

AMSR2 亮温轨道间隙时空谱随机森林重建

陈家楠¹, 张丽², 张贺¹, 储栋³, 殷志祥¹, 吴鹏海^{1,4}

1. 安徽大学 资源与环境工程学院, 合肥 230601;

2. 安徽尚原空间科技有限公司, 合肥 230071;

3. 安徽师范大学 地理与旅游学院, 芜湖 241002;

4. 湿地生态保护与修复安徽省重点实验室, 合肥 230031

摘要: 亮温是被动微波遥感的重要基础观测量, 是反演地表温度、土壤湿度、雪水当量等关键地表参量的重要输入数据, 在气象、气候与环境遥感领域具有重要的科学价值与应用潜力。被动微波传感器 AMSR2 (Advanced Microwave Scanning Radiometer 2) 可获得全天候、全球覆盖的亮温数据, 但受轨道设计与传感器特性限制, AMSR2 亮温数据存在轨道间隙, 影响数据的完整性和应用精度。本文在分析轨道间隙时空特征及亮温数据与环境变量广义谱的非线性关系基础上, 提出一种时空谱随机森林 STSRF (Spatio-Temporal Spectral Random Forest) 多维度重建模型。以 2020 年中国区域 AMSR2 亮温数据为例, 按月份及昼夜独立构建训练和验证数据集; 开展模拟实验和真实实验, 并评估重建前后数据的降尺度效果。在模拟实验中, STSRF 重建亮温具有较高精度, 昼、夜场景下均方根误差分别为 0.78—2.21 K 和 0.73—2.35 K, 且在高海拔地区整体重建精度优于其他区域; 在真实实验中, STSRF 重建亮温在空间分布上与 AMSR2 观测数据高度吻合, 无明显重建痕迹。此外, 降尺度对比分析表明, 与直接降尺度方案相比, 基于重建数据的降尺度结果在空间细节保持和数值精度方面更具优势, 进一步验证了重建策略的有效性。因此, STSRF 方法不仅能有效重建 AMSR2 亮温轨道间隙数据, 还有助于后续降尺度处理, 为大范围高分辨率微波遥感应用提供技术支持。

关键词: AMSR2 亮温, 轨道间隙重建, 时空谱随机森林, 降尺度处理, 环境变量

中图分类号: TP79/P2

引用格式: 陈家楠, 张丽, 张贺, 储栋, 殷志祥, 吴鹏海. 2026. AMSR2 亮温轨道间隙时空谱随机森林重建. 遥感学报, 30(6): 1856–1870

Chen J N, Zhang L, Zhang H, Chu D, Yin Z X and Wu P H. 2026. Spatiotemporal-spectral random forest reconstruction of orbital gaps in AMSR2 brightness temperature. National Remote Sensing Bulletin, 30(6): 1856–1870 [DOI:10.11834/jrs.20265233]

1 引言

亮温 BT (Brightness Temperature) 作为被动微波遥感的重要观测变量, 其主要通过测量地表和大气在特定频段的辐射能量, 间接反映地表物理特性和大气状态 (Prigent 等, 1997; Njoku 等, 2003)。由于被动微波 PMW (Passive microwave) 具有穿透云层和全天候观测的能力, BT 数据在地表温度反演、土壤湿度监测、雪水当量估算及植被水分含量分析等领域发挥了重要作用 (Owe 等, 2008; Kerr 等, 2010)。特别是在气候变化研究和

灾害监测中, PMW BT 因其独特的敏感性和高时间分辨率被广泛应用。然而, 微波遥感受限于卫星轨道覆盖的限制, BT 数据常存在轨道间隙问题, 影响了其空间完整性和连续性, 进而给多源遥感数据的融合及环境监测带来了挑战 (Prigent 等, 2005; Peng 等, 2016)。因此, 轨道间隙重建对于提升 BT 数据应用广度和深度具有重要意义。

近年来, 热红外云下地表温度 (LST) 重建研究取得较大进展, 而对低分辨率 PMW BT/LST 轨道间隙重建研究则相对较少 (丁利荣 等, 2023; Wu 等, 2021)。根据是否使用辅助数据, 现有的

收稿日期: 2025-06-27; 预印本: 2026-03-19

基金项目: 国家自然科学基金(编号:42271381); 安徽省自然科学基金(编号:2308085Y29)

第一作者简介: 陈家楠, 研究方向为被动微波亮温无缝重建。E-mail: nan990917@163.com

通信作者简介: 吴鹏海, 研究方向为热红外遥感智能处理与应用。E-mail: wuph@ahu.edu.cn

PMW BT/LST重建方法大致划分为两类。其中,一类方法主要基于插值技术和时空域互补信息对缺失数据进行填补,典型的填补插值方法包括反距离加权、经验正交函数分解和奇异谱分析(Duan等, 2017; Xu和Cheng, 2021; Ghafarian Malamiri等, 2018; Zhang等, 2019)该类方法计算高效、结构简单,通常依赖数据的时空连续性,适用于小范围缺失场景;但在应对PMW BT影像中的大尺度轨道间隙时,重建效果仍存在提升空间。为进一步提升重建效果,有学者利用深度学习的非线性建模优势,挖掘多时相数据的时空特征,提升了AMSR2轨道间隙重建精度与效率(Wu等, 2022);但这类方法依赖全局时空特征,对样本的覆盖性要求较高,在处理异常或突变现象时存在一定局限性。

另一类方法是引入多源辅助数据,以增强对缺失区域的空间表征能力,从而提高重建精度和空间一致性。这类辅助数据不仅包括其他被动微波卫星的BT产品,还有与BT密切相关的多种环境变量(如植被指数、土地覆盖类型、高程等);作为重建过程中与时空信息对应的广义“谱”信息。例如,Tang等(2022)则采用风云三号气象卫星(FY-3B)微波成像仪MWRI(Microwave Radiation Imager)BT作为辅助变量,基于随机森林RF(Random Forest)算法模拟AMSR2 BT与MWRI BT轨道间隙外区域的关系,实现AMSR2 BT的轨道间隙重建。Lian等(2023)采用11种环境变量作为辅助数据,构建了LST与环境变量之间的非线性关系;并基于深度神经网络实现AMSR2 LST的轨道间隙重建。这类方法的关键在于辅助环境变量的有效获取。

PMW(如AMSR2)BT数据普遍存在轨道间隙,特别是在中低纬度;相邻时相数据在空间上具有一定的互补性与周期性,且BT变化过程受多种环境因素综合影响,表现出明显的非线性和区域异质性。因此,轨道间隙重建不仅需要考虑像元间的“时空”关联性,还需借助有效环境变量的广义“谱”特征,以增强对缺失区域的空间表征能力。Ji等(2025)将邻近环境变化整合进深度学习模型,以实现被动微波地表温度数据的缺失重建。然而,基于相邻时空样本的深度学习重建方法往往面临样本不足的限制,样本增强的同时也带来计算成本(Huang等, 2023);更重要的

是,近些年高质量全天候地表温度数据集的公开发布,也为PMW BT数据轨道间隙重建提供了重要支撑,这在以往PMW BT重建研究中并不多见。

因此,为解决PMW BT数据轨道间隙重建中样本稀疏、非线性关系复杂及缺失区域空间特征表达不足等关键问题,本研究创新性地综合利用前后时相的时空互补特征与包括地表温度在内的多源环境变量构成的广义谱特征,并结合具备非线性建模能力、样本量需求灵活及抗过拟合优势的随机森林模型,提出一种时空谱随机森林STSRF(Spatio-Temporal Spectral Random Forest)重建方法;以实现AMSR2 BT轨道间隙的高精度重建。进一步地,本研究探讨了间隙填补前后对PMW BT数据降尺度结果的影响,验证STSRF模型在高精度遥感数据生成中的适用性与推广潜力。

2 研究区与数据

2.1 研究区

本研究选取中国区域作为研究范围,如图1所示。图1(a)为研究区域的边界示意图,图1(b)展示了AMSR2 BT数据在中国陆地区域的单日空间覆盖情况。受其圆锥扫描特性制约,观测数据中存在固有的轨道间隙,图1中以白色区域标示这些观测空白区。

2.2 研究数据

本研究中所指的“广义谱特征”主要指环境变量在空间、时间及地物属性维度上对BT分布规律的综合表征能力。因此本研究使用2020年全年AMSR2 BT数据及8个与其密切相关的环境变量,包括地表温度(LST)、归一化植被指数(NDVI)、增强植被指数(EVI)、土地覆盖类型(LC)、数字高程模型(DEM)、坡度(Slope)、经度(Longitude)和纬度(Latitude)。这些变量通过地表辐射特性、植被覆盖及地形起伏影响PMW BT的空间分布与传输过程。

AMSR2是日本宇宙航空研究开发机构(JAXA)研制的被动微波遥感器,搭载于GCOM-W1卫星,并于2012年5月发射。AMSR2可通过7个频率(6.9、7.3、10.7、18.7、23.8、36.5、89.0 GHz)获取垂直(V)和水平(H)极化BT数据,具备全天候观测能力。JAXA提供多级别标准BT产品(Level-1、

Level-2、Level-3)，其中，Level-3 全球数据的空间分辨率为 0.1°或 0.25°，每日提供 2 次观测（北京时间 1:30 和 13:30），本研究选用 JAXA 网站（<https://www.eorc.jaxa.jp/en/>）提供的 0.1°分辨率 Level-3 BT 数据，并以 18.7 GHz V 极化频段为重建对象，以验证所提方法在典型频段下的适用性。首先，该频段处于中频微波区，在地表热辐射敏感性与大气穿透能力之间取得了良好平衡，

18.7 GHz 通道在地表温度、土壤湿度和植被覆盖变化监测中表现出更优的响应特性。其次，V 极化通道受地表粗糙度和植被结构影响较小，能更稳定地反映地表辐射特征，从而提升模型在复杂地表条件下的泛化能力。该频段在现有研究中被广泛应用于地表温度和土壤湿度的反演，并展现出良好的辐射响应特性，相关结论亦可为其他频段的拓展应用提供方法参考。




图1 研究区概况
Fig. 1 Research area overview

DEM 与 Slope 反映了地形起伏对地表辐射传输的“地形谱”效应，而 Longitude 与 Latitude 则体现了大尺度空间位置及太阳辐射梯度的“地理谱”特征。因此，地形因素对 BT 变化具有重要影响，本研究采用空间分辨率为 900 m 的 SRTM DEM 数据（<http://srtm.csi.cgiar.org/srtmdata/>）LC 揭示了地物散射差异的“地物谱”信息，对地表能量平衡和辐射特性具有显著影响，本研究使用 MCD12Q1 LC 产品（空间分辨率 500 m），可从（<https://ladsweb.modaps.eosdis.nasa.gov/>）获取。LST、NDVI 和 EVI 则反映了地表热辐射及植被状态的“生物物理特性谱”特征，植被指数数据采用 MOD13A2 NDVI 和 EVI 产品，由 MODIS/Terra 提供，空间分辨率 1 km，时间分辨率 16 d（数据源同上）。

由于 LST 与 BT 在物理机制上具有高度相关性（Tong 等，2022），其时空分布直接影响 BT 变化。近年来，多源全天候热红外 LST 产品的持续发布也进一步拓展了可用数据资源（Zhang 等，2020，2021；Tang 等，2024；Wu 等，2019），为微波 BT 数据的缺失重建提供了关键的温度场信息。本研究采用课题组最新研发的全天候每日 1 km 类

MODIS LST 产品（<https://github.com/AHU-RS/MSRA-GAN>），详见表 1。

表 1 实验数据类别详细信息
Table 1 Detailed information on experimental data categories

数据集	变量	分辨率
AMSR2_L3	Brightness Temperature (BT)	10 km/d
MOD13A2	Normalized Difference Vegetation Index (NDVI)	1 km/16 d
	Enhanced Vegetation Index (EVI)	
MCD12Q1	Land Cover (LC)	500 m/a
SRTM	Digital Elevation Model (DEM)	1 km/a
	Slope	
	Longitude	
	Latitude	
类 MODIS	Land Surface Temperature (LST)	1 km/a

3 研究方法

如图 2 所示，本研究的整体框架包括 3 个主要步骤：（1）数据时空匹配处理，（2）AMSR2 BT 轨道间隙重建，（3）AMSR2 BT 重建后空间降尺度。首先，对 8 个环境变量进行时空匹配生成 2 个数据

集: 用于降尺度的1 km日尺度数据集和用于重建的10 km日尺度数据集。其次, 利用待重建日期前后2 d的BT数据及10 km日尺度数据集, 通过STSRF模型填补轨道间隙, 生成完整的10 km BT

数据。最后, 结合1 km日尺度数据集, 利用空谱随机森林(SSRF)方法对重建后的10 km数据进行降尺度至1 km, 获得高分辨率BT数据。




图2 重建框架流程图

Fig. 2 Reconstruction Framework Flowchart

3.1 数据时空匹配

本研究选取的环境变量空间分辨率均优于1 km, 既满足BT重建的输入变量, 也符合后续将重建的BT数据降尺度至1 km的要求。由于所选环境变量的时空分辨率与AMSR2 BT数据存在差异, 因此需对所有数据集进行全面的预处理。

首先, 考虑到NDVI和EVI在云覆盖区域可能存在数据缺失问题, 本研究采用合作者提出的ST-Tensor模型(Chu等, 2021)处理得到具有空间完整性、一致性的NDVI和EVI数据。其次, 将所有8种变量的空间分辨率使用空间聚类法(均值聚类)统一转换为10 km和1 km; 特别地, 对于MCD12Q1 IGBP土地覆盖分类数据, 基于BT的相似性对其进行重分类, 将原有的17种类型整合为8种类型包括: 水体与常年湿地、常绿林地、落叶林地、灌丛植被区、稀树草原与草地、耕地、裸地和积雪与冰川区(Zhou等, 2015)。最后, 为了与AMSR2的时间分辨率保持一致, 还需将所有变量的时间分辨率进行匹配; 由于NDVI和EVI的时间分辨率为16天, 而植被短时间内变化相对缓慢, 因此可以假设16天内NDVI和EVI保持稳定(孙

锐等, 2016; Zhao和Duan, 2020)。

3.2 PMW BT重建

3.2.1 STSRF重建模型构建

随机森林模型凭借其在处理高维非线性数据、抗噪性和泛化能力方面的卓越性能, 已被广泛应用于遥感数据分析。近年来, 研究者开发了多种增强模型, 如时空随机森林(Wang等, 2024)、空间光谱随机森林(Wang等, 2022)和多光谱随机森林(Xiao等, 2021)。借鉴这些研究, 结合PMW BT的特性, 本研究提出了一种时空谱随机森林(STSRF)重建模型, 该模型结合待重建日期前后时相的时空互补特征与多源环境变量构成的广义谱特征, 建立非线性映射, 捕捉地表辐射传输的时间动态、空间分布及环境因子对BT的调控作用。

鉴于PMW BT存在较大的轨道扫描间隙、相邻时相的空间互补性以及一定的周期性特征(苏扬等, 2022), 本研究在模型训练中构建目标日前后两天均具有有效观测值的空间交集掩码, 以定义一致的可用样本区域, 并统一应用于目标日所有辅助变量的提取过程, 从而充分利用多时相信

息并避免因缺失区域不一致对模型训练产生干扰。为规范定义用于模型训练的有效像元区域, 现引入其空间交集的数学表示如下:

$$M^c = M_{t-1} \cap M_t \cap M_{t+1} \quad (1)$$

式中, M_t 表示目标日期的 BT 有效观测区域, M_{t-1} 和 M_{t+1} 分别表示目标日前一天和后一天的 BT 有效观测区域, 三者的空间交集 M^c 定义为在 3 天内均存在有效观测的像元区域如图 3 所示。该交集区域作为训练样本的空间基础, 以确保输入特征空间

的一致性。基于此, 构建用于 BT 重建的 STSRF 模型如下:

$$BT_t^{(i)} = f(BT_{t-1}^{(i)}, BT_{t+1}^{(i)}, LST^{(i)}, NDVI^{(i)}, EVI^{(i)}, LC^{(i)}, DEM^{(i)}, Slope^{(i)}, Lon^{(i)}, Lat^{(i)}) \quad (2)$$

式中, $i \in M^c$, $BT_t^{(i)}$ 表示像元 i 处目标日 t 的 BT 观测值, f 为基于 RF 学习模型的非线性函数, 输入变量包括目标日前后天在像元 i 处的 BT 观测值 $BT_{t-1}^{(i)}$ 和 $BT_{t+1}^{(i)}$, 以及 8 个环境变量在像元 i 处的观测值。




图 3 连续 3 天的有效像元示意图

Fig. 3 Schematic diagram of valid pixels over three consecutive days

在预测阶段, 本研究将非线性函数 f 应用于目标日期 t 的缺失区域, 以估算该区域内缺失的 BT 像元值。具体预测公式如下所示:

$$\widehat{BT}_t^{(j)} = f(BT_{t-1}^{(j)}, BT_{t+1}^{(j)}, LST^{(j)}, NDVI^{(j)}, EVI^{(j)}, LC^{(j)}, DEM^{(j)}, Slope^{(j)}, Lon^{(j)}, Lat^{(j)}) \quad (3)$$

式中, j 表示目标日 t 上缺失 BT 值的像元集合, 即模型的重建区域。 $\widehat{BT}_t^{(j)}$ 表示通过已训练的非线性函数 f 预测获得的目标日期缺失区域内像元 j 处的 BT 值。模型的输入特征包括目标日前后 2 天在像元 j 处的 BT 观测值 $BT_{t-1}^{(j)}$ 和 $BT_{t+1}^{(j)}$, 以及 8 个环境变量在像元 j 处的观测值。

3.2.2 模型训练

针对 STSRF 模型在取并集操作后样本量减少的问题, 本研究通过实验发现: 逐日训练模式因样本不足导致模型欠拟合, 而季度训练虽能扩大

样本量, 却因时间跨度过大难以捕捉地表参数的动态变化规律。为此, 本文提出按月份划分的训练策略, 该方案在样本充足性与时序动态性之间取得最佳平衡, 能有效提升模型的重建性能。

基于上述策略, 将全年数据按月份与过境时刻划分为 24 个训练子集。得益于 AMSR2 的宽幅扫描特性, 训练样本在空间上完整覆盖中国陆域范围, 并包含所有主要土地覆盖类型, 确保了模型的泛化能力。各子集样本量 3.5—4.0 万, 样本选择时采用 Z-score 法剔除离群值。模型以待重建日期的可用 BT 值为目标, 整合前后两日的 BT 数据及 8 个环境变量作为输入特征。采用 4:1 的交叉验证显示, 各子模型重建 RMSE 稳定在 1.04—2.28 K, 验证了方法的有效性。


4 结果与分析

4.1 模拟实验

4.1.1 模拟实验的可视化结果

本研究通过人为挖空部分数据并对其进行模拟重建实验,将重建结果与挖空区域的原始数据对比,以评估模型性能。如图4所示,本研究选择了3个具有代表性的样区,涵盖不同海拔位置、气候类型及样区大小,并按白天和夜晚分别进行分析。其中,图4(a)和4(b)分别展示了白天和夜晚的模拟区域分布,图4(c)和4(d)为对应

重建结果。样区1的范围为50像素×20像素,位于高海拔地区,代表高寒干旱区,样区2的范围为30像素×30像素,位于中低海拔地区,代表湿热季风区。样区3的范围为40像素×15像素,位于中高海拔地区,代表温带半湿润区的特征。图4(c)和4(d)分别展示了重建后的白天和夜晚BT数据。可以观察到,利用STSRF模型重建的BT图像在空间纹理信息上表现出较强的连续性,且未显示出明显的边界效应,说明模型在空间重建中的表现较为平滑。




图中标注的1、2、3分别为研究区1、2、3

图4 8月15日(白天)和1月15日(夜晚)模拟区域示意图

Fig. 4 Schematic diagram of the simulated regions on August 15 (daytime) and January 12 (nighttime)

由于六月刚入夏,部分区域处于梅雨季节,3个样区在此时段的气候差异尤为显著。因此,本研究选取了3个区域中六月内已有的生成结果中气候条件较为接近的日期,通过放大比较这3个区域之间的空间信息特征,并分析AMSR2_BT与STSRF_BT的空间一致性结果见图5。可见,AMSR2_BT与

STSRF_BT具有较高的空间一致性。图中同时展示的差值分析结果表明,重建前后BT差异主要集中在0—2 K,空间分布均匀,无明显系统性偏差,仅在地形起伏或地表类型变化剧烈的局部区域存在轻微差异。整体而言,STSRF模型能够较好地保持BT的空间结构特征,实现对轨道间隙的精确重建。



区域一 6月30日; 区域二、三 6月20日

图5 3个模拟区域白天和夜晚的详细空间信息及差值图


Fig. 5 Detailed spatial information and difference maps for the three simulation regions

4.1.2 定量评价结果

为定量模型在不同空间尺度和时空条件下的性能, 本研究在区域一、区域二和区域三分别开展独立实验, 数据覆盖2020年全年, 按白天、夜晚的不同季度分析重建效果, 并通过RMSE、MAE和 R^2 评估模型的时空适应性与稳定性。

图6和图7展示了STSRF重建BT与AMSR2观测BT在不同气候区四季昼夜场景下的散点分布。分析表明, STSRF在白天具有较高精度和空间一

致性, 高寒干旱区(区域一)表现最佳($R^2=0.94-0.98$, $MAE=0.48-1.35$ K, $RMSE=0.78-2.21$ K), 湿热季风区(区域二)受湿度影响仍保持较高性能($R^2=0.91-0.97$, $MAE=0.81-1.03$ K, $RMSE=1.15-1.79$ K)。温带半湿润区(区域三)因AMSR2轨道间隙扩大, 验证数据较少, 导致 R^2 略低(0.90—0.96)。尽管如此, STSRF在该区仍展现出稳定的重建能力RMSE(0.94—1.22 K), 散点分布无明显偏移, MAE波动范围较小(0.60—0.91 K)。






图6 白天3个区域重建前后四季的密度散点图

Fig. 6 Density scatter plots of the three regions before and after reconstruction in four seasons during daytime




图7 夜晚3个区域重建前后四季的密度散点图

Fig. 7 Density Scatter Plots of the Three Regions Before and After Reconstruction in Four Seasons During Nighttime

在夜间场景中（图7），STSRF模型也表现出更稳健的重建性能。高寒干旱区（区域一） R^2 （0.96—0.97）、MAE（1.10—1.49 K）和RMSE（1.62—2.35 K）接近最优，展现出对极端环境的高解析能力。湿热季风区（区域二）虽受湿度波动影

响，仍保持较高精度（ $R^2=0.87—0.97$ ，MAE=0.50—0.86 K，RMSE=0.73—1.40 K），表明模型能有效抑制散射噪声。温带半湿润区（区域三）夜间性能弱于白天，其中夜间的决定系数 $R^2=0.88—0.92$ ，而白天则为0.90—0.96。RMSE增加了11.8%。此外，各

区域夏季指标整体劣于其他季节, 主要因梅雨季节天气突变性增强, 降低了模型预测精度。

综上, STSRF_BT在不同气候类型、季节、空间尺度及区域大小下均表现出较高精度与较强鲁棒性, 其通过融合时空连续性与广义谱特征表达能力, 成功克服了复杂地形与多样气候条件对BT重建的耦合干扰, 为中国范围内被动微波BT数据的修复提供了有益的支持。

4.2 真实实验


本研究对2020年全年数据进行了重建, 现选取每月第一天的白天(图8)和夜晚(图9)的重建前后结果, 以直观展现模型的性能; 此外, 重建后的2020年全国范围数据已公开发布([https://github.com/AHU-RS/STSRF\[2025-06-27\]](https://github.com/AHU-RS/STSRF[2025-06-27]))。图8和图9直观展现了模型在全年不同时间的重建能力, 清晰反映出其在空间纹理还原和时空连续性保持方面的优良表现, 进一步印证了模型的稳定性与适用性。

4.3 消融实验

本研究设计了消融实验, 以探讨时空特征与广义谱特征的组合是否构成BT重建的理想输入特征组合, 并分析不同特征对模型性能的影响。目标日期前后2 d的BT数据用于捕捉时间连续性, 而8个环境变量刻画BT的空间异质性及环境依赖性, 两者结合可全面反映BT的时空分布规律。为验证这一假设, 本研究设立3种对比实验, 并采用按月训练: (1) SSRF: 仅使用8个环境变量(仅

广义谱); (2) STRF: 仅使用前后2 d的BT数据(仅时空); (3) STSRF-T: 使用目标日期前后2 d的BT数据和除LST外的7个环境变量(时空一部分广义谱), 其中LST是与BT相关性最强的关键变量之一; (4) STSRF: 使用目标日期前后两天的BT数据和8个环境变量(时空—广义谱融合)。

本研究延续4.1节中所选取的3个研究区域, 采用SSRF、STRF、STSRF-T和STSRF模型对2020年BT数据进行重建分析。定量结果显示(表2), STSRF在所有区域昼夜场景下均表现最优, STSRF-T的重建精度略低于STSRF, 且明显优于SSRF和STRF。具体而言: 在区域一, STSRF的 R^2 值(白天0.982, 夜晚0.979)显著高于SSRF(白天0.963, 夜晚0.951)和STRF(白天0.925, 夜晚0.953), 而略高于STSRF-T(白天0.980, 夜晚0.979), 其MAE(白天0.990 K, 夜晚1.297 K)和RMSE(白天1.673 K, 夜晚2.064 K)均为最低值; 在区域二, STSRF同样保持优势, R^2 (白天0.986, 夜晚0.984)明显优于SSRF(白天0.972, 夜晚0.962)和STRF(白天0.903, 夜晚0.921), 且MAE(白天0.899 K, 夜晚0.700 K)较STRF(白天2.739 K, 夜晚1.968 K)降低67.2%—64.4%; 在区域三, STSRF的RMSE(白天1.071 K, 夜晚1.174 K)较STRF(白天2.668 K, 夜晚2.213 K)显著降低59.9%—46.9%。而较STSRF-T(白天1.252 K, 夜晚1.252 K)则降低6.2%—14.5%。这证实单一维度特征难以充分表征其与微波辐射的复杂关系。



(a) AMSR2 BT





图8 2020年每月1号白天AMSR2 BT重建前后空间格局比较

Fig. 8 Spatial comparison of daytime AMSR2 BT before and after reconstruction on the first day of each month in 2020

STSRF 的优势源于时空—广义谱协同机制：
(1) 时空特征通过辐射梯度约束增强数据连续性（区域一夜 R^2 达 0.979）；
(2) 广义谱特征提升地表异质性表征能力（区域三夜 MAE 降至 0.787 K）；
(3) 特征融合平衡昼夜辐射差异（区域三昼夜

RMSE 差仅 0.103 K，显著低于 STRF 的 0.455 K）。
进一步地，消融实验结果表明，LST 作为与 PMW BT 高度相关的物理变量，其引入不仅提升了模型对地表辐射机制的刻画能力，也增强了复杂区域下的预测稳定性与细节还原效果。






图9 2020年每月1日夜晚 AMSR2 BT重建前后空间格局比较

Fig. 9 Spatial comparison of nighttime AMSR2 BT before and after reconstruction on the first day of each month in 2020

表2 2020年全年白天和夜晚3个区域评价情况
Table2 Evaluation of three regions during daytime and nighttime for the entire year of 2020

评价指标	模型	区域一		区域二		区域三	
		白天	夜晚	白天	夜晚	白天	夜晚
R^2	SSRF	0.963	0.951	0.972	0.962	0.937	0.947
	STRF	0.925	0.953	0.903	0.921	0.899	0.901
	STSRF-T	0.980	0.979	0.976	0.979	0.977	0.968
	STSRF	0.982	0.979	0.986	0.984	0.984	0.972
MAE/K	SSRF	1.598	1.910	1.229	0.945	1.285	1.081
	STRF	2.199	2.183	2.739	1.968	2.060	1.671
	STSRF-T	1.069	1.297	1.141	0.834	0.796	0.836
	STSRF	0.990	1.297	0.899	0.700	0.715	0.787
RMSE/K	SSRF	2.458	3.189	2.048	1.778	2.064	1.622
	STRF	3.416	3.127	3.829	2.598	2.668	2.213
	STSRF-T	1.791	2.143	1.847	1.328	1.252	1.252
	STSRF	1.673	2.064	1.441	1.175	1.071	1.174

4.4 重建 BT 数据后的降尺度分析

为探讨重建前后 BT 数据对降尺度结果的影响，本研究分别以重建前和重建后的 BT 数据作为输入使用空谱随机森林模型进行降尺度实验。由于重建阶段已充分利用了与 BT 相关的环境变量，

因此这些变量在降尺度过程中仍作为辅助因子使用。为系统评估两种方案的差异，引入保真度评价方法（景映红 等，2024），以量化不同方案在 BT 空间细节保持方面的表现。考虑到 AMSR2 BT 数据本身缺乏真实的高分辨率参考值，直接验证降尺度精度存在一定困难，因此本研究将降尺度后的 BT 结果重新降采样至 10 km 分辨率，并与原始 AMSR2 BT 数据进行对比。由于 AMSR2 BT 的每个像元本质上代表天线视场 BT 的空间平均值，因此采用平均值降采样方法最能反映其成像特征，从物理意义上保证与原始 BT 数据的一致性，避免插值类方法引入的系统偏差。最后，通过引入各项误差指标，综合评估不同降尺度方案在整体一致性与细节保持方面的差异，从而定量反映重建对降尺度精度的影响。

本文选取含缺失数据的 3 个不同区域影像块开展实验，分别展示原始数据、直接将尺度结果、重建结果及重建后降尺度结果，如图 10 所示。结果表明：直接降尺度因缺失数据影响，存在细节丢失、噪点增加和边界不连续等问题。由图 10（a）可见：在水陆交界区域，直接降尺度导致水系 BT 值趋于周围陆地，边界模糊；而先重建再降尺度

能更清晰地分辨不同下垫面, 提高精细度。在复杂地形区域 (b行), 直接降尺度生成大量噪点, 而重建后再降尺度能减少异常值, 使预测结果更平滑, 并保持地形特征; 在轨道间隙较大的区域

(c行), 直接降尺度导致缺失区与周边区域存在明显边界, 而重建后再降尺度能消除边界效应, 提高数据的空间一致性和可信度。




图10 重建前后降尺度效果对比

Fig. 10 Comparison of Downscaling Effects Before and After Reconstruction

此外, 本研究还分别计算了2种降尺度方案在昼夜、四季及全年尺度下的3项指标 (RMSE、MAE 和 R^2)。如表3所示, 量化结果表明对比直接降尺度与重建后降尺度的全年评估结果, 重建后降尺度策略使全年昼夜 R^2 值分别提高 0.006 和 0.011, MAE降低 0.047 K (白天) 和 0.049 K (夜晚), RMSE减少 0.092 K (白天) 和 0.137 K (夜

晚)。季节尺度上, 重建后降尺度策略展现出全面优化: 春季夜间 RMSE降低 4.4% (从 3.398 K降低至 3.556 K), 夏季夜间 MAE显著下降 3.2% (从 1.907 K降低至 1.970 K), 秋季夜间 RMSE减少 4.5% (从 3.365 K降低至 3.522 K), 冬季昼间 R^2 提升至 0.908。

表3 重建前、后降尺度结果四季以及全年对比

Table 3 Comparison of downscaling results before and after reconstruction for each season and the entire year											
指标	时间	春季		夏季		秋季		冬季		全年	
		重建后	重建前	重建后	重建前	重建后	重建前	重建后	重建前	重建后	重建前
R^2	白天	0.887	0.882	0.871	0.864	0.867	0.860	0.908	0.903	0.883	0.877
	夜晚	0.910	0.899	0.905	0.894	0.903	0.891	0.925	0.917	0.911	0.900
MAE/K	白天	2.061	2.114	2.076	2.142	1.952	2.003	1.709	1.725	1.949	1.996
	夜晚	2.039	2.102	1.907	1.970	1.922	1.976	1.726	1.740	1.898	1.947
RMSE/K	白天	3.519	3.623	3.529	3.645	3.407	3.516	2.998	3.032	3.363	3.455
	夜晚	3.398	3.556	3.304	3.466	3.365	3.522	2.965	3.030	3.257	3.394

上述定量分析结果进一步验证了目视分析的结论,即轨道间隙重建在降尺度过程中发挥了关键作用,为降尺度建模提供了更完整的输入数据,使得BT数据在空间细节保留、误差控制和整体一致性方面均优于直接降尺度方案。

5 结 论

为实现缺失BT数据的高精度重建,本文提出了时空谱随机森林(STSRF)模型,通过融合相邻时相的时空互补信息与多源环境变量所表征的广义谱特征,构建BT与环境因子之间的非线性映射关系。在此基础上,开展了系统实验分析,主要结论如下:(1)引入LST变量能够显著提升PMW BT重建精度。消融实验中,在去除LST等关键变量后,模型在不同区域和季节条件下的RMSE均出现明显增大,这表明,LST作为表征地表热状态的重要变量,可为BT提供稳定的物理约束;(2)所提出的STSRF模型融合相邻时相BT信息与多源环境变量,实现对时序特征与空间结构的协同建模。模拟实验中,模型在昼夜不同条件下均取得较高精度;真实轨道间隙重建结果表明,重建BT与原始观测在空间分布上高度一致,无明显重建痕迹。对比单一特征方法,STSRF在复杂地形及高海拔区域表现出更好的稳定性,体现了其对BT非线性关系的有效刻画能力与良好的泛化性能;(3)相较于直接使用原始含缺失数据进行降尺度,重建后降尺度结果在空间连续性与数值稳定性方面均显著提升。直接降尺度在缺失区域易产生不合理空间结构,而基于重建BT的结果能够保持更一致的空间分布特征。说明重建过程有效恢复了BT的空间信息,为后续尺度转换提供稳定且具有物理约束的输入基础。

本研究仍存在以下局限性:(1)尽管通过模拟实验和多指标评估验证了轨道间隙重建模型的性能,但受限于同等条件真实BT数据的缺乏,模型仍需进一步验证;(2)该模型在AMSR2数据上展现出良好性能,具备向其他被动微波数据(如MWRI)扩展的可行性;但不同传感器之间仍可能存在分辨率差异或观测特性差异,需进一步验证模型的跨传感器适应能力。

参考文献(References)

Chu D, Shen H F, Guan X B, Chen J M, Li X H, Li J and Zhang L P.

2021. Long time-series NDVI reconstruction in cloud-prone regions via spatio-temporal tensor completion. *Remote Sensing of Environment*, 264: 112632 [DOI: 10.1016/j.rse.2021.112632]
- Ding L R, Zhou J, Zhang X D, Wang S F, Tang W B, Wang Z W, Ma J, Ai L J, Li M S and Wang W. 2023. Estimation of all-weather land surface temperature with remote sensing: progress and challenges. *National Remote Sensing Bulletin*, 27(7): 1534-1553 (丁利荣, 周纪, 张晓东, 王韶飞, 唐文彬, 王子卫, 马晋, 艾丽皎, 李明松, 王伟. 2023. 全天候地表温度遥感获取进展与挑战. *遥感学报*, 27(7): 1534-1553) [DOI: 10.11834/jrs.20211323]
- Duan S B, Li Z L and Leng P. 2017. A framework for the retrieval of all-weather land surface temperature at a high spatial resolution from polar-orbiting thermal infrared and passive microwave data. *Remote Sensing of Environment*, 195: 107-117 [DOI: 10.1016/j.rse.2017.04.008]
- Ghafarian Malamiri H R, Rousta I, Olafsson H, Zare H and Zhang H. 2018. Gap-filling of MODIS time series land surface temperature (LST) products using singular spectrum analysis (SSA). *Atmosphere*, 9(9): 334 [DOI: 10.3390/atmos9090334]
- Huang X H, Li C, Yang T, Cao B, Cheng J, Xie G C and Wu P H. 2023. Seamless reconstruction of AMSR-E land surface temperature swath gaps for China's landmass. *IEEE Transactions on Geoscience and Remote Sensing*, 61: 4411615 [DOI: 10.1109/TGRS.2023.3335820]
- Ji W Z, Chen Y H, Xia H P, Gao H and Zhu L. 2025. Jointing adjacent environmental variation into a deep learning model for gap-filling passive microwave-based land surface temperature. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 18: 9682-9700 [DOI: 10.1109/JSTARS.2025.3554810]
- Jing Y H, Shen H F, Li X H, Wu J G and Qiu Z H. 2024. Spatial down-scaling of remote sensing parameters from perspective of data fusion[J]. *Geomatics and Information Science of Wuhan University*, 49(2): 175-189 (景映红, 沈焕锋, 李星华, 吴金徽, 邱中航. 2024. 数据融合视角下的遥感参量空间降尺度. *武汉大学学报(信息科学版)*, 49(2): 175-189) [DOI: 10.13203/j.whugis.20220549]
- Kerr Y H, Waldeufel P, Wigneron J P, Delwart S, Cabot F, Boutin J, Escorihuela M J, Font J, Reul N, Gruhier C, Juglea S E, Drinkwater M R, Hahne A, Martin-Neira M and Mecklenburg S. 2010. The SMOS mission: new tool for monitoring key elements of the global water cycle. *Proceedings of the IEEE*, 98(5): 666-687 [DOI: 10.1109/JPROC.2010.2043032]
- Lian Y H, Duan S B, Huang C, Han W J and Liu M. 2023. Generation of spatial-seamless AMSR2 land surface temperature in China during 2012-2020 using a deep neural network. *IEEE Transactions on Geoscience and Remote Sensing*, 61: 5300618 [DOI: 10.1109/TGRS.2023.3247806]
- Njoku E G, Jackson T J, Lakshmi V, Chan T K and Nghiem S V. 2003. Soil moisture retrieval from AMSR-E. *IEEE Transactions on Geoscience and Remote Sensing*, 41(2): 215-229 [DOI: 10.1109/TGRS.2002.808243]
- Owe M, de Jeu R and Holmes T. 2008. Multisensor historical climatology of satellite-derived global land surface moisture. *Journal of Geophysical Research: Earth Surface*, 113(F1): F01002 [DOI: 10.

- 1029/2007JF000769]
- Peng J, Loew A, Zhang S Q, Wang J and Niesel J. 2016. Spatial down-scaling of satellite soil moisture data using a vegetation temperature condition index. *IEEE Transactions on Geoscience and Remote Sensing*, 54(1): 558-566 [DOI: 10.1109/TGRS.2015.2462074]
- Prigent C, Aires F, Rossow W B and Robock A. 2005. Sensitivity of satellite microwave and infrared observations to soil moisture at a global scale: relationship of satellite observations to in situ soil moisture measurements. *Journal of Geophysical Research: Atmospheres*, 110(D7): D07110 [DOI: 10.1029/2004JD005087]
- Prigent C, Rossow W B and Matthews E. 1997. Microwave land surface emissivities estimated from SSM/I observations. *Journal of Geophysical Research: Atmospheres*, 102(D18): 21867-21890 [DOI: 10.1029/97JD01360]
- Su Y, Wu P H, Cheng J, Yin Z X, Ma X S and Yang H. 2022. Research on deep learning methods for AMSR-E land surface temperature data reconstruction. *National Remote Sensing Bulletin*, 26(4): 739-751 (苏扬, 吴鹏海, 程洁, 殷志祥, 马晓双, 杨辉. 2022. AMSR-E 地表温度数据重建深度学习方法. *遥感学报*, 26(4): 739-751) [DOI: 10.11834/jrs.20220426]
- Sun R, Rong Y, Su H B and Chen S H. 2016. NDVI time-series reconstruction based on MODIS and HJ-1 CCD data spatial-temporal fusion. *Journal of Remote Sensing (in Chinese)*, 20(3): 361-373 (孙锐, 荣媛, 苏红波, 陈少辉. 2016. MODIS 和 HJ-1CCD 数据时空融合重构 NDVI 时间序列. *遥感学报*, 20(3): 361-373) [DOI: 10.11834/jrs.20165173]
- Tang W B, Xue D J, Long Z Y, Zhang X D and Zhou J. 2022. Near-real-time estimation of 1-km all-weather land surface temperature by integrating satellite passive microwave and thermal infrared observations. *IEEE Geoscience and Remote Sensing Letters*, 19: 7001305 [DOI: 10.1109/LGRS.2021.3067908]
- Tang W B, Zhou J, Ma J, Wang Z W, Ding L R, Zhang X D, and Zhang X. 2024. TRIMS LST: a daily 1 km all-weather land surface temperature dataset for China's landmass and surrounding areas (2000-2022). *Earth System Science Data*, 16(1): 387-419 [DOI: 10.5194/essd-16-387-2024]
- Tong C, Wang H Q, Zhu L Y, Deng X D and Wang K. 2022. Reconstruct SMAP brightness temperature scanning gaps over Qinghai-Tibet Plateau. *International Journal of Applied Earth Observation and Geoinformation*, 115: 103090 [DOI: 10.1016/j.jag.2022.103090]
- Wang Q M, Tang Y J, Tong X H and Atkinson P M. 2024. Filling gaps in cloudy Landsat LST product by spatial-temporal fusion of multi-scale data. *Remote Sensing of Environment*, 306: 114142 [DOI: 10.1016/j.rse.2024.114142]
- Wang Q M, Wang L X, Zhu X L, Ge Y, Tong X H and Atkinson P M. 2022. Remote sensing image gap filling based on spatial-spectral random forests. *Science of Remote Sensing*, 5: 100048 [DOI: 10.1016/j.srs.2022.100048]
- Wu P H, Su Y, Duan S B, Li X H, Yang H, Zeng C, Ma X S, Wu Y L and Shen H F. 2022. A two-step deep learning framework for mapping gapless all-weather land surface temperature using thermal infrared and passive microwave data. *Remote Sensing of Environment*, 277: 113070 [DOI: 10.1016/j.rse.2022.113070]
- Wu P H, Yin Z X, Yang H, Wu Y L and Ma X S. 2019. Reconstructing geostationary satellite land surface temperature imagery based on a multiscale feature connected convolutional neural network. *Remote Sensing*, 11(3): 300 [DOI: 10.3390/rs11030300]
- Wu P H, Yin Z X, Zeng C, Duan S B, Göttsche F M, Ma X S, Li X H, Yang H and Shen H F. 2021. Spatially continuous and high-resolution land surface temperature product generation: a review of reconstruction and spatiotemporal fusion techniques. *IEEE Geoscience and Remote Sensing Magazine*, 9(3): 112-137 [DOI: 10.1109/MGRS.2021.3050782]
- Xiao Y, Zhao W, Ma M G and He K L. 2021. Gap-free LST generation for MODIS/terra LST product using a random forest-based reconstruction method. *Remote Sensing*, 13(14): 2828 [DOI: 10.3390/rs13142828]
- Xu S and Cheng J. 2021. A new land surface temperature fusion strategy based on cumulative distribution function matching and multi-resolution Kalman filtering. *Remote Sensing of Environment*, 254: 112256 [DOI: 10.1016/j.rse.2020.112256]
- Zhang X D, Zhou J, Göttsche F M, Zhan W F, Liu S M and Cao R Y. 2019. A method based on temporal component decomposition for estimating 1-km all-weather land surface temperature by merging satellite thermal infrared and passive microwave observations. *IEEE Transactions on Geoscience and Remote Sensing*, 57(7): 4670-4691 [DOI: 10.1109/TGRS.2019.2892417]
- Zhang X D, Zhou J, Liang S L, Chai L N, Wang D D and Liu J. 2020. Estimation of 1-km all-weather remotely sensed land surface temperature based on reconstructed spatial-seamless satellite passive microwave brightness temperature and thermal infrared data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 167: 321-344 [DOI: 10.1016/j.isprsjprs.2020.07.014]
- Zhang X D, Zhou J, Liang S L and Wang D D. 2021. A practical re-analysis data and thermal infrared remote sensing data merging (RTM) method for reconstruction of a 1-km all-weather land surface temperature. *Remote Sensing of Environment*, 260: 112437 [DOI: 10.1016/j.rse.2021.112437]
- Zhao W and Duan S B. 2020. Reconstruction of daytime land surface temperatures under cloud-covered conditions using integrated MODIS/Terra land products and MSG geostationary satellite data. *Remote Sensing of Environment*, 247: 111931 [DOI: 10.1016/j.rse.2020.111931]
- Zhou J, Dai F N, Zhang X D, Zhao S J and Li M S. 2015. Developing a temporally land cover-based look-up table (TL-LUT) method for estimating land surface temperature based on AMSR-E data over the Chinese landmass. *International Journal of Applied Earth Observation and Geoinformation*, 34: 35-50 [DOI: 10.1016/j.jag.2014.07.001]

Spatiotemporal–spectral random forest reconstruction of orbital gaps in AMSR2 brightness temperature

CHEN Jianan¹, ZHANG Li², ZHANG He¹, CHU Dong³, YIN Zhixiang¹, WU Penghai^{1,4}

1. School of Resources and Environmental Engineering, Anhui University, Hefei 230601, China;

2. Anhui Shangyuan Space Technology Co., Ltd., Hefei 230071, China;

3. School of Geography and Tourism, Anhui Normal University, Wuhu 241002, China;

4. Key Laboratory of Wetland Ecological Protection and Restoration Anhui Province, Hefei 230031, China

Abstract: Brightness Temperature (BT) serves as a critical geophysical parameter reflecting the Earth's surface energy budget and holds substantial significance in meteorological monitoring, climate change studies, and environmental remote sensing. The Advanced Microwave Scanning Radiometer 2 (AMSR2) enables global, all-weather acquisition of BT data. However, because of orbital design constraints and sensor-specific characteristics, the AMSR2 BT product suffers from orbital data gaps, which hinder its continuity and limit its effectiveness in quantitative applications. This study aims to develop a robust reconstruction framework to address these data discontinuities and improve the spatiotemporal integrity of AMSR2 BT datasets.

To reconstruct the missing orbital BT data, we propose a novel multidimensional model termed spatiotemporal-spectral random forest (STSRF). The model integrates spatiotemporal patterns with generalized spectral features that characterize the nonlinear relationships between BT and multiple environmental variables. Using the 2020 AMSR2 BT dataset over China as a case study, we separately constructed training and validation datasets on a monthly basis for daytime and nighttime observations. Simulated data masking and real-missing data scenarios were applied to evaluate reconstruction accuracy. Moreover, downscaling experiments were conducted before and after reconstruction to assess the influence of data integrity on spatial detail restoration.

In the simulation experiments, the STSRF model demonstrated high reconstruction accuracy, with root-mean-square errors ranging from 0.78 K to 2.21 K during the day and from 0.73 K to 2.35 K at night. Notably, the model achieved superior performance in high-altitude regions. In real experiments, the spatial distribution of reconstructed BT closely matched original AMSR2 observations, showing no discernible reconstruction artifacts. Downscaling evaluation revealed that the STSRF-based reconstruction significantly enhanced numerical precision and spatial feature retention compared with the direct downscaling applied to incomplete datasets. The enhanced numerical precision and spatial feature retention observed in the downscaling evaluation confirm the added value of gap filling prior to resolution enhancement.

The proposed STSRF model effectively overcomes the limitations of traditional single-feature approaches by incorporating multidimensional information, including temporal dynamics and environmental variability. It provides a reliable strategy for reconstructing AMSR2 BT orbital gaps while enhancing downstream data usability for high-resolution microwave remote sensing applications. The results affirm that spatiotemporal and spectral feature fusion not only improves reconstruction robustness but also supports accurate and complete environmental monitoring over large regions.

Key words: AMSR2 brightness temperature, orbital gap reconstruction, spatiotemporal spectral random forest, downscaling, environmental variables

Supported by National Natural Science Foundation of China (No. 42271381); Natural Science Foundation of Anhui Province (No. 2308085Y29)