

邵瀚锐, 李智. 多输出多分辨率电磁频谱地图构建方法[J]. 智能计算机与应用, 2026, 16(4): 110-115. DOI: 10.20169/j.issn.2095-2163.25120406

多输出多分辨率电磁频谱地图构建方法

邵瀚锐, 李智

(四川大学 电子信息学院, 成都 610065)

摘要: 认知无线网络中, 欠覆盖区域的电磁频谱地图构建受稀疏观测与复杂传播环境限制, 传统单输出方法难以刻画空间不连续性和预测不确定性。为提高构建可靠性, 该研究提出多输出多分辨率的两阶段频谱映射框架, 通过生成对抗网络动态融合稀疏观测与学习到的传播特征, 在低分辨率阶段生成多组候选谱图以量化不确定性, 并构建信息价值图, 引导无人机执行高收益采样; 随后在高分辨率阶段利用补充观测实现逐级细化重构。该框架突破了传统单输出模型的局限, 兼具不确定性建模、多分辨率渐进优化与无人机集群智能引导等创新特性。实验结果表明, 在复杂城市与非均匀传播环境中, 该方法在各类采样率下均显著降低构建误差, 尤其在低采样率条件下仍保持稳定且领先的重构精度, 相比典型深度学习模型展现出更强的稀疏观测适应能力。

关键词: 频谱地图; 稀疏观测; 多输出多分辨率; 生成对抗网络; 不确定性建模

中图分类号: TN929.5

文献标志码: A

文章编号: 2095-2163(2026)04-0110-06

Multi-output multi-resolution electromagnetic spectrum mapping method

SHAO Hanrui, LI Zhi

(College of Electronics and Information Engineering, Sichuan University, Chengdu 610065, China)

Abstract: In cognitive radio networks, constructing electromagnetic spectrum maps in under-covered regions is constrained by sparse observations and complex propagation environments. Traditional single-output methods struggle to capture spatial discontinuities and quantify predictive uncertainty. To enhance mapping reliability, this study proposes a two-stage multi-output and multi-resolution spectrum mapping framework. By employing a generative adversarial network to dynamically fuse sparse measurements with learned propagation features, the first stage generates multiple low-resolution candidate maps to quantify uncertainty and constructs an information-value map that guides UAVs toward high-reward sampling locations. The second stage progressively refines the reconstruction using high-resolution supplementary observations. This framework overcomes the limitations of conventional single-output models and integrates uncertainty modeling, multi-resolution progressive optimization, and intelligent UAV swarm guidance. Experimental results demonstrate that the proposed method significantly reduces reconstruction errors across various sampling rates in complex urban and non-uniform propagation environments. The improvement is particularly pronounced under low sampling rates, where the method maintains stable and superior reconstruction accuracy, exhibiting stronger robustness to sparse observations compared with typical deep learning models.

Key words: Spectrum Map; sparse observation; multi-output multi-resolution; generative adversarial network; uncertainty modeling

0 引言

在5G/6G时代无线通信需求持续攀升的背景下, 频谱资源短缺已成为制约网络性能的关键瓶颈, 而在复杂、动态的实际环境中实时掌握电磁态势尤为重要^[1]。作为认知无线电技术的核心, 电磁频谱

地图能够直观展示空间与频率域的功率分布, 为频谱监测、干扰规避与资源优化提供关键支撑^[2]。图1给出了典型的认知无线电频谱测绘场景示意, 然而城市峡谷、山地等非均匀传播环境中, 观测数据往往稀疏且受多径、遮挡与阴影效应影响, 使传统基于几何假设的插值方法难以获得可靠估计。

作者简介: 邵瀚锐(2000—), 男, 硕士研究生, 主要研究方向: 电磁环境感知。

通信作者: 李智(1975—), 男, 博士, 教授, 博士生导师, 主要研究方向: 物联网与边缘计算, 无人系统与群体智能, 频谱压缩感知。Email: lizhi

@scu.edu.cn。

收稿日期: 2025-12-04

哈尔滨工业大学主办 ◆ 专题设计与应用




图 1 认知无线电频谱测绘场景图

Fig. 1 Cognitive radio spectrum mapping scenario

近年来,深度学习成为频谱映射主流,例如 MEGAN 框架^[3]将频谱图重构视为图像补全任务,在欠覆盖区域显著优于 Kriging^[4]方法;自编码器^[5]通过学习阴影衰落与路径损耗分布,在小样本下降低误差;图神经网络则利用建筑物掩膜和邻域拓扑信息增强对视距/非视距环境的建模能力^[6]。尽管这些方法在非均匀场景中表现良好,但普遍依赖单输出模式,存在明显局限,无法量化预测不确定性,易在高风险区域产生偏差。无人机 (Unmanned Aerial Vehicle, UAV) 辅助感知^[7]被广泛用于增强观测密度,通过机动采样扩展覆盖范围,但现有研究多基于贪婪或固定策略规划,如转移学习驱动的 UAV 路径优化或基于数字信息素的搜索机制^[8],均缺乏结合不确定性反馈的闭环控制,难以避免冗余飞行并有效提升测绘效率。这些局限在欠覆盖区域尤为明显:稀疏观测会进一步放大传播不确定性,而现有方法缺乏多输出和多分辨率能力,难以在保证精度的同时实现基于信息价值的逐级重构。为解决这些问题,本文提出一种多输出多分辨率的频谱地图构

建框架,通过生成对抗网络 (Generative Adversarial Network, GAN)^[9]建模传播结构、不确定性量化及无人机集群感知,实现从粗到高分辨率的逐级优化,提升估计精度并减少冗余采样,增强认知无线网络在欠覆盖环境中的态势感知能力。

1 多输出多分辨率电磁频谱地图构建框架

该框架包含两个阶段:

第一阶段 (低分辨率多输出初步映射阶段),利用 UAV 初始稀疏观测数据,结合先验调制归一化残差块 (Prior - Modulated Normalized Residual Block, PMNRB),通过 GAN 生成多张低分辨率候选频谱图,计算功率均值与方差,得到信息价值图,用于指导 UAV 的采样路径。

第二阶段 (高分辨率精细重构阶段),基于第一阶段得到的低分辨率均值图与 UAV 在高价值区域采集的高分辨率观测数据,实现从低分辨率到高分辨率的电磁频谱地图精细重构。

1.1 低分辨率多输出初步映射模块

低分辨率多输出初步映射模块是框架的入口 (如图 2 所示)。输入为 UAV 在初始飞行阶段获取的稀疏功率观测 P_{obs} 及对应掩码 M (例如仅覆盖约 5% 区域的 10×10 低分辨率网格)。该模块的目标是:

- 1) 生成多张低分辨率候选电磁频谱地图,刻画未知区域的多种合理假设;
- 2) 计算功率均值与方差,得到信息价值分布,指导后续 UAV 采样。

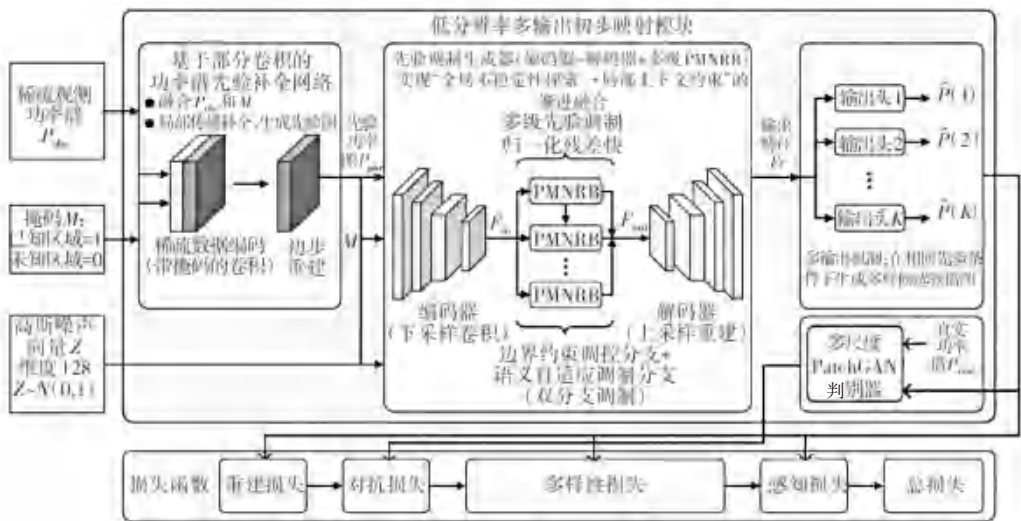


图 2 低分辨率多输出初步映射模块示意图

Fig. 2 Schematic diagram of the low-resolution multi-output preliminary mapping module

模块基于 GAN 构建。生成器采用编码器-解码器结构^[10],输入标准高斯噪声向量 z , 通过多输出机制生成多种频谱分布;判别器采用多尺度 PatchGAN^[11]区分生成与真实谱图的局部结构。对抗训练保证生成结果在统计特征与纹理模式上接近真实场景。整体损失由重建损失 L_{rec} (像素级误差)、对抗损失 L_{adv} (衡量生成图像与真实图像差异)、感知损失 L_{perc} (捕捉高层次传播模式)和多样性损失 L_{div} (鼓励输出间差异)构成,总损失函数为:

$$L_{total} = \lambda_{rec} L_{rec} + \lambda_{adv} L_{adv} + \lambda_{div} L_{div} + \lambda_{perc} L_{perc} \quad (1)$$

其中 λ_{rec} 、 λ_{adv} 、 λ_{div} 、 λ_{perc} 用于调整各部分在总损失中的重要性,从而确保模型在像素恢复、语义一致性和不确定性建模之间找到最佳平衡。在这些损失中,多样性损失是实现“不确定性建模”的关键。通过计算多输出地图间的感知距离,强制网络在相同先验条件下产生显著差异,从而实现“不确定性

建模”。具体而言,对于两张输出地图 \hat{P}_1 和 \hat{P}_2 , 多样性损失定义为:

$$L_{div} = \frac{1}{K} \sum_{k=1}^K \|\phi_k(\hat{P}_1 \odot M) - \phi_k(\hat{P}_2 \odot M)\|_2 \quad (2)$$

其中, ϕ_k 为 VGG 网络^[12]第 k 层的特征提取器, M 为掩码(已知区域为 1,未知区域为 0)。

为避免稀疏观测下“从零生成”带来的偏差,模块通过基于部分卷积(Partial Convolution)^[13]的 U-net 网络^[14]对 P_{obs} 进行预处理,仅在有效区域执行卷积并自适应归一化,抑制无效像素干扰,得到粗略先验图 P_{prior} 。该先验图经过多尺度下采样后注入生成器深层特征,确保重构结果符合真实传播规律。

生成器的核心由多级串联的 PMNRB 构成,PMNRB 结构如图 3 所示,主要目标是实现噪声特征与先验信息的自适应融合。

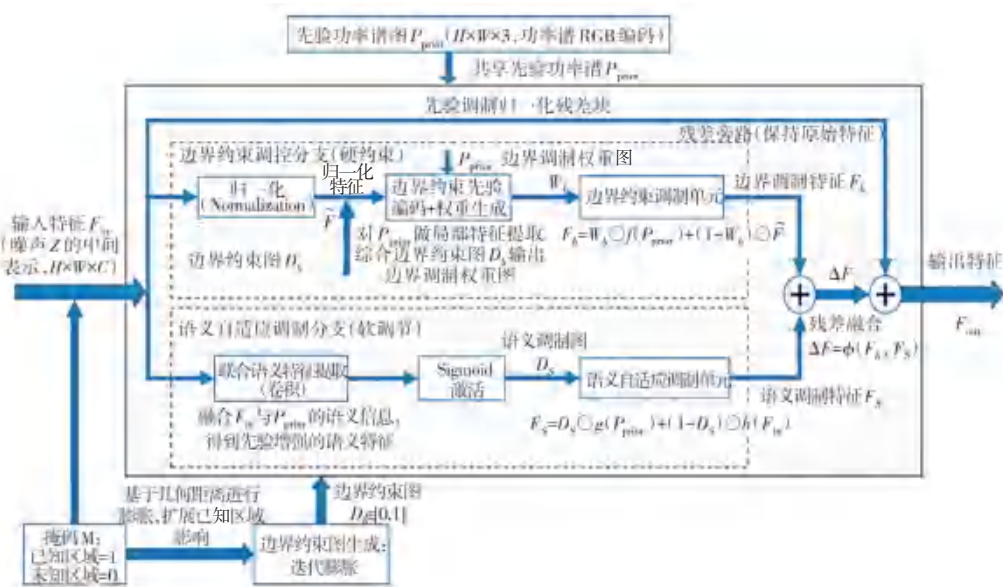


图 3 先验调制归一化残差块结构示意图

Fig. 3 Structural diagram of the PMNRB

其中,边界约束调控分支利用输入掩码生成一系列多尺度边界约束图,用于在靠近观测边界的位置

$$M_i(x, y) = \begin{cases} 1, & \text{如果领域内有至少一个邻点}(x', y') \text{ 满足 } M_{i-1}(x', y') = 1, \\ 0, & \text{其他情况} \end{cases} \quad (3)$$

随后通过差分计算提取该尺度下的边界层:

$$E_i(x, y) = M_i(x, y) - M_{i-1}(x, y) \quad (4)$$

并通过以指数衰减因子 k^{-i} 调制该边界层的影响权重,得到最终的边界约束图:

$$D_b(x, y) = E_i(x, y) \cdot k^{-i} \quad (5)$$

通过这种方式,模型能够显式识别已知-未知交界处的空间结构,并在该区域施加约束,使生成

置强化几何连续性。具体而言,首先对原始掩码执行一次膨胀操作,得到邻域像素的扩展掩码 M_i :

的谱图在边界附近呈现更平滑、语义一致的过渡。

与边界约束调控分支互补,语义自适应调制分支旨在根据不同空间区域的不确定性水平动态调整生成器内部的特征融合方式。该分支将从先验图提取的特征 F_p 与噪声驱动的特征 F_{in} 进行融合,通过卷积与非线性激活生成语义调制图 D_s :

$$D_s = \sigma(\text{Conv}(F_p \oplus F_{in})) \cdot (1 - M) + M \quad (6)$$

其中,⊕表示通道拼接, $\sigma(\cdot)$ 为Sigmoid函数。

两个分支输出的调制信号在残差结构中融合,形成最终特征^[15]。这样一来边界附近更倾向观测及传播先验,远离观测的区域则保留更多随机性与多样化假设,从而在整个低分辨率网格上实现先验约束和多样性探索的平衡。

1.2 信息价值驱动的 UAV 采样模块

多输出初步映射模块生成的 N 张低分辨率候选地图 $\{P_1, P_2, \dots, P_N\}$ 在未知区域往往存在显著差异,这种差异本质上反映了模型对该区域的预测不确定性。信息价值驱动的 UAV 采样模块则以此为基础,构建信息价值分布图,并据此优化 UAV 集群的采样决策。

首先,对多输出地图逐点计算功率均值 P_{mean} 和功率方差 σ^2 , 得到信息价值图 V :

$$P_{\text{mean}}(x, y) = \frac{1}{N} \sum_{i=1}^N P_i(x, y) \quad (7)$$

$$\sigma^2(x, y) = \frac{1}{N} \sum_{i=1}^N (P_i(x, y) - P_{\text{mean}}(x, y))^2 \quad (8)$$

$$V(x, y) = w_1 \cdot P_{\text{mean}}(x, y) + w_2 \cdot \sigma^2(x, y) \quad (9)$$

其中, P_{mean} 描述潜在信号强度和大尺度传播趋势, σ^2 刻画跨输出预测差异。通过加权融合,两者共同形成的信息价值图 V 能够突出那些既可能具有较强信号,又呈现较高预测分歧的区域,使其成为优先观测的高收益候选点。获得 V 后,通过聚类方式选取待测任务点集合^[16]。首先设定阈值 τ , 保留 $V > \tau$ 的高价值像素,再对保留点进行空间聚类(K-means),避免任务点过度集中,聚类中心即作为最终目标点。

为进一步提升采样效率,本文采用基于距离优化的 UAV 任务分配策略^[17]。通过近似求解总飞行距离最小化的分配问题,将目标点合理分配给不同 UAV。随后,UAV 按照分配结果飞向各自任务点,在途中执行功率谱扫描并采集新观测 P_{new} , 同时实时更新观测掩码,为精细重构提供新的有效观测。

1.3 高分辨率精细重构模块

在完成低分辨率多输出初步映射模块的推理,并基于信息价值驱动的 UAV 采样后,系统已获得较为可靠的低分辨率功率谱均值图,并在高价值区域获得补充观测数据。基于这些信息,高分辨率精细重构模块将空间网格从 $M \times M$ (例如 10×10) 提升至 $N \times N$ (例如 100×100)。在这一阶段,模型仍采用 GAN 框架,但输入模式和功能已发生变化:从第一阶段的“多输出+随机噪声驱动”的不确定性探索

模式,转变为“单输出+确定性输入”的精细重构模式。具体而言,UAV 集群根据信息价值分布图采集的高分辨率观测经预处理后转化为 PMNRB 所需的高分辨率先验图;同时,第一阶段得到的 P_{mean} 通过双线性插值重采样至 $N \times N$, 为模型提供可靠的全局能量分布框架,确保高分辨率细节不是从零开始生成。与此配套,第一阶段输出的 σ^2 也经过归一化与上采样,用于调整 PMNRB 中语义调制分支的权重,从而对已高度确定的区域强化先验约束,而对高度不确定区域允许生成器进行更大幅度的细节补偿。

2 实验结果分析

2.1 实验场景设置

为了验证本文提出的多输出多分辨率频谱测绘框架在复杂真实传播环境中的有效性,采用射线跟踪技术构建高保真电磁仿真场景。选择四川大学望江校区作为仿真区域。该区域建筑密度高、结构复杂,既包含开阔广场与运动场,也包含多层教学楼、图书馆及水面等多类典型城市环境,能够充分呈现多径衰落与阴影遮挡等复杂传播特征。仿真范围约为 $1\,000\text{ m} \times 1\,000\text{ m}$, 建筑材料参数基于混凝土、玻璃幕墙等典型材质设置,采用 3D RT 引擎模拟自由空间损耗、反射、绕射与散射等传播机制。

为增强测试的广泛性与方法的鲁棒性,场景中随机布设 13 个全向辐射源,其位置在每轮仿真中随机生成,以覆盖多种传播形态,包括:建筑物密集区、开阔区域以及水面或空旷通道附近。辐射源发射频率为 100 MHz、发射功率为 50 dBm,安装高度为 2 m。UAV 数量设置为 5 架,初始位置在区域内随机分布,并以 200 m 高度执行飞行任务。

2.2 实验结果

图 4 展示了本文两阶段多输出多分辨率频谱构建方法的关键结果。图 4(a) 为真实电磁频谱图,图 4(c) 为 UAV 在随机初始位置获得的稀疏观测数据。基于该观测,第一阶段通过低分辨率多输出映射生成多种候选谱图,如图 4(d) 图 4(f) 所示,有效刻画未观测区域的空间不确定性,并据此得到信息价值图,如图 4(g),图 4(h) 用于指导 UAV 采样任务分配。在补充观测的基础上,第二阶段进行高分辨率精细重构,得到图 4(b) 所示结果,其整体结构与局部细节均与真实分布高度一致,验证了所提方法的有效性。

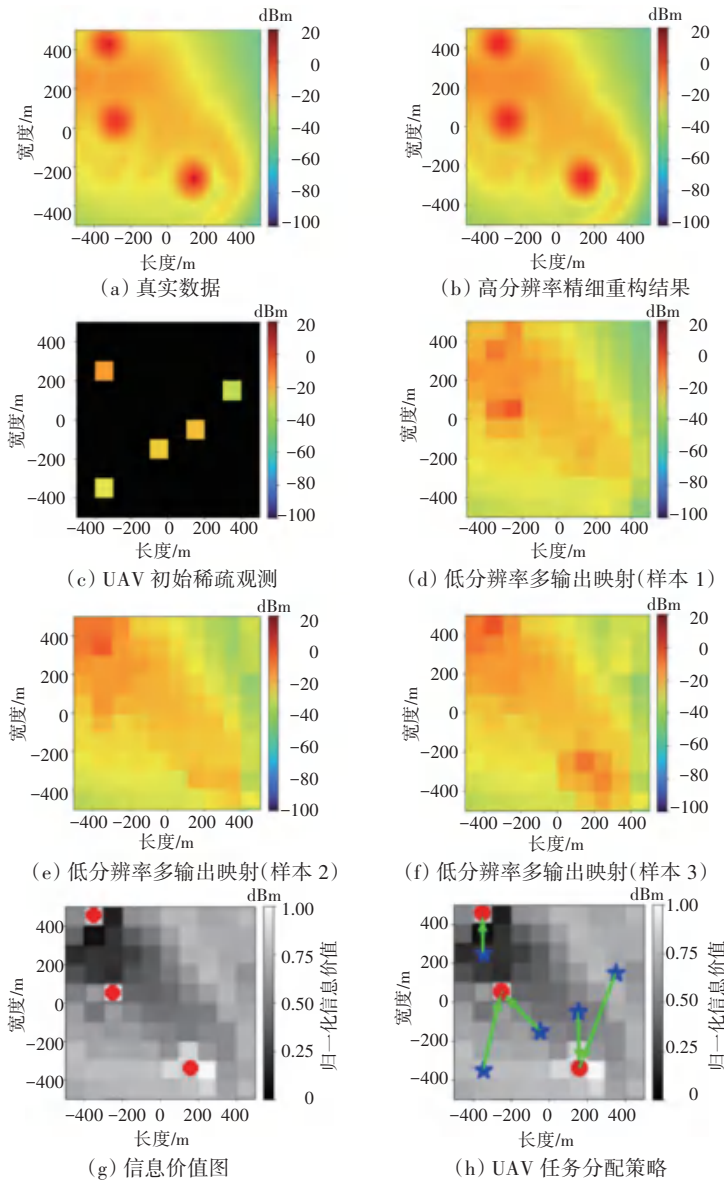


图 4 两阶段频谱地图构建方法结果图

Fig. 4 Results of the two-stage spectrum map construction method

2.3 对比实验

为了直观展示本文提出的两阶段方法的优势,本文引入了 MEGAN 模型、GLGAN 模型^[18]和反距离加权插值法(Inverse Distance Weighting, IDW)算法^[19]作为对比方法。MEGAN 是电磁频谱构建领域首个将电磁数据预测问题转化为电磁图像重构问题的算法;GLGAN 模型则引入了局部与全局判别器结合的双判别器结构;IDW 算法是常用于电磁频谱地图构建的插值方法^[20]。所有算法均在 UAV 连续飞行采样场景下进行对比,首先采用均方根误差(Root Mean Square Error, RMSE)指标评估各算法的构建精度。在采样率从 0.1 递增至 0.8 的设置下,记录每类算法在测试集上评价指标的平均值,得到的实验结果如图 5 所示。可以看出,针对不同的采样率,本文提出方法的构建

效果最好,深度学习模型整体反演效果优于插值算法 IDW。尤其在 0.1 采样率下,本文方法的性能效果尤为明显,相比于 GLGAN, RMSE 下降了 16.7%。

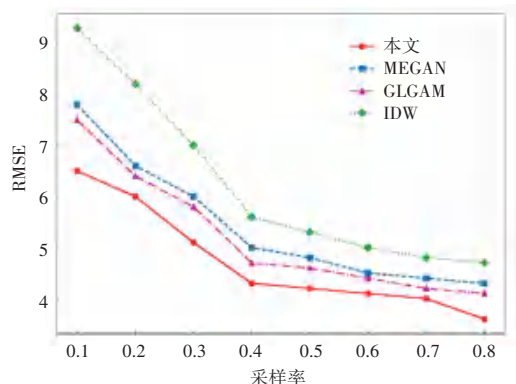


图 5 不同算法的 RMSE 随采样率变化曲线

Fig. 5 RMSE of different algorithm as a function of sampling rate

下面根据峰值信噪比 (Peak Signal-to-Noise Ratio, PSNR) 和结构相似性指数 (Structural Similarity Index, SSIM) 两个指标来进一步评估各算法的性能。PSNR 用于衡量生成的电磁频谱图像与真实图像之间的像素级误差, PSNR 值越高, 表示图像质量越好、重建误差越小。SSIM 则是通过对比图

像的亮度、对比度和结构等高层次特征来评估图像的相似性。其取值范围一般在 0~1 之间, 数值越接近 1, 表明两幅图像在视觉上的相似性越高。表 1 展示了 3 类深度学习方法在不同采样率下的 PSNR 和 SSIM 指标记录, 从表 1 中可以看出本文方法的重构质量最高。

表 1 不同采样率下各算法 PSNR 与 SSIM 对比结果

Table 1 Comparison of PSNR and SSIM among different algorithms at various sampling rates

算法模型	PSNR				SSIM			
	0.1	0.3	0.5	0.7	0.1	0.3	0.5	0.7
本文算法	30.980	32.582	34.366	35.354	0.767	0.832	0.895	0.929
MEGAN	30.313	32.041	33.383	34.376	0.708	0.788	0.851	0.901
GLGAN	30.520	32.229	33.846	34.845	0.726	0.811	0.873	0.910

3 结束语

针对复杂环境中电磁频谱地图构建过程中面临的稀疏观测与传播不确定性问题, 本文提出了一种多输出多分辨率的频谱地图构建框架。通过结合生成对抗网络与先验调制归一化残差块, 该框架实现了从低分辨率初步映射到高分辨率精细重构的逐步优化, 有效提升了估计精度, 并通过信息价值驱动的 UAV 采样策略优化了测量效率。结果表明, 该方法在复杂城市与非均匀传播环境中显著降低了构建误差, 优于现有的典型算法。未来研究可进一步探索如何结合实时数据流, 提升该框架在更大规模动态环境下的应用潜力, 为认知无线网络的高效运行提供技术支持。

参考文献

[1] 夏海洋, 查淞, 黄纪军, 等. 电磁频谱地图构建方法研究综述及展望[J]. 电波科学学报, 2020, 35(4):445-456.

[2] 王登亮, 余志勇, 宋小杉, 等. 分布式无线电磁频谱监测多源信息融合处理技术[J]. 智能计算机与应用, 2024, 14(5):67-74.

[3] HAN X, XUE L, SHAO F, et al. A power spectrum maps estimation algorithm based on generative adversarial networks for underlay cognitive radio networks[J]. Sensors, 2020, 20(1): 311.

[4] 胡炜林, 刘辉, 彭闯, 等. 基于 Kriging 算法的电磁频谱地图构建技术研究[J]. 空军工程大学学报(自然科学版), 2022, 23(3): 26-33.

[5] LU K, BARNES N, ANWAR S, et al. Depth completion auto-encoder[C]//Proceedings of 2022 IEEE/CVF Winter Conference on Applications of Computer Vision Workshops (WACVW). Piscataway, NJ: IEEE, 2022: 63-73.

[6] CHEN G, LIU Y, ZHANG T, et al. A graph neural network based radio map construction method for urban environment[J]. IEEE Communications Letters, 2023, 27(5): 1327-1331.

[7] 白云鹏, 林志鹏, 段洪涛, 等. 面向频谱测绘任务的多无人机

协同航迹规划方法[J]. 信号处理, 2022, 38(12):2563-2571.

[8] 沈东, 魏瑞轩, 茹常剑. 基于数字信息素的无人机集群搜索控制方法[J]. 系统工程与电子技术, 2013, 35(3): 591-596.

[9] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets [J]//Proceedings of International Neural Information Processing Systems. NeurIPS, 2014: 2672-2680.

[10] GOODFELLOW I, BENGIO Y, COURVILLE A, et al. Deep Learning[M]. Cambridge: MIT Press, 2016.

[11] ISOLA P, ZHU J Y, ZHOU T, et al. Image-to-image translation with conditional adversarial networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ: IEEE, 2017: 1125-1134.

[12] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [C]//Proceedings of the 3rd International Conference on Learning Representations. ICLR, 2015: 114.

[13] LIU G, REDA F A, SHIH K J, et al. Image inpainting for irregular holes using partial convolutions[C]//Proceeding of the European Conference on Computer Vision. Cham: Springer, 2018: 85-100.

[14] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation[C]//Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention. MICCAI, 2015: 234-241.

[15] 张晗, 韩宇, 姜航, 等. 基于残差自编码器的电磁频谱地图构建方法[J]. 无线电通信技术, 2023, 49(2): 255-261.

[16] 金峥嵘, 王洁, 陈丹彤, 等. 基于频谱测绘的辐射源定位[J]. 通信技术, 2021, 54(12):2644-2649.

[17] 何杏宇, 付冲, 杨桂松, 等. 基于任务与巡航方向相关性分析的无人机任务分配[J]. 计算机应用研究, 2022, 39(10): 2989-2995.

[18] IIZUKA S, SIMO-SERA E, ISHIKAWA H. Globally and locally consistent image completion[J]. ACM Transactions on Graphics (ToG), 2017, 36(4): 1-14.

[19] 张洁, 段平. 地形因子对反距离加权插值方法(IDW)最优距离指数的影响分析[J]. 地理科学, 2023, 43(7): 1281-1290.

[20] 王梦艺, 盛业华, 黄一昀, 等. 电磁地理环境监测数据空间插值方法[J]. 地球信息科学学报, 2017, 19(7): 872-879.