



DOI:10.12404/j.issn.1671-1815.2405481

引用格式:谢佳伟,余志勇,张羽洁,等.基于空间注意力深度残差网络的细粒度电磁频谱地图构建方法[J].科学技术与工程,2025,25(14):5905-5912.

Xie Jiawei, Yu Zhiyong, Zhang Yujie, et al. Spatial attention deep residual network based fine-grained electromagnetic spectrum map construction method[J]. Science Technology and Engineering, 2025, 25(14): 5905-5912.

电子技术、通信技术

# 基于空间注意力深度残差网络的细粒度电磁频谱地图构建方法

谢佳伟<sup>1,2</sup>, 余志勇<sup>1\*</sup>, 张羽洁<sup>1</sup>, 曹俊杰<sup>1,3</sup>, 杨剑<sup>1</sup>

(1. 火箭军工程大学作战保障学院, 西安 710025; 2. 中国人民解放军 96743 部队, 天水 741020;  
3. 国防科技大学信息通信学院, 武汉 430000)

**摘要** 当前,电磁频谱资源的高效利用是无线通信领域的热点问题,而电磁频谱地图(electromagnetic spectrum map, EMSM)能够可视化展示某任务区域内的频谱使用情况,为无线网络优化工作提供有效支持。针对场景复杂且空间点位监测数据有限条件下生成细粒度 EMSM 难度大的问题,提出了一种增强空间注意力特征块(enhanced spatial-attention feature block, ES-AFB)的改进深度残差网络(deep residual networks, DRN)模型,借鉴图像超分辨率思想并利用 EMSM 的强空间特性,设计深度残差网络提取 EMSM 的相关性和频谱特征,利用增强空间注意力特征块挖掘粗粒度 EMSM 的内在隐含空间特征,再通过网络的多层上采样模块重构数据尺寸,从而达到更好的细粒度图像恢复效果,能够利用有限的粗粒度监测数据生成高质量的细粒度 EMSM。仿真实验结果验证了算法的有效性,利用实测数据生成 EMSM 的均方根误差不超过 3%。

**关键词** 电磁频谱地图; 电磁频谱图; 深度残差网络; 空间注意力; 细粒度

中图分类号 TN911.7;

文献标志码 A

## Spatial Attention Deep Residual Network Based Fine-Grained Electromagnetic Spectrum Map Construction Method

XIE Jia-wei<sup>1,2</sup>, YU Zhi-yong<sup>1\*</sup>, ZHANG Yu-jie<sup>1</sup>, CAO Jun-jie<sup>1,3</sup>, YANG-Jian<sup>1</sup>

(1. School of Operational Support, Rocket Force University of Engineering, Xi'an 710025, China;

2. Chinese People's Liberation Army Unit 96743, Tianshui 741020, China;

3. College of Information and Communication, National University of Defence Technology, Wuhan 430000, China)

**[Abstract]** The efficient utilization of electromagnetic spectrum resources has become a significant concern in the domain of wireless communications, with EMSM(electromagnetic spectrum map) playing a crucial role in visually representing spectrum usage within a specific task area and providing valuable support for the optimization of wireless networks. To address the challenges associated with generating fine-grained EMSMs under conditions of complex scenes and limited spatial point monitoring data, an improved DRN(deep residual network) model, ES-AFB(enhanced with a spatial attention feature block), was proposed. This model drew inspiration from image super-resolution techniques and leveraged the strong spatial characteristics of EMSMs to design a deep residual network capable of extracting the correlation and spectral features of EMSMs. The enhanced spatial attention feature block was utilized to mine the intrinsic implicit spatial features of coarse-grained EMSMs. Subsequently, the data size was reconfigured through the network's multilayer up-sampling module, enabling the achievement of a more effective fine-grained image restoration. This approach allows for the generation of high-quality fine-grained EMSMs using limited coarse-grained monitoring data. The effectiveness of the algorithm is validated through simulation experiments, with the root-mean-square error of the EMSMs generated from actual data being found to be no more than 3%.

**[Keywords]** electromagnetic spectrum map; spectral map; deep residual network; spatial attention; fine-grained

收稿日期: 2024-07-22; 修订日期: 2025-02-28

基金项目: 国家自然科学基金(62071481, 61501471)

第一作者: 谢佳伟(1993—), 女, 汉族, 湖北黄冈人, 硕士。研究方向: 无线电通信与电磁频谱感知。E-mail: jiaweixie9301@163.com。

\* 通信作者: 余志勇(1975—), 男, 汉族, 湖北恩施人, 博士, 教授。研究方向: 抗电磁干扰与信号处理。E-mail: yutouzy@163.com。

伴随着全面信息化的推进,世界各地通过多种通信方式逐渐联结在了一起。无线通信则作为一种大范围通信方式在其中扮演了至关重要的角色。因此,如何使用有限的电磁频谱资源来进行高效的无线通信成为当今世界各国的热点研究课题<sup>[1]</sup>。

电磁频谱地图 (electromagnetic spectrum map, EMSM) 是一种将当前区域内的电磁频谱资源以地图的形式进行展示的数据表达方式<sup>[2]</sup>。具体地说,电磁频谱地图将区域的信号强度投影到其对应的各个地理坐标点上,用以表征区域内信号强度的分布情况。通过电磁频谱地图可以了解当前区域的频谱使用情况以及空间中各位置的信道使用情况,从而为后续的频谱分配、降低通信干扰等工作奠定基础。所以,构建准确的电磁频谱地图可以说是电磁频谱研究的一项重要基础工作<sup>[3]</sup>。

当前获取电磁频谱地图的方式一般是通过在区域内放置多个信号传感器的方式来获取该区域内多个点的信号强度。但受限于复杂地理环境和传感器成本的制约,通过这种方式获取的电磁频谱地图往往是粗粒度的,无法准确地反映该无线电任务区域的电磁频谱态势。因此,通过粗粒度的电磁频谱地图来生成细粒度的电磁频谱地图成为了解无线电任务区域电磁频谱态势的关键技术<sup>[4]</sup>。

此前,研究者们主要使用传统的空间频谱态势推断方法来进行电磁频谱地图的构建。其主要可以分为基于空间插值的直接构建法、基于参数构建的间接构建法和结合了以上方法的混合构建法<sup>[5-6]</sup>。Janakara 等<sup>[7]</sup>基于 Kriging 方法提出了一种相对最优频谱地图测绘方法。Denkovski 等<sup>[8]</sup>比较了不同反距离权重插值法在观测数据处于不同时段和空域前提下的性能分析。文献<sup>[9]</sup>提出了一种基于 Shepard 方法改进优化的插值算法,提高了算法效率并增强了稳定性。然而,传统的空间频谱态势构建方法都是基于各类插值算法或依赖于对传播现象进行建模。但在实际的无线电传播环境中往往存在复杂的电磁环境影响或无线电信号干扰,任务区域的扩大导致的算法复杂性急剧上升或不适当的建模方法导致的构建准确性下降使得基于传统的空间频谱态势推断方法难以得到广泛运用<sup>[10-11]</sup>。

近年来,深度学习由于其对特征提取的高效性在图像处理相关领域得到了广泛的运用。张晗等<sup>[12]</sup>提出一种残差自编码器用于构建电磁频谱地图;Han 等<sup>[13-14]</sup>首次提出将生成对抗网络应用于频谱测绘图构建;Levie 等<sup>[15]</sup>提出了 RadioUNet 的网络结构,采用 Unet 这种特殊的结构构建自编码器。

而电磁频谱地图可以看作是由电磁频谱态势构成的一种特殊图像,据此,通过深度学习方法来提取监测数据中所包含的频谱数据分布特征从而构建电磁频谱地图将是一种克服传统方法不足的有效手段<sup>[16]</sup>。并且,通过学习的方式,不断将监测样本数据转化为图的形式输入深度神经网络中,由神经网络来完成从输入监测图像到输出电磁频谱地图的映射过程与图像处理领域中的超分辨率技术保持了高度一致性,即输入低分辨率图像来上采样得到高分辨率图像的过程对应着输入粗粒度电磁频谱地图来得到细粒度电磁频谱地图的过程<sup>[17]</sup>。

与一般图像不同的是,电磁频谱地图具有非常强的空间内在相关性。因为空间中的频谱特征通常与该区域的信号源具有一致性。无线电任务区域中的信号辐射源在电磁频谱地图中会存在非常明显的特征并由此影响其整个区域的电磁频谱态势。针对该特点,现提出基于空间自注意力深度残差网络的细粒度电磁频谱地图构建方法。具体地说,为了解决细粒度电磁频谱地图构建问题。设计一个深度残差网络来提取输入的粗粒度电磁频谱地图中的相关性,通过推断网络来预测频谱特征,并使用一个设计的多层上采样模块来构建细粒度的电磁频谱地图。针对电磁频谱地图的空间特征在深度残差网络中设计一个空间自注意力模块来进一步提取信号辐射源特征,从而提升网络构建准确性。通过实验分析本文方法在多个信号辐射源以及不同数量的传感器监测数据下生成的细粒度电磁频谱地图的准确性。

## 1 问题建模

在本文所考虑的由粗粒度电磁频谱地图生成细粒度电磁频谱地图问题中,粗粒度电磁频谱地图是根据在空间中分布的信号监测传感器生成的,传感器生成的数据为其在该位置上接收到的信号强度值 (received signal strength, RSS)<sup>[18]</sup>。本文研究考虑了一个如图 1 所示的一个一般性电磁环境场景,在该场景中无线电任务区域  $A$  内随机分布有  $X$  个不同类型的信号辐射源,并均匀分布有  $K$  个信号监测传感器。这些传感器会记录接收到的信号强度值然后通过物联网等方式将其汇总到数据融合中心,从而生成该区域的粗粒度电磁频谱地图。

为了使用超分辨率技术来进行细粒度电磁频谱地图的构建,将区域  $A$  离散化为由  $i \times j$  个传感器构成的网格,其中  $i \times j = K$ , 每个传感器位于网格的节点上。用  $S_x$  表示信号辐射源  $x$  的位置,信号强度




图1 无线电任务区域内信号源及传感器分布示意图  
Fig. 1 Schematic distribution of sources and sensors in the radio mission area

值为  $P_x$ ; 用  $R_{m,n}$  表示网格中第  $m$  行第  $n$  列的空间位置, 其中  $m$  和  $n$  满足  $1 \leq m \leq i$  且  $1 \leq n \leq j$ 。因此, 传感器  $R_{m,n}$  处接收的信号强度  $RSS_{m,n}$  可以表示为所有信号辐射源在该空域位置处产生的信号强度之和, 即

$$RSS_{m,n} = \sum_{x=1}^X \frac{P_x}{d_{x,m,n}^\alpha} \quad (1)$$

式(1)中:  $d_{x,m,n}^\alpha$  为信号源  $x$  与传感器  $R_{m,n}$  的距离, 其中  $\alpha$  为路径损失指数。

因此, 真实电磁频谱地图可以表示为  $T$ , 而粗粒度电磁频谱地图可以表示为一个二维张量  $T'$ , 其元素  $T'_{m,n}$  表示位置  $(m,n)$  处的  $RSS_{m,n}$ 。

如图2所示, 将粗粒度电磁频谱图构建为细粒度电磁频谱地图的过程可以视为将低分辨率的二

维张量  $T'$  转化为高分辨率的二维张量  $\hat{T}$  的过程。已知  $T'$  的尺寸为  $i \times j$ , 若  $\hat{T}$  的尺寸为  $ri \times rj$ , 其中  $r$  为超分辨率提升比例系数, 因此使用粗粒度电磁频谱地图构建  $r$  倍细粒度电磁频谱地图的问题可以表示为

$$\hat{T} = \varphi(T'; \theta) \quad (2)$$

式(2)中:  $\varphi$  为使用的超分辨率算法; 参数  $\theta$  则通过神经网络训练获得。

## 2 引入 ES-AFB 的深度残差网络的细粒度电磁频谱地图构建方法

### 2.1 深度残差网络结构

为了更好地适应电磁频谱地图的强空间相关性, 本文研究提出了如图3所示网络结构用于准确构建细粒度电磁频谱地图。该网络结构框架分为3个主要阶段: 浅层特征提取、深层特征提取和重建阶段。

在浅层特征提取阶段, 首先使用卷积操作从输入的粗粒度电磁频谱地图中提取浅层特征, 这不仅稳定了训练过程, 还提高了特征提取的精度。接下来, 使用若干个注意力特征块 (attentional feature block, AFB) 模块进行深层特征提取<sup>[19]</sup>。在最终的重建阶段, 本文研究使用两个具有不同滤波器尺寸的卷积层来提取多尺度特征, 并通过多个子像素层对粗粒度电磁频谱地图特征进行上采样, 输出细粒度电磁频谱地图。




图2 由粗粒度电磁频谱地图构建细粒度电磁频谱地图

Fig. 2 Construction of fine-grained electromagnetic spectrum from coarse-grained electromagnetic spectrum maps

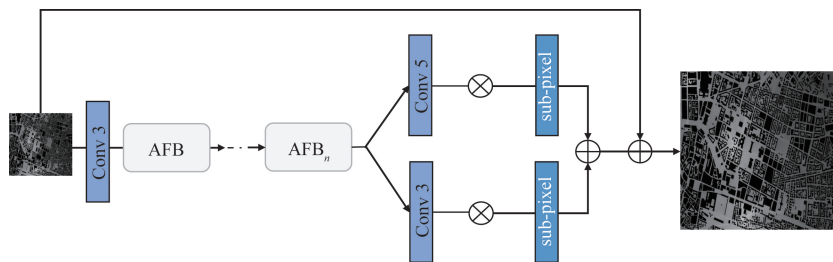


图3 基于空间注意力深度残差网络的频谱态势推断方法网络架构

Fig. 3 Network architecture for spectral posture inference methods based on spatial attention deep residual networks

## 2.2 增强空间注意力特征块

本文提出的注意力特征块 (AFB) 结构如图 4 所示, 它由两个卷积层、ReLU 激活层和增强空间注意力 (enhanced spatial attention, ESA) 模块组成。

该结构通过跳跃连接实现了低级特征和高级特征间的恒等映射, 有助于维持特征在传递过程中的完整性, 同时避免深层网络训练中常见的梯度消失问题。在经过浅层特征提取阶段后, 张量数据进一步通过串联的多个 AFB 模块进行深层特征提取, 来生成高级特征图。为了加强网络的特征提取能力并提高模型对电磁频谱地图中隐性特征的敏感性, 在每个 AFB 模块的卷积层后增设了 ESA 模块。表 1 和表 2 分别表示注意力特征块 (AFB) 和增强空间注意力模块 (ESA) 的具体参数设置。

具体来说, 如图 5 所示该模块首先通过卷积层对输入特征进行压缩, 以减少参数量同时保留重要的特征信息。接着, 应用步长为 2 的卷积操作和  $2 \times 2$  的最大池化, 这一组合不仅降低了特征的空间维度, 还增强了模型的抽象能力。随后, 通过组卷积进行  $7 \times 7$  的最大池化, 进一步加强了模型对于局




图 4 AFB 的结构

Fig. 4 AFB structure

表 1 注意力特征块 (AFB) 的参数设置

Table 1 Attention feature block (AFB) parameter settings

层名称	输入尺寸	输出尺寸
$3 \times 3$ 卷积层	$H \times W \times 64$	$H \times W \times 64$
$3 \times 3$ 卷积层	$H \times W \times 64$	$H \times W \times 64$
ESA 模块	$H \times W \times 64$	$H \times W \times 64$

注:  $H$  为高度;  $W$  为宽度; 64 为通道数。

表 2 增强空间注意力模块 (ESA) 的参数设置

Table 2 Enhanced spatial attention (ESA) module parameterization

层名称	输入尺寸	输出尺寸
$1 \times 1$ 卷积层	$H \times W \times 64$	$H \times W \times 16$
$3 \times 3$ 卷积层	$H \times W \times 16$	$H/2 \times W/2 \times 16$
池化层	$H/2 \times W/2 \times 16$	$1 \times 1 \times 16$
$3 \times 3$ 卷积层	$1 \times 1 \times 16$	$1 \times 1 \times 16$
$3 \times 3$ 卷积层	$1 \times 1 \times 16$	$1 \times 1 \times 16$
$3 \times 3$ 卷积层	$1 \times 1 \times 16$	$1 \times 1 \times 16$
上采样层	$1 \times 1 \times 16$	$H \times W \times 16$
$1 \times 1$ 卷积层	$H \times W \times 16$	$H \times W \times 64$
Sigmoid 激活层	$H \times W \times 16$	$H \times W \times 64$




图 5 ESA 的结构示意图

Fig. 5 Schematic of enhanced spatial attention structure

部区域的敏感度。最后, 该模块通过卷积和 Sigmoid 激活函数结合, 生成一个特征权重图, 该权重图作为掩模应用于原始输入特征, 从而突出更为重要的特征区域。

## 2.3 多尺度上采样模块

考虑到不同频率的信号辐射源在不同采样尺度下对特征提取具有不同的贡献度<sup>[20]</sup>, 本文研究提出了使用如图 6 多尺度的上采样模块来进行电磁频谱地图的上采样, 从而生成准确的细粒度电磁频谱地图。

采用双分支设计, 分别使用  $3 \times 3$  和  $5 \times 5$  的卷积核, 以捕捉不同尺度的图像特征。通过设置这些卷积核在两个旁路之间共享信息, 网络能够综合利用不同尺度的特征信息, 增强特征的表达能力。为了在保持网络性能的同时减少参数量和计算复杂度, 选用组卷积技术替代传统的卷积操作。组卷积通过将输入特征图分组, 并在每个组内独立进行卷积操作, 有效地减少了模型的参数和计算量。表 3 表示多尺度上采样模块的具体参数设置, 其中  $N$  为通道数 ( $N = \text{放大倍数} \times \text{放大倍数} \times 3$ )。

在上述模块的作用下, 输入的粗粒度电磁频谱地图数据经过空间注意力深度残差网络模型的处理得到相应的细粒度电磁频谱地图数据。网络将通过反向传播来进行训练, 所采用的损失函数为真




图 6 多尺度上采样模块

Fig. 6 Multi-scale up-sampling module

表 3 多尺度上采样参数设置

Table 3 Sampling parameter settings on multiple scale

层名称	输入尺寸	输出尺寸
$3 \times 3$ 组卷积层	$H \times W \times N$	$H \times W \times N$
$5 \times 5$ 组卷积层	$H \times W \times N$	$H \times W \times N$
上采样层	$H \times W \times N$	$H \times W \times 3$

实电磁频谱地图  $T$  与推理结果  $\hat{T}$  之间的均方根误差,网络模型的训练算法如下。

#### 算法1 空间注意力深度残差网络模型训练算法

1. 初始化训练轮数  $N_{epoch}$ 、批次大小  $N_{batch}$ 、训练数据数量  $N_{train}$ 、学习率  $l_r$ 、网络参数  $\theta$ 、上采样倍率  $r$
2. 初始化 AFB 模块个数  $n$
3. 循环,共训练  $N_{epoch}$  个轮次:
  4. 循环,共迭代  $(N_{train} N_{batch})$  次:
    5. 从训练数据中采样  $N_{batch}$  个数据,输入数据  $D_0$
    6. 对  $D_0$  进行卷积,得到  $D_1$
    7. 进行 AFB 模块操作,重复  $n$  次:
    8. 对  $D_1$  进行卷积得到  $D_2$  送入 ESA 模块:
    9. 对  $D_2$  进行卷积得到  $D_3$
    10. 对  $D_3$  进行卷积、池化及上采样后得到  $D_4$
    11. 拼接  $D_3$  和  $D_4$  得到  $D_5$
    12. 对  $D_5$  进行卷积操作后,与  $D_2$  进行叉乘得到  $D_6$
    13. 拼接  $D_1$  和  $D_6$ , 得到  $D_7$
    14. 得到经过 AFB 模块操作后的特征  $F_{AFB}$
    15. 对  $F_{AFB}$  进行多路  $r$  倍上采样操作,得到数据  $D_{up1}$  和  $D_{up2}$
    16. 拼接  $D_{up1}$  和  $D_{up2}$  得到  $D_{up}$
    17. 拼接  $D_{up}$  和  $D_0$ , 得到推理结果  $\hat{T}$
    18. 计算损失  $L(\theta) \leftarrow \|T - \hat{T}\|_2^2$
    19. 更新网络参数  $\theta$
    20. 结束该次迭代
21. 结束循环,得到训练好的神经网络

## 3 实验结果与分析

实验部分使用由 Altair 软件生成的仿真数据集来进行模型的训练与验证。本节将介绍数据的生成过程并通过实验来对本文方法从各个方面进行验证与评估。

### 3.1 数据生成与实验设置

如前文所述,监测传感器接收的监测数据为该网格的信号强度值(RSS),影响接收 RSS 值的主要因素为各信号辐射源的频率与路径损失指数。考虑到实际信号传播过程中会受到复杂地形环境以及噪声的影响,在实验设置中引入了阴影衰落模型与噪声模型。在考察预测模型是否有效而不关心电波传播衰减精度的前提下,针对频谱传感器接收功率的衰减,本文研究仅考虑电波传播的路径损耗和阴影衰落。

#### 3.1.1 路径损耗模型的选择

仿真实验使用对数距离路径损耗模型对任务区域的路径传播损耗进行建模,路径损耗模型为

$$R_{ss} = P_i + K - 10n \lg \frac{d}{d_0} \quad (3)$$

式(3)中: $P_i$  为辐射源发射功率,其多个辐射源参考区间为 20 ~ 60 dBm;  $K$  是与发射天线增益有关的常数,一般使用  $d_0$  处的实测功率值来表示;  $d_0$  为天

线远场距离,是一个参考距离常数;  $d$  为接收机与辐射源位置的实际距离;仿真实验中,将目标任务进行了网格化后,取  $d_0 = 1$  m 表示电波传播的路径损耗以网格为单位进行衰减;  $n$  为随环境变化的路径损耗指数,市郊区常用的取值范围为 2.7 ~ 3.5, 实验中  $n = 3$ 。

#### 3.1.2 阴影衰落模型的选择

仿真实验使用对数正态阴影衰落模型即 Rician 模型对区域的阴影衰落进行建模,大量室外信道表明标准差  $\sigma_{sdw}$  的范围在 4 ~ 13 dB,为不失一般性,实验中均值和标准差分别为  $\mu_{sdw} = 0, \sigma_{sdw} = 5$  dB。

#### 3.1.3 加性高斯白噪声

噪声模型为高斯模型,无线电任务区域的环境高斯白噪声功率设为 -90 dBm。

因此,传感器接收到的信号强度  $RSS_{m,n}$  可以表示为来自多个信号辐射源的接收功率的总和,具体参数设置如表 4 所示。

表 4 实验参数设置

Table 4 Experimental parameter setting

参数	值
区域范围 $A/(km \times km)$	2.2 × 3.2
发射功率 $P_i/dBm$	[20,60]
频率 $f/MHz$	[900,1 800]
阴影衰落标准差 $\sigma_{sdw}/dB$	5
路径损耗因子 $n$	3
噪声功率 $\xi/dBm$	-90

在生成实验数据时,通过在上述区域中随机选择大小为 300 m × 300 m 范围的区域进行数据生成。每隔 1 m 设置进行数据收集,将其生成的数据进行汇总多次采样后形成分辨率为 300 × 300 像素的细粒度电磁频谱地图作为样本真实值,然后进行不同等级的下采样(down-sampling)来得到不同粒度的粗粒度电磁频谱地图以供测试和训练。每次数据生成时均改变选择的区域位置、信号辐射源数量与发射功率以及频率,从而保持样本的多样性。最终生成的训练集、验证集和测试集的样本数据量分别为 3 200、1 600 和 800。

### 3.2 评估指标

为了评价 EMSM 重建的精度,采用峰值信噪比(PSNR)和平均绝对百分比误差(MAPE)作为性能评价指标。峰值信噪比表示为

$$PSNR = 10 \lg \frac{MAX^2}{MSE} \quad (4)$$

式(4)中:PSNR 为用于衡量重建图像与原始图像之间的差异,它通常用于图像质量评价,dB;MAX 为图像像素值的最大可能值;MSE 为原始图像和重建图像之间的均方误差。

其中平均绝对百分比误差表示为

$$\text{MSE} = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n [T(i,j) - \hat{T}(i,j)]^2 \quad (5)$$

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{A_i - F_i}{A_i} \right| \times 100\% \quad (6)$$

式中： $T$ 、 $\hat{T}$ 分别为某时隙的原始电磁频谱地图和重建预测电磁频谱地图； $m$ 和 $n$ 为图像的高度和宽度；MAPE为用于衡量预测值与监测值之间的误差比例； $A_i$ 为第 $i$ 个监测值； $F_i$ 为第 $i$ 个预测值； $n$ 为监测值的总数。

### 3.3 结果与分析

所提出的基于空间注意力深度残差网络的细粒度电磁频谱地图生成方法目的是在传感器数量有限的情况下使用针对性改进的超分辨率网络来高效提取粗粒度电磁频谱地图中的特征生成细粒度电磁频谱地图<sup>[21]</sup>。选用双三次插值算法(Bicubic)、亚像素卷积神经网络(ESPCN)和超分辨率深度残差网络(SRResNet)三种具有代表性的超分辨率方法作为对比实验来评估本文方法的有效性。图7为使用不同的方法进行细粒度频谱地图生成的效果示意图,可以看出本文方法对比其他方法更加接近真实的频谱地图。

为了研究不同的采样率对各类方法生成的频谱地图还原质量的影响,在实验中选择了采样率分别为0.5、0.25、0.167和0.1的不同测试集数据进行测试。根据图8可以看出,随着采样率的下降,各方法的PSNR值均有下降;但是,本文方法在不同的采样率下相较其他方法仍然保持着优势地位,在采

样率为0.1时该方法的PSNR值为23.15 dB,表明本文方法能够有效地利用不同采样率下得到的粗粒度频谱地图来还原生成细粒度频谱地图,并且在较低的采样率,即布置较少传感器的情况下仍然能够还原出高质量的频谱地图。

图9为不同采样率下各方法的MAPE指标变化情况,用于表示各方法使用粗粒度频谱地图生成的细粒度频谱地图的与真实频谱地图的误差情况。可以看出,在采样率从0.5逐渐下降至0.1的过程中,本文方法的MAPE值始终低于其他对比方法,且随着采样率的下降该优势表现得更为明显。在采样率为0.1时,本文方法相较于Bicubic基线方法的MAPE值少了0.27,性能提升明显。这与PSNR指标的情况表现一致。

由此可以说明本文方法在不同的采样条件下由粗粒度电磁频谱地图生成细粒度电磁频谱地图时均优于对比方法,并且随着采样率的下降本文方法对比其他方法的优势进一步扩大——在放置较少传感器的情况下仍能进行相对准确的细粒度电磁频谱地图的生成,相较其他方法具有更好的实际运用价值。

在进行电磁频谱地图生成时,区域内存在的多个辐射源会使得区域中的电磁环境变得更为复杂。因此还讨论了在辐射源数量逐渐增加的情况下,各方法的性能变化。

为了进一步验证本文研究中所使用的ESA结构和多尺度上采样模块对细粒度频谱地图生成性能提升的贡献,分别使用在本文方法中移除ESA结

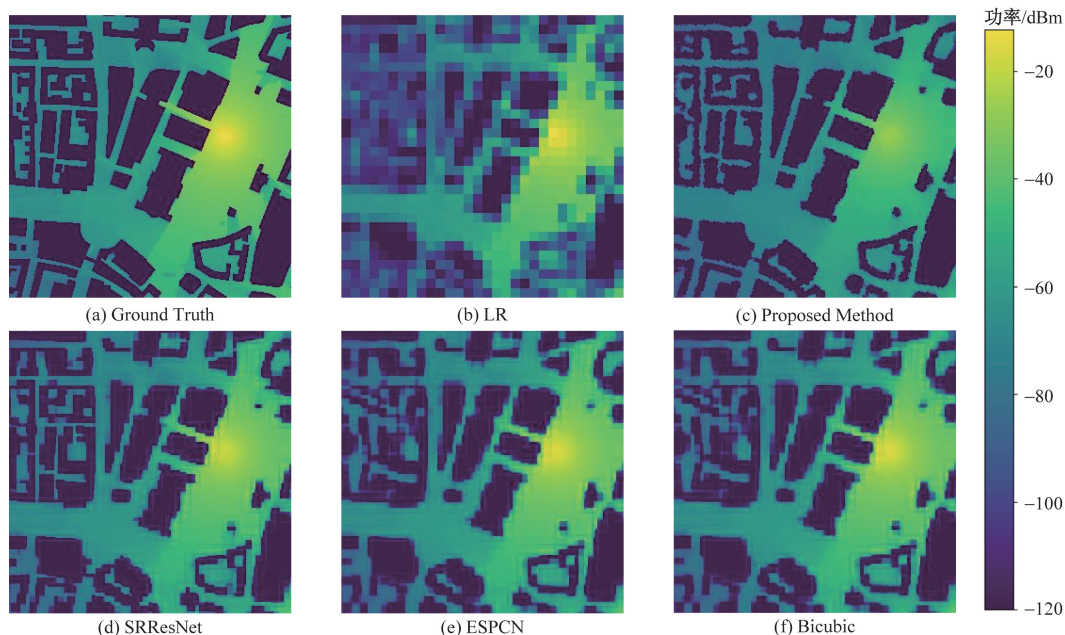


图7 不同方法构建的电磁频谱地图可视化效果图

Fig. 7 Visualization effect of electromagnetic spectrum maps constructed by different methods




图 8 不同采样率情况下 PSNR 性能指标示意图

Fig. 8 Schematic representation of PSNR performance indicators for different sampling cases

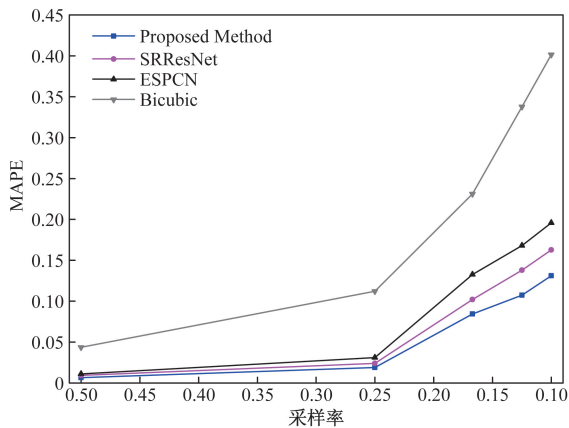


图 9 不同采样率情况下 MAPE 性能指标示意图

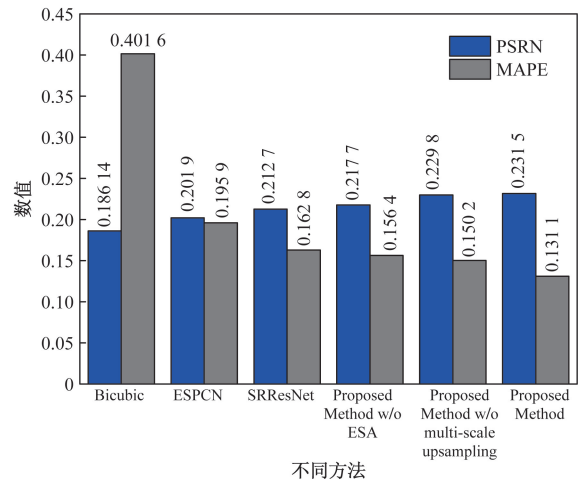
Fig. 9 Schematic representation of MAPE performance index at different sampling rates

构和多尺度上采样模块的方法在采样率为 0.1 的情况下来进行性能对比。

从图 10 中可以看出,本文方法与移除结构后的 PSNR 分别为 21.77、22.98 和 23.15, MAPE 分别为 0.156 4、0.150 2 和 0.131 1,并且都优于其他对比方法。这说明所使用的两种改进结构对于生成细粒度频谱地图的性能提升均有贡献。并且 ESA 结构对于性能的提升有着更高的贡献,这表明 ESA 结构能够更有效地提取空间中不同位置信号源所带来的特征影响,验证了所提出的空间注意力机制来优化深度残差网络的细粒度电磁频谱地图生成方法的有效性。

#### 4 结论

针对复杂场景且空间监测数据有限条件下生成细粒度 EMSM 难度大的问题,提出了一种增强空间注意力特征块(ES-AFB)的改进深度残差网络(DRN)模型生成细粒度 EMSM 的方法。该方法使



PSNR 为峰值信噪比;MAPE 为平均绝对百分比误差

图 10 消融实验示意图

Fig. 10 Ablation experiment

用图像超分辨率的思想,设计深度残差网络提取 EMSM 的相关性和频谱特征,结合电磁频谱地图本身空间特征性强的特点在残差模块中引入空间注意力机制(增强空间注意力特征块)来加强对频谱态势特征的学习,再通过网络的多层上采样模块重构数据尺寸,从而达到更好的细粒度图像恢复效果,能够利用有限的粗粒度监测数据生成高质量的细粒度 EMSM。将本文方法与几种基线方法进行了比较,并使用多项指标对本文方法的性能进行了评估。仿真结果表明,本文方法在生成细粒度电磁频谱地图时对比其他方法具有明显优势,其峰值信噪比 PSNR 提高 2~5 dB, MAPE 降低 3%~27%。在放置较少传感器的情况下仍能进行相对准确的细粒度电磁频谱地图的生成,相较其他方法具有更好的实际运用价值。

#### 参 考 文 献

[1] 雷瑶瑶,白迪,杨春勇,等. 面对分布式多域电磁态势感知的射频传感器设计[J]. 科学技术与工程, 2024, 24(11): 4567-4573.  
 Lei Yaoyao, Bai Di, Yang Chunyong, et al. Design of RF sensor facing distributed multi-domain electromagnetic situational awareness[J]. Science Technology and Engineering, 2024, 24(11): 4567-4573.

[2] 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.  
 Xia Haiyang, Cha Song, Huang Jijun, et al. Review and prospect of electromagnetic spectrum map construction method[J]. Journal of Radio Wave Science, 2020, 35(4): 445-456.

[3] Zhang T, Du Z, Wang X, et al. Joint optimization of sensor deployment and spectrum data completion for radio map construction[J]. IEEE Signal Processing Letters, 2024, 31: 1289-1293.

[4] Wang J, Zhu Q M, Lin Z P, et al. Sparse Bayesian learning-based

- 3D radio environment map construction-sampling optimization, scenario-dependent dictionary construction, and sparse recovery[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2024, 10(1): 80-93.
- [5] 徐浩然, 王红军, 赵文元. 电磁频谱地图构建中的空间插值方法综述[J]. *电讯技术*, 2025, 65(1): 141-152.  
Xu Haoran, Wang Hongjun, Zhao Wenyuan. A review of spatial interpolation methods in electromagnetic spectrum map construction[J]. *Telecommunications Technology*, 2025, 65(1): 141-152.
- [6] 查淞, 夏海洋, 黄纪军, 等. 基于监测数据的电磁频谱地图构建与验证[J]. *国防科技大学学报*, 2023, 45(3): 171-178.  
Cha Song, Xia Haiyang, Huang Jijun, et al. Construction and validation of electromagnetic spectrum map based on monitoring data[J]. *Journal of National University of Defence Technology*, 2023, 45(3): 171-178.
- [7] Janakaraja P, Wang P, Chen Z. Towards cloud-based crowd-augmented spectrum mapping for dynamic spectrum access[C]//25th International Conference on Computer Communication and Networks (ICCCN). Waikoloa: ICCCN, 2016: 1-7.
- [8] Denkovski D, Atanasovski V, Gavrilovska L, et al. Reliability of a radio environment map: case of spatial interpolation techniques[C]//7th International ICST Conference on Cognitive Radio Oriented Wireless Networks and Communications(CROWNCOM). Stockholm: ICST, 2012: 248-253.
- [9] 宇然, 常俊, 宗容, 等. 基于改进空间插值的无线电环境地图生成技术[J]. *电子技术应用*, 2018, 44(3): 103-107.  
Zi Ran, Chang Jun, Zong Rong, et al. Radio environment map generation technique based on improved spatial interpolation[J]. *Electronic Technology Applications*, 2018, 44(3): 103-107.
- [10] 陶诗飞, 吴昱江, 罗佳, 等. 基于反障碍距离加权的复杂场景电磁频谱地图构建方法[J]. *电子与信息学报*, 2024, 24(8): 15-18.  
Tao Shifei, Wu Yujiang, Luo Jia, et al. Electromagnetic spectrum map construction method for complex scenes based on anti-obstacle distance weighting[J]. *Journal of Electronics and Information*, 2024, 24(8): 15-18.
- [11] 张玥. 认知无线网络频谱地图技术研究[D]. 长沙: 国防科技大学, 2020.  
Zhang Yue. Research on spectrum map technology for cognitive wireless networks[D]. Changsha: National University of Defence Technology, 2020.
- [12] 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.  
Zhang Han, Han Yu, Jiang Hang, et al. Residual self-encoder-based method for electromagnetic spectrummap construction[J]. *Radio Communication Technology*, 2023, 49(2): 255-261.
- [13] Han X, Xue L, Xu Y, et al. A radio environment maps estimation algorithm based on the pixel regression framework for underlay cognitive radio networks using incomplete training data[J]. *Sensors*, 2020, 20(8): 2245.
- [14] Han X, Xue L, Xu Y, et al. A two-phase transfer learning-based power spectrum mapsreconstruction algorithm for underlay cognitive radio networks[J]. *IEEE Access*, 2020, 8: 81232-81245.
- [15] Levie R, Yapar Ç, Kutyniok G, et al. RadioUNet: fast radio map estimation with convolutional neural networks[J]. *IEEE Transactions on Wireless Communications*, 2021, 20(6): 4001-4015.
- [16] Zeng P, Chen J. UAV-aided joint radio map and 3D environment reconstruction using deep learning approaches[C]//ICC 2022-IEEE International Conference on Communications. Seoul: IEEE, 2022: 5341-5346.
- [17] Liu K, Lin Z, Liu Y, et al. A new spectrum map fusing method based on difference group sparsity[C]//IEEE/CIC International Conference on Communications in China(ICC). Dalian: ICC, 2023: 1-6.
- [18] 任克强, 温晓珍. 接收信号强度指示测距模型修正与粒子群算法权重优化的节点定位算法[J]. *科学技术与工程*, 2020, 20(31): 12942-12947.  
Ren Keqiang, Wen Xiaozhen. Node localization algorithm with received signal strength indication ranging model modification and particle swarm algorithm weight optimization[J]. *Science Technology and Engineering*, 2020, 20(31): 12942-12947.
- [19] 王明明, 孙寅静, 孙晓云, 等. 基于深度残差网络与迁移学习的地形识别方法[J]. *科学技术与工程*, 2023, 23(9): 3779-3786.  
Wang Mingming, Sun Yijing, Sun Xiaoyun, et al. Terrain recognition method based on deep residual network and migration learning[J]. *Science Technology and Engineering*, 2023, 23(9): 3779-3786.
- [20] 陈立峰, 刘佳, 潘晓中, 等. 基于密集残差网络的图像隐藏方案[J]. *科学技术与工程*, 2024, 24(9): 3719-3726.  
Chen Lifeng, Liu Jia, Pan Xiaozhong, et al. Image hiding scheme based on dense residual network[J]. *Science Technology and Engineering*, 2024, 24(9): 3719-3726.
- [21] 诸林云, 范菁, 曲金帅, 等. 基于BERT与多通道卷积神经网络的细粒度情感分类[J]. *科学技术与工程*, 2023, 23(33): 14264-14270.  
Zhu Linyun, Fan Jing, Qu Jinshuai, et al. Fine-grained emotion classification based on BERT and multi-channel convolutional neural network[J]. *Science Technology and Engineering*, 2023, 23(33): 14264-14270.