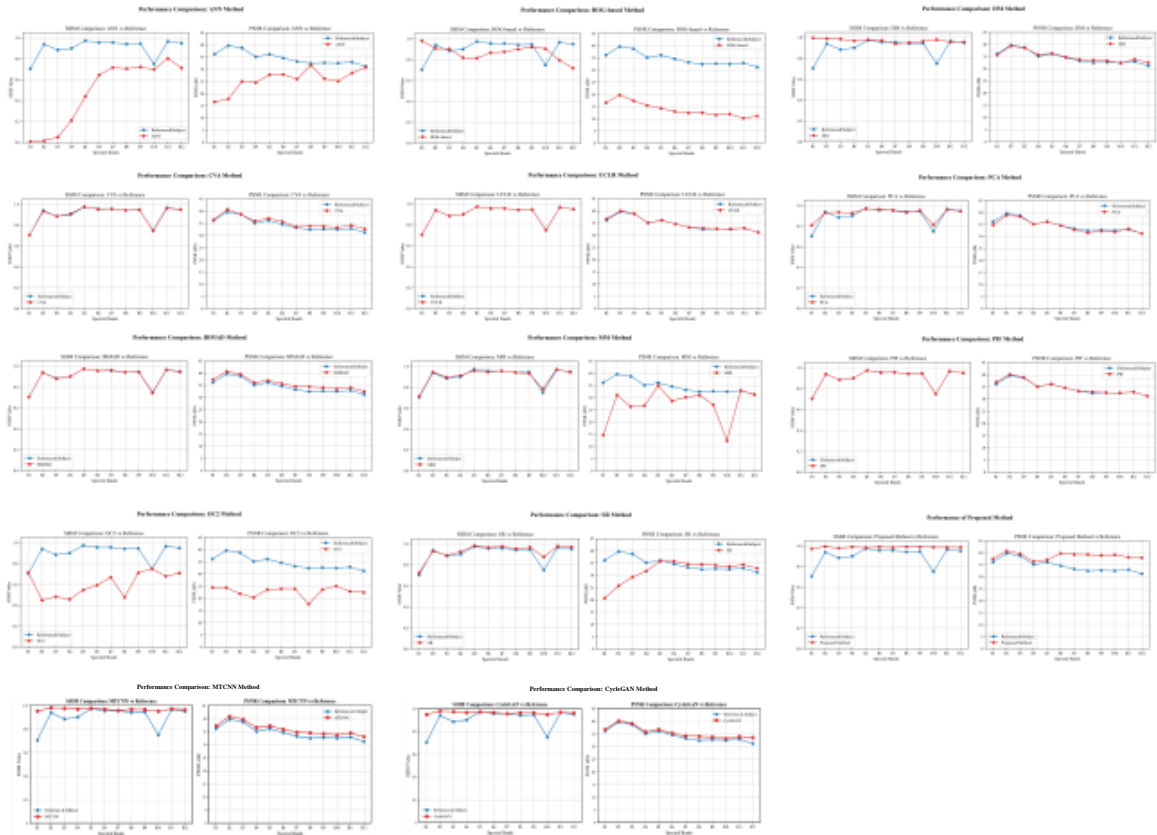


图3 不同RRN方法的PSNR和SSIM比较。

Fig. 3 PSNR and SSIM comparison of different methods

本文方法性能的提升可归因于其以扩散理论为基础的建模框架。该框架通过变分方法对辐射残差与噪声的联合分布进行概率建模,从而在数学层面实现了对辐射不一致性的精细化描述。与依赖手工设计特征或全局统计量的传统方法不同,本文方法通过一个配备光谱与空间注意力机制的专用网络学习辐射不一致性的逆过程。这一设计使其能够有效捕获跨波段的依赖关系与多尺度上下文特征,同时借助残差连接机制稳定了训练过程。

相比之下,基于神经网络及其变体的方法因对异常值敏感而表现出波段间的不稳定性;而诸如UCLR和SR等非迭代或线性技术则难以捕捉非线性辐射关系。本文方法有效减少了对经验参数调优的依赖,并在多样化的地表覆盖条件下展现出更强的泛化能力,为大尺度相对辐射归一化应用提供了一种稳健的、基于学习的解决方案。

图4展示了参考影像、原始待校正影像及各

方法归一化结果的视觉对比。与参考影像相比,待校正影像存在明显辐射差异,主要表现为亮度降低及植被、裸土、道路、水体等地表覆盖类型间的对比度不一致,这与影像获取季节差异及采集时间间隔相关。

多数归一化方法在一定程度上改善了辐射一致性。本文方法生成的归一化影像在视觉上与参考影像最为接近,所有地表覆盖类型均展现出协调的对比度与自然的纹理表现。这一结果与其优异的定量性能高度吻合,进一步验证了方法的有效性。IRMAD与CVA同样产生了视觉上令人信服的归一化结果,仅存在微小的残余变化,这与它们在定量评估中的优异排名相一致。

HOG-based、UCLR以及PIF表现出部分校正效果,但局部区域仍存在过校正或欠校正现象,这与它们处于中等水平的定量得分相吻合。ANN在某些区域保持了基本的光谱特性,但在辐射差异较大的区域引入了可见的视觉伪影,印证了前文所述其对异常值敏感的结论。

PCA与HM的辐射对齐能力相对有限。PCA引入了明显的光谱失真,而HM虽然改善了全局对比度,却未能有效处理局部辐射不一致

性。MM与OC2辐射归一化效果比较不明显。

Cycle-GAN存在局部伪影。MT-CNN在高辐射差异区域校正不够彻底。




图4 不同RRN方法的视觉比较。

Fig. 4 Visual comparison of different RRN methods

4.4 消融实验

为评估所提扩散框架中基于SSIM筛选的样本选择模块、光谱注意力模块SAM、空间注意力模块SPA及扩散模型结构对相对辐射归一化性能的贡献,我们开展了消融实验。实验通过逐一移除或替换核心模块,构建消融对照组,所有实验均在同一哨兵2号测试集上进行,采用RMSE、RMD进行定量评价,结果汇总于表2。

表2 消融实验的RMSE和RMD比较

Tab. 2 RMSE and RMD comparison with and without in ablation experiments

方法	RMSE	RMD
w/o SSIM	385.19	6.01
w/o SAM	301.24	4.96
w/o SPA	308.75	5.07
w/o Diffusion	295.31	4.82
with SSIM	284.46	4.42

消融实验定量评估了各关键组件对模型性能的贡献。首先,SSIM筛选机制的有效性得到验证。与未采用该策略相比,采用SSIM筛选后RMSE降低96.63,RMD降低0.79,误差指标的显著下降证明,在高结构相似性像素构成的纯净

数据集上训练,能够引导扩散模型学习更精确、稳健的辐射变换函数,从而证实了基于SSIM的样本选择策略的必要性。SAM消融实验表明,该模块可提升光谱区分能力,且仅依赖空间注意力难以充分挖掘跨波段依赖,光谱与空间注意力的协同作用至关重要。SPA消融实验表明,该模块能有效建模像素间长距离空间依赖,提升影像局部纹理与全局结构的一致性,与SAM形成互补。将扩散模型替换为U-Net后,误差指标劣于基准模型,表明扩散模型的概率建模能力可有效规避传统U-Net易出现的局部伪影与辐射过度校正问题,实现辐射校正精度与空间细节保留的更优平衡。

5 结论

本研究提出了一种基于扩散模型的多时相遥感影像相对辐射归一化框架。其核心创新在于将RRN重新定义为学习到的辐射不一致性的逆过程,通过构建前向扩散与反向采样的概率传递机制,实现对复杂辐射畸变成分与随机噪声的稳健分离与建模。该框架摒弃了传统方法对线性映射或全局统计特征的依赖,转而从数据驱动角度学习辐射传递函数,显著提升了模型对非线性

性畸变与异质地表覆盖的适应能力。集成专用的空间-光谱注意力网络进一步增强了模型捕获跨波段依赖关系与多尺度空间上下文特征的能力,其中光谱注意力模块通过自适应重标定通道响应强化关键波段信息,空间注意力模块则利用自注意力机制建模长距离像素依赖,二者协同作用使得模型能够在保持光谱保真度的同时精确保留地物边缘与纹理细节。基于SSIM的预处理阶段被用于自动选择稳定的伪不变影像块进行训练,通过筛选高质量训练样本有效降低地物变化带来的干扰,确保模型聚焦于辐射校正任务本身,从而提升训练收敛速度与最终归一化精度。

在哨兵2号数据集上进行的大量定量与定性评估表明,所提方法在RMSE、RMD、PSNR及

SSIM等多重指标上均持续优于包括IRMAD、CVA及基于ANN在内的现有主流与传统方法。实验数据显示,该方法在保持与参考影像高度接近的辐射保真度与结构相似性方面展现出卓越能力,尤其在高辐射差异波段与复杂地表覆盖区域仍能保持稳定的校正性能。这些结果确立了扩散模型作为RRN的强大范式,其概率生成特性为辐射不一致性建模提供了全新的理论视角,同时端到端的可训练架构使其能够适应多样化的遥感数据特性,减少对手工设计特征与启发式阈值依赖。未来工作将扩展模型以处理云遮挡、冰雪覆盖等复杂极端辐射变化场景,通过模型轻量化与并行计算优化,提升其在大规模遥感数据处理中的计算效率与实际部署可行性。

参 考 文 献:

- [1] Hui Y, Xu B, Huang H, *et al.* Modelling spatial-temporal change of Poyang Lake using multitemporal Landsat imagery [J]. *International Journal of Remote Sensing*, 2008, 29(20): 5767-5784.
- [2] Bovolo F, Bruzzone L. A theoretical framework for unsupervised change detection based on change vector analysis in the polar domain [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2006, 45(1): 218-236.
- [3] Ghosh A, Mishra N S, Ghosh S. Fuzzy clustering algorithms for unsupervised change detection in remote sensing images [J]. *Information Sciences*, 2011, 181(4): 699-715.
- [4] Vicente-Serrano S M, Pérez-Cabello F, Lasanta T. Assessment of radiometric correction techniques in analyzing vegetation variability and change using time series of Landsat images [J]. *Remote Sensing of Environment*, 2008, 112(10): 3916-3934.
- [5] Zhang Y, Yu L, Sun M, *et al.* A mixed radiometric normalization method for mosaicking of high-resolution satellite imagery [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(5): 2972-2984.
- [6] Yan N, Wu B, Boken V K, *et al.* A drought monitoring operational system for China using satellite data: design and evaluation [J]. *Geomatics, Natural Hazards and Risk*, 2016, 7(1): 264-277.
- [7] Schultz M, Verbesselt J, Avitabile V, *et al.* Error sources in deforestation detection using BFAST monitor on Landsat time series across three tropical sites [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, 9(8): 3667-3679.
- [8] Teillet P. Image correction for radiometric effects in remote sensing [J]. *International Journal of Remote Sensing*, 1986, 7(12): 1637-1651.
- [9] Yang X, Lo C. Relative radiometric normalization performance for change detection from multi-date satellite images [J]. *Photogrammetric Engineering and Remote Sensing*, 2000, 66(8): 967-980.
- [10] Liu S, Lian J, Zhan X, *et al.* Automatically eliminating seam lines with Poisson editing in complex relative radiometric normalization mosaicking scenarios [J]. *arXiv preprint*, 2021, arXiv:2106.07441.
- [11] Liu S, Wang L, Lian J, *et al.* Auto robust relative radiometric normalization via latent change noise modeling [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 1-13.
- [12] Chen Y, Sun K, Li D, *et al.* Improved relative radiometric normalization method of remote sensing images for change detection [J]. *Journal of Applied Remote Sensing*, 2018, 12(4): 045018.

-
- [13] Vermote E F, Tanré D, Deuze J L, *et al.* Second simulation of the satellite signal in the solar spectrum, 6S: An overview [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1997, 35(3): 675-686.
- [14] Hall F G, Strelak D E, Nickerson J E, *et al.* Radiometric rectification: toward a common radiometric response among multitemporal, multisensor images [J]. *Remote Sensing of Environment*, 1991, 35(1): 11-27.
- [15] Bao N, Lechner A M, Fletcher A, *et al.* Comparison of relative radiometric normalization methods using pseudo-invariant features for change detection studies in rural and urban landscapes [J]. *Journal of Applied Remote Sensing*, 2012, 6(1): 063578.
- [16] Sadeghi V, Ebadi H, Ahmadi F F. A new model for automatic normalization of multitemporal satellite images using artificial neural network and mathematical methods [J]. *Applied Mathematical Modelling*, 2013, 37(9): 6437-6445.
- [17] Zhou H, Liu S, He J, *et al.* A new model for the automatic relative radiometric normalization of multiple images with pseudo-invariant features [J]. *International Journal of Remote Sensing*, 2016, 37(19): 4554-4573.
- [18] Tu Y H, Phinn S, Johansen K, *et al.* Assessing radiometric correction approaches for multi-spectral UAS imagery for horticultural applications [J]. *Remote Sensing*, 2018, 10(11): 1684.
- [19] Ho J, Jain A, Abbeel P. Denoising diffusion probabilistic models [C]. *Advances in Neural Information Processing Systems*, 2020, 33: 6840-6851.
- [20] Song Y, Ermon S. Generative modeling by estimating gradients of the data distribution [C]. *Advances in Neural Information Processing Systems*, 2019, 32: 1-11.
- [21] Liu J, Wang Q, Fan H, *et al.* Residual denoising diffusion models [C]. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2024: 2773-2783.
- [22] Song J, Meng C, Ermon S. Denoising Diffusion Implicit Models [J]. *arXiv preprint*, 2020, arXiv:2010.02502.
- [23] Richards J A, Richards J. *Remote Sensing Digital Image Analysis* [M]. 3rd ed. Berlin: Springer, 1999.
- [24] Jensen J R. Urban/suburban land use analysis [C]. *Manual of Remote Sensing*. 2nd ed. Falls Church: Wiley, 1983: 1571-1666.
- [25] Ya'allah S M, Saradjian M R. Automatic normalization of satellite images using unchanged pixels within urban areas [J]. *Information Fusion*, 2005, 6(3): 235-241.
- [26] He H, Liu X, Shen Y. Relative radiometric correction of high-resolution remote sensing images based on feature category [J]. *Cluster Computing*, 2018, 22: 1-9.
- [27] Canty M J, Nielsen A A. Automatic radiometric normalization of multitemporal satellite imagery with the iteratively re-weighted MAD transformation [J]. *Remote Sensing of Environment*, 2008, 112(3): 1025-1036.
- [28] Malila W A. Change vector analysis: An approach for detecting forest changes with Landsat [C]. *Proceedings of the LARS Symposium*, 1980: 385-385.
- [29] Yuan D, Elvidge J C. Comparison of relative radiometric normalization techniques [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 1996, 51(3): 117-126.
- [30] Tang L, Zhao X, Hu X, Luo C, Lin M. A Multi-Task Convolutional Neural Network Relative Radiometric Calibration Based on Temporal Information [J]. *Remote Sensing*, 2024, 16(17): 3346.
- [31] Zhu J Y, Park T, Isola P, *et al.* Unpaired Image-to-Image Translation Using Cycle-Consistent Adversarial Networks [C]//*Proceedings of the IEEE International Conference on Computer Vision (ICCV)*. Venice: IEEE, 2017: 2223-2232.
- [32] Bu L J, Chen X X, Zhang Z P, *et al.* Two-Stage residual conditional diffusion network for super-resolution reconstruction of remote sensing images [J]. *Chinese Journal of Liquid Crystals and Displays*, 2025, 40(11): 1647-1660.
- [33] Zhao X, Du G L. Super-resolution of remote sensing images based on conditional prior enhancement and diffusion models [J]. *Chinese Journal of Liquid Crystals and Displays*, 2025, 40(7): 1067-1079.

- [34] Mao H M, Ding Z Y, Yang Y Y, *et al.* Effect of atmospheric turbulence on imaging quality of high-resolution remote sensing satellites[J]. *Chinese Optics*, 2024, 17(1): 167-177.

作者简介:



宋丽瑶,女,讲师,博士,2023年于西安交通大学获得博士学位,主要从事遥感图像辐射归一化、辐射校正的研究。
E-mail: songliyao@xatu.edu.cn



李海巍,男,博士,研究员,博士生导师,2016年于中南大学获得博士学位,主要从事遥感成像机理、星载和无人机图像智能处理、高光谱应用等方面研究工作。E-mail: lihaiwei@opt.ac.cn



刘纯焱,男,研究生,就读于西安工业大学,主要进行深度学习算法等方面研究工作。E-mail: 2022032344@st.xatu.edu.cn