

基于生成对抗网络的三维频谱态势补全

胡田钰¹, 吴启晖¹, 黄 洋^{1,2}

(1. 南京航空航天大学电子信息工程学院, 南京 211106; 2. 东南大学信息科学与工程学院, 南京 211189)

摘要: 三维频谱态势是解决空天地信息网络中频谱资源利用不足的重要手段, 可以表征功率谱密度在三维电磁空间的时空频分布情况, 由此通信系统可“有的放矢”地实现频谱预测、频谱决策和频谱管控等多种应用。但受限于用户部署等因素, 实际构建的三维频谱态势往往离散且缺损。因此, 本文提出一种基于生成对抗网络的三维频谱态势补全算法。然后进一步提出一种改进的生成对抗网络结构和一系列的数据处理方法, 以降低算法的补全误差和训练时间。仿真结果表明, 所提出的算法能有效地对缺损三维频谱态势进行补全, 并且其补全精度远优于传统插值方法。

关键词: 频谱态势补全; 生成对抗网络; 机器学习

中图分类号: TN929.5

文献标志码: A

Three-Dimensional Spectrum Situation Completion Based on Generative Adversarial Networks

HU Tianyu¹, WU Qihui¹, HUANG Yang^{1,2}

(1. College of Electronic and Information Engineering, Nanjing University of Aeronautics & Astronautics, Nanjing 211106, China;

2. School of Information Science and Engineering, Southeast University, Nanjing 211189, China)

Abstract: The three-dimensional (3D) spectrum situation is a significant method to handle the issue of making full use of spectrum resources in the ground-air-space integrated information network. It characterizes the time-space-frequency distribution of the power spectrum density in 3D electromagnetic space. Hence, the communication system can implement a variety of applications such as spectrum prediction, spectrum decision, and spectrum management and control in a targeted manner. However, due to user deployment and other factors, the actual 3D spectrum situation is often discrete and incomplete. Therefore, this paper proposes a 3D spectrum situation completion algorithm based on generative adversarial networks (GANs). Moreover, this paper proposes an improved GANs structure and data processing methods to decrease the completion error and the training time of the algorithm. Simulation results indicate that the proposed algorithm can effectively complete the 3D spectrum situation and outperform the conventional interpolation method in terms of completion accuracy.

Key words: spectrum situation completion; generative adversarial networks; machine learning

基金项目: 国家自然科学基金(61827801, 61631020, 61901216)资助项目; 江苏省自然科学基金(BK20190400)资助项目; 东南大学移动通信国家重点实验室开放研究基金(2020D08)资助项目。

收稿日期: 2020-09-08; **修订日期:** 2020-10-30

引言

近年来,随着中国空天地信息网络一体化的不断发展,卫星网络与地面移动网络已作为常态化基础网络存在,而各类基于无人机或其他空中平台的中继网络则将组成天地之间的机动网络,通信系统正迎来从地面 5G 到航空 6G 这一 6G 基础形态的重大演进^[1-2]。但随着空天地信息网络中无线智能终端和业务数量的急剧增长,日益稀缺的频谱资源与已分配频谱资源利用不足之间的尖锐矛盾也愈发突出^[3-4]。因此,急需研究适用于空天地信息网络的认知无线电(Cognitive radio, CR)技术,以提高三维电磁频谱空间的频谱利用率。

CR 将无线网络中的用频设备分为主要用户(Primary users, PUs)和次级用户(Secondary users, SUs)^[5-6]。对于地面通信系统,常用的一种表征当前区域内频谱资源使用情况的 CR 技术是将 SUs 所获取的信号功率谱密度(Power spectrum density, PSD)等无线电参数的分布情况进行可视化,“有的放矢”地实现频谱预测、频谱决策和频谱管控等多种应用,以提高通信系统频谱资源利用率。该可视化方法通常被称为频谱地图或无线电(环境)地图^[7-9]。但是,该方法仅考虑 PSD 在地理位置上的二维分布情况,不能简单地套用于空天地信息网络。

因此,本文将对 PSD 在三维空间上的时空频分布情况的表征进行研究,并以“频谱态势”来指代该分布情况。三维频谱态势使人们可以查看任何时间和三维位置的准确 PSD 分布,从而提高频谱资源在时间和空间维度上的利用率^[10]。但在三维电磁频谱空间中,受限于 SUs 的空间部署、监测频段以及监测时间段等因素,所构建的三维频谱态势在时域、空域和频域等维度上往往是离散且缺损的。如图 1 所示,在三维目标区域中, PUs 占用频谱资源并进行信号发射,但 PUs 的位置信息、发射 PSD 等未知;而进行信号接收的 SUs 所在位置和接收 PSD 则已知。因此,此时通过 SUs 的实测频谱数据只能得到缺损三维频谱态势。所以,三维频谱态势构建的基本任务和主要难点便在于利用现有实测数据和 PSD 时空频相关性,对三维频谱态势进行精确补全,以形成可供系统使用的补全三维频谱态势,其理想补全示例如图 2 所示。对于常用于二维频谱地图补全的插值方法,例如反距离加权(Inverse distance weighted, IDW)算法,虽然可以扩展至三维频谱态势补全,但该算法只考虑距离因素,实际中往往因为缺乏模型

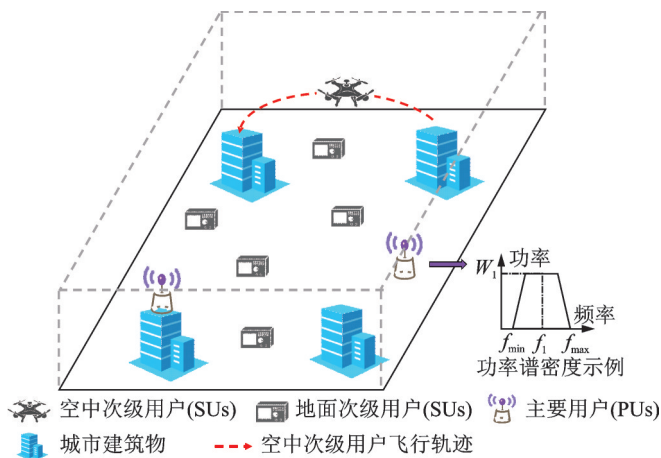


图 1 三维目标区域的主要用户和次级用户分布示例以及主要用户的功率谱密度示例(f_1 为中心频率, f_{\max} 和 f_{\min} 分别为频率最大值和最小值)

Fig.1 Example of the deployment of PUs and SUs in a three-dimensional target area and an example of power spectrum density of a PU (where f_1 , f_{\max} and f_{\min} are the center frequency, the maximum frequency and the minimum frequency, respectively)

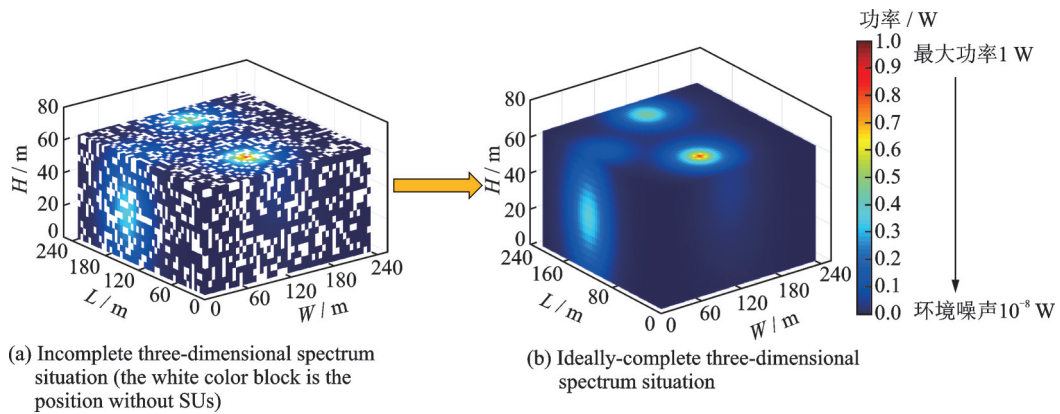


图2 工作频率为 f_1 时的目标区域三维频谱态势的理想补全示例

Fig.2 Ideal completion example of the three-dimensional spectrum situation of a target area when the working frequency is f_1

验证而导致补全效果不佳^[10-11]。本文将专注于三维频谱态势的精确补全,并借助备受关注的生成对抗网络(Generative adversarial networks, GANs)技术来实现^[12]。

GANs旨在生成足以与真实样本相比拟的模拟样本,当网络训练收敛时,GANs所生成的模拟样本几乎可以认为服从于真实数据分布,即能做到“以假乱真”^[13-16]。因此,文献[17]以若干不同频率下的完整频谱地图作为训练数据,通过转换频谱地图为RGB彩色图像的数据预处理方法,利用所提出的图估计GAN(Map estimation GANs, MEGAN)结构学得频谱地图补全机制,最终输出补全后的频谱地图。但文献[17]仅关注二维的底层认知无线网络,并未对三维电磁频谱空间展开进一步研究。文献[18]虽然提出了一种对三维频谱态势补全性能与无人机部署耗能进行联合优化的三维频谱感知框架,但其仅利用传统图像恢复方法在不同维度进行切片平均来实现三维补全。总的来说,在三维电磁频谱空间中,利用GANs实现精确的三维频谱态势补全的相关研究还未见报道。

为了进一步提高三维频谱态势补全的精确性,本文针对三维电磁频谱空间提出了一种基于生成对抗网络的三维频谱态势补全算法,具体工作如下:

(1) 利用生成对抗网络在三维电磁频谱空间展开研究,利用新兴的生成对抗网络实现三维频谱态势补全,为构建高精度数字孪生频谱空间打下坚实基础。

(2) 提出了一种具备U形结构的三维条件生成对抗网络(Three-dimensional U-shaped conditional generation adversarial network, 3D-UCGAN),该结构能从包含完整三维频谱态势的训练数据中提取更符合三维电磁频谱空间环境特征的有用信息。

(3) 提出了一系列改进三维频谱态势补全性能的数据处理方法,主要包括3D-UCGAN的输入数据预处理以及输出数据再处理。

通过仿真可以得到如下结论:所提出的基于生成对抗网络的三维频谱态势补全算法的性能优于传统基于插值的补全算法;所提出的3D-UCGAN结构能有效地降低本文算法的补全误差和训练时间;所选择的数据预处理方法可以进一步加速网络收敛速度。

1 系统模型

1.1 三维频谱态势补全模型

现代无线通信的基础设施由部署在三维空间的异构无线网络组成,因此目标区域的三维频谱态势

是由该区域内若干异构网络同时进行的无线传输叠加形成,进而呈现出信号功率谱密度在不同位置、频率和时间上的不规则变化情况^[10]。因此,将三维频谱态势 $\Psi(\mathbf{x}, f, t)$ 定义为三元组变量 (\mathbf{x}, f, t) 到信号功率的一种映射关系,其中 $\mathbf{x} \in \mathbf{R}^3$ 表示通信系统在使用三维频谱态势时所查看位置的三维坐标 (x_l, x_w, x_h) ,而 f 和 t 则分别表示所查看的特定时间和工作频率。但为了进一步简化模型,在后续的讨论中忽略变量 t 。

对于长宽高为 $L \times W \times H$ 的三维目标区域 A ,将其进行栅格化,把三维目标区域 A 分为 $N_L \times N_W \times N_H$ 个栅格。后文中的位置坐标均代表栅格的位置坐标。但当栅格划分较稀疏时,很可能某栅格内存在多个接收SUs。因此,如果栅格 x 处存在 N_x 个接收SUs,则将这 N_x 个SUs接收功率谱的平均值视为该栅格在频谱态势上展现的接收功率谱。经该数据栅格化处理,可假设三维目标区域 A 中均匀分布着 N_R 个数量已知的接收SUs,且此时每个栅格中至多存在1个接收SU;而同时存在着 N_T 个数量未知的发射PUs。

对于三维频谱态势补全问题,设定第 i 个发射PU的位置坐标和发射功率谱分别为 $\mathbf{x}_{T,i}$ 和 $\{\Psi(\mathbf{x}_{T,i}, f)\}_{f=f_{\min}}^{f_{\max}}$ 未知;而第 j 个接收SU的位置坐标和接收功率谱分别为 $\mathbf{x}_{R,j}$ 和 $\{\tilde{\Psi}(\mathbf{x}_{R,j}, f)\}_{f=f_{\min}}^{f_{\max}}$ 已知, f_{\min} 和 f_{\max} 分别为工作频率的最大值和最小值。而其余栅格处的接收频谱数据则是未知且需要补全的。将此时的频谱态势称为区域 A 的缺损三维频谱态势 $\{\tilde{\Psi}(\mathbf{x}, f)\}_{f=f_{\min}}^{f_{\max}}, \forall \mathbf{x} \in A$,且区域 A 的三维频谱态势采样率 $\alpha = \frac{N_R}{N_L \times N_W \times N_H}$ 。理想情况下,若每个栅格处均存在一个接收SU,则区域 A 的三维频谱态势是已知且完整的,记为 $\{\Psi(\mathbf{x}, f)\}_{f=f_{\min}}^{f_{\max}}, \forall \mathbf{x} \in A$ 。

进一步地,在目标区域的无线电环境下,若第 i 个发射PU将频率为 f 的信号从栅格 $\mathbf{x}_{T,i}$ 发送至任一其他栅格 x 处,且将此时的信号传播规律记为 $\Gamma_{\mathbf{x}_{T,i} \rightarrow x}(f)$,则三维频谱态势补全问题可被建模为

$$\begin{aligned} \{\Psi(\mathbf{x}, f)\}_{f=f_{\min}}^{f_{\max}} &= \left\{ \sum_{i=1}^{N_T} \Gamma_{\mathbf{x}_{T,i} \rightarrow x}(f) \Psi(\mathbf{x}_{T,i}, f) + \sigma^2 \right\}_{f=f_{\min}}^{f_{\max}} \quad \forall \mathbf{x} \in A \\ \text{s.t. } \{\tilde{\Psi}(\mathbf{x}_{R,j}, f)\}_{f=f_{\min}}^{f_{\max}} &= \left\{ \sum_{i=1}^{N_T} \Gamma_{\mathbf{x}_{T,i} \rightarrow \mathbf{x}_{R,j}}(f) \Psi(\mathbf{x}_{T,i}, f) + \sigma^2 \right\}_{f=f_{\min}}^{f_{\max}} \quad j=1, 2, \dots, N_R \end{aligned} \quad (1)$$

式中 $\{\Psi(\mathbf{x}, f)\}_{f=f_{\min}}^{f_{\max}}$ 为三维目标区域 A 中任一栅格处的接收功率谱,而 σ^2 为当前目标区域的环境噪声^[17]。遗憾的是,式(1)具有无穷解,因为可以存在无数个满足当前约束条件的PUs发射功率谱。因此,往往只能通过插值或假设信号传播模型的方法来对缺损栅格处的频谱数据进行补全,进而得到符合目标区域电磁环境特征的式(1)的解,即存在一定误差的补全三维频谱态势 $\{\hat{\Psi}(\mathbf{x}, f)\}_{f=f_{\min}}^{f_{\max}}, \forall \mathbf{x} \in A$ 。本文将使用所提出的3D-UCGAN对历史频谱态势数据或经验频谱态势数据进行挖掘,从而对式(1)进行隐性建模,以学得更符合三维目标区域电磁频谱环境特征的频谱态势补全机制,从而降低补全误差。

1.2 信号传播模型

本节将对传播规律 $\Gamma_{\mathbf{x}_{T,i} \rightarrow x}(f)$ 进行建模,即建立三维目标区域的信号传播模型。对于第 i 个PU所发出的频率为 f 的信号,假设其从位置 $\mathbf{x}_{T,i}$ 传播到任一其他位置 x 时的路径损耗 $PL(d)$ 为

$$PL(d) = P_{L-FREE}(d_0) + 10n \lg\left(\frac{d}{d_0}\right) \quad (2)$$

式中 d 为位置 $x_{T,i}$ 与位置 x 间的距离, d_0 为计算时的参考距离, n 为路径损耗因子, $P_{L-FREE}(d_0)$ 为参考距离 d_0 下的自由空间传播损耗^[19-21]。因此, 对于第 i 个 PU 的发射信号, 位置 x 处的接收功率为

$$10 \lg \Psi(x, f) = 10 \lg \Psi(x_{T,i}, f) - PL(d) \quad (3)$$

2 基于生成对抗网络的三维频谱态势补全

本节首先简要介绍了 GANs 的基本概念以及学习机制。其次, 提出了基于 GANs 的三维频谱态势补全算法, 并对数据处理方法进行了一定的改进。进一步地, 为了提高 GANs 对三维频谱态势的学习能力, 提出了一种面向三维频谱态势补全的 3D-UCGAN 结构, 并将该结构应用于所提算法中。

2.1 GANs 基本概念与学习机制

GANs 主要由生成器网络和鉴别器网络组成^[22], 其中生成器网络 $G(z; \theta_g)$ 在参数 (即网络中各神经元的权重与偏置) θ_g 的作用下, 将潜变量 $z \sim p_z(z)$ 转换为与真实样本 $s \sim p_{data}(s)$ 规格相同的模拟样本 \hat{s} , 即 $G(z; \theta_g) = \hat{s}$; 且样本 \hat{s} 服从生成器网络对分布 $p_{data}(s)$ 隐式建模得到的分布 $p_g(\hat{s})$ ^[12]。而鉴别器网络 $D(s; \theta_d)$ 或 $D(\hat{s}; \theta_d)$ 则在参数 θ_d 的作用下, 判断输入样本 s 或 \hat{s} 服从于分布 $p_{data}(s)$ 而不是分布 $p_g(\hat{s})$ 的可能性^[12]。

GANs 旨在学习数据分布 $p_{data}(s)$, 并采用生成器网络和鉴别器网络相互对抗的训练策略来实现。针对鉴别器网络, 该策略最大化其正确鉴别的概率, 而针对生成器网络则最大化鉴别器网络鉴别出错的概率。进而在不同鉴别结果的反馈下, 不断提升网络鉴别/生成能力。假如具备足够的网络容量, 则鉴别器网络和生成器网络可实现动态平衡。此时生成器网络隐性建模得到的分布 $p_g(\hat{s})$ 收敛于分布 $p_{data}(s)$, 而鉴别器网络不能正确地区分样本 s 和 \hat{s} 。

2.2 基于 GANs 的三维频谱态势补全算法

所提出的基于 GANs 的三维频谱态势补全算法共包括离线训练阶段和在线部署阶段, 其中“在线”和“离线”均针对所使用的 GANs 而言。进一步地, 算法中不仅包括与 GANs 相关的流程, 还包括各阶段所必需的数据处理方法, 其将更有利于 GANs 训练与态势补全。需要说明的是, 在算法实际运行时, 所使用的 GANs 结构为 2.3 节提出的 3D-UCGAN 结构。在离线训练阶段, 借助深度学习 (Deep learning, DL) 数据驱动的特点^[22], 以完整频谱态势数据作为训练数据对 GANs 进行训练。而对于算法在线部署阶段, 借助深度学习低复杂度的特点^[22], 将已训练至收敛的生成器网络部署于实际应用, 直接根据 SUs 的测量结果对实际缺损三维频谱态势进行精确补全。所提出的基于 GANs 的三维频谱态势补全算法的流程如图 3 所示。

GANs 学习缺损三维频谱态势至补全三维频谱态势的补全机制, 也即以缺损三维频谱态势作为条件的完整态势数据分布。具体而言, 在 GANs 的对抗训练过程中, 网络参数 θ_g 和 θ_d 在目标函数的指导下, 经基于梯度的学习算法不断迭代更新, 以至于网络的鉴别能力或生成能力在不断提升。因此, 生成器网络在输入缺损三维频谱态势的情况下, 不断朝着输出补全三维频谱态势近似于对应完整三维频谱态势的方向进行学习; 而鉴别器网络则在输入完整/补全三维频谱态势的情况下, 朝着正确鉴别此时输入态势真假的的方向进行学习。进而 GANs 逐步达到生成器隐性建模分布接近于态势数据分布的预期效果, 并最终实现收敛。

(1) 离线训练阶段

该阶段以来源于三维目标区域的历史完整频谱态势数据或仿真得到的经验完整频谱态势数据作为 GANs 训练的真实数据。另外, 为了提高面向三维频谱态势补全的 GANs 泛化能力, 并且出于降低训练复杂度的目的, 设定训练数据由若干组经数据预处理的完整三维频谱态势的切片

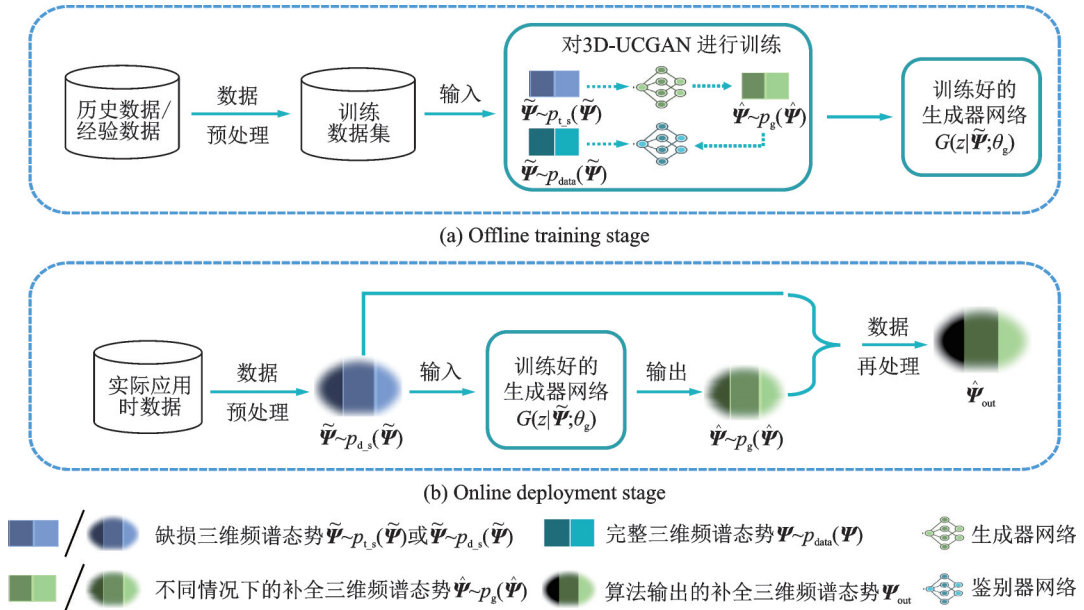


图3 基于3D-UCGAN的三维频谱态势补全算法流程图

Fig.3 Procedure of three-dimensional spectrum situation completion algorithm based on 3D-UCGAN

$\Psi(x, f), \forall x \in A$ 组成, 其中每组切片的频率 f 、PUs 数量 N_T 和位置 $\{x_{T,i}\}_{i=1}^{N_T}$ 均随机选择; 即训练数据并非由数据规模急剧增加的若干组频谱态势 $\{\Psi(x, f)\}_{f=f_{min}}^{f_{max}}, \forall x \in A$ 组成。因此, 所使用的面向三维频谱态势补全的 GANs 可在任意频率下进行补全, 也即是能得到补全三维频谱态势 $\{\hat{\Psi}(x, f)\}_{f=f_{min}}^{f_{max}}, \forall x \in A$ 。值得注意的是, 每组切片的 SUs 数量 N_R , 或说区域 A 的三维频谱态势采样率 α 将在 GANs 训练前给出, 而其所在位置则在数据预处理过程中随机选取得到。为了使后续叙述更为简明, 将无误差的完整三维频谱态势切片 $\Psi(x, f), \forall x \in A$ 简记为完整三维频谱态势 Ψ , 而将只包含实测获得的接收 SUs 处频谱数据的缺损三维频谱态势切片 $\tilde{\Psi}(x, f), \forall x \in A$ 简记为缺损三维频谱态势 $\tilde{\Psi}$, 而有一定误差的补全三维频谱态势切片 $\hat{\Psi}(x, f), \forall x \in A$ 简记为补全三维频谱态势 $\hat{\Psi}$ 。

本文所提出的数据预处理方法基于灰度进行。具体而言, 在离线训练阶段, 首先将每组完整三维频谱态势切片进行归一化处理, 即得到灰度模式下的一通道完整三维频谱态势“灰度图”(数据维度: $1 \times N_L \times N_W \times N_H$), 如图 4(a) 所示。进一步地, 将一通道三维频谱态势“灰度图”扩充为三通道的完整三维频谱态势“灰度图”(数据维度: $3 \times N_L \times N_W \times N_H$), 其中每通道的频谱数据仍与原一通道时的数据相同。同时还对一通道三维频谱态势“灰度图”以采样率 α 进行采样, 即上文所述的随机选取 SUs 位置。随后, 以相同方式对该采样数据扩充为三通道, 并对未采样点以除黑白灰色以外的颜色进行重新着色, 得到三通道的缺损三维频谱态势“彩色图”。本文选取红色对未采样点进行着色, 如图 4(b) 所示。因此, 在经过数据预处理后, 可得到三通道的完整三维频谱态势“灰度图”和缺损三维频谱态势“彩色图”, 其将作为训练数据用于后续 GANs 的训练中。需要说明的是, 文献[17]提出一种基于 RGB 的数据预处理方法, 其直接将归一化数据经 RGB 色谱图进行颜色映射。但该方法仅针对量化离散的频谱数据进行, 极有可能在颜色(逆)映射时丢失信息, 反而增加补全误差。因此, 本文并未采用该方法, 并且不同数据预处理方法所带来的算法补全性能影响将在第 3 节给出。

对于本文所提出的 3D-UCGAN 结构的训练, 其真实样本为历史数据或经验数据经预处理后得到的完

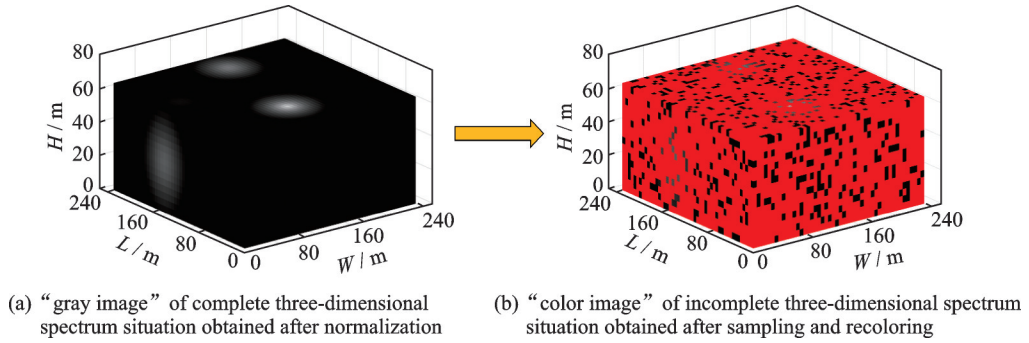


图4 工作频率为 f_1 时的目标区域完整三维频谱态势的数据预处理示例

Fig.4 A data preprocessing example of complete three-dimensional spectrum situation of a target area when the working frequency is f_1

整三维频谱态势 $\Psi \sim p_{\text{data}}(\Psi)$ 。对于3D-UCGAN结构中的生成器网络而言,其输入为缺损三维频谱态势 $\tilde{\Psi} \sim p_{t,s}(\tilde{\Psi})$,而输出的模拟样本则为补全三维频谱态势 $\hat{\Psi} \sim p_g(\hat{\Psi})$;对于鉴别器网络,其则对输入的补全三维频谱态势 $\tilde{\Psi}$ 或完整三维频谱态势 Ψ 加以区分鉴别。在生成器网络和鉴别器网络经迭代训练达到动态平衡后,可得到已训练好的生成器网络 $G(z|\tilde{\Psi}; \theta_g)$,即得到已学得三维频谱态势补全机制的生成器网络。

(2) 在线部署阶段

该阶段把已训练好的生成器网络部署到实际应用,例如面向航空6G的频谱认知智能管控体系架构中的频谱云模块^[1]。设定实际应用时的频谱数据为SUs实测获得的缺损三维频谱态势,且同样需要进行数据预处理。但该阶段的数据预处理方法与离线训练阶段所用方法有些许差别。首先,对于数据归一化,SUs很可能不会刚好放置于三维目标区域内接收功率最大值/最小值所在栅格处。因此,将以往实测接收功率的最值与此次实际应用时的数据最值进行比较,并取其更大/小值,以尽量避免数据处理误差。其次,将不再进行离线训练阶段数据预处理方法中的采样步骤,而是直接对扩充为三通道的缺损三维频谱态势“灰度图”的未采样点进行重新着色。

因此,对于已被部署至实际应用的生成器网络而言,其输入为经上述预处理后得到的缺损三维频谱态势 $\tilde{\Psi} \sim p_{d,s}(\tilde{\Psi})$,注意其分布 $p_{d,s}(\tilde{\Psi})$ 与离线训练阶段的缺损三维频谱态势分布 $p_{t,s}(\tilde{\Psi})$ 不同,因为两者的原始数据不同。而生成器网络的输出则为相对于实测缺损三维频谱态势 $\tilde{\Psi}$ 的补全三维频谱态势 $\hat{\Psi} \sim p_g(\hat{\Psi})$ 。进一步地,还对实测态势 $\tilde{\Psi}$ 和补全态势 $\hat{\Psi}$ 进行数据再处理,以进一步提升态势补全性能。文献[17]忽略了实测数据,直接将生成器网络输出的态势 $\hat{\Psi}$ 作为算法输出。因此,在所提出的数据再处理方法中,结合实测态势 $\tilde{\Psi}$,只对未采样点进行补全。具体而言,首先令算法输出的补全三维频谱态势 $\hat{\Psi}_{\text{out}} = \hat{\Psi}$ 。其次,针对输出态势 $\hat{\Psi}_{\text{out}}$ 中的未采样点,将GANs输出的补全态势 $\hat{\Psi}$ 中相同位置处的对应数据直接复制到态势 $\hat{\Psi}_{\text{out}}$ 中。最后,在实际应用时,算法通过执行在线部署阶段而输出补全三维频谱态势 $\hat{\Psi}_{\text{out}}$ 。

2.3 面向三维频谱态势补全的3D-UCGAN结构

(1) 训练框架

三维频谱态势补全旨在通过实测的缺损三维频谱态势 $\tilde{\Psi}$ 求解得到与完整三维频谱态势 Ψ 相差甚小的补全三维频谱态势 $\hat{\Psi}$ 。因此,势必要将缺损三维频谱态势 $\tilde{\Psi}$ 作为生成器网络的输入之一。这与文献[12]所提出的基本GANs不同,其生成器网络输入仅为潜变量 z 。因此,对于面向三维频谱态势补全的GANs结构,将首先引入条件GAN(Conditional GAN,CGAN)框架^[14]。CGAN框架通过向生成器网

络和鉴别器网络同时输入额外的条件信息来实现。因此,选择缺损三维频谱态势 $\tilde{\Psi}$ 作为条件信息。

由于基本GANs的代价函数存在一定的缺陷,其训练过程经常出现不稳定的现象^[15]。因此,还引入文献[16]提出的带有梯度惩罚项的Wasserstein GAN(Wasserstein GAN with gradient penalty, WGAN-GP)框架。不同于文献[12]所采用的JS(Jensen-Shannon)散度,WGAN-GP中使用Lipschitz约束下的Wasserstein距离作为代价函数,以此减轻网络训练时的不稳定性。

因此,通过所引入的CGAN和WGAN-GP框架,确定了面向三维频谱态势补全的3D-UCGAN结构的训练目标

$$\begin{aligned} \text{Min}_{\theta_g} \text{Max}_{\theta_d} V(D, G) = & E_{\Psi \sim p_{\text{data}}(\Psi)} [D(\Psi | \tilde{\Psi}; \theta_d)] + E_{z \sim p_z(z)} [-D(G(z | \tilde{\Psi}; \theta_g) | \tilde{\Psi}; \theta_d)] - \\ & \lambda E_{\Psi' \sim p_{\text{gp}}(\Psi')} \left[\left(\left\| \nabla_{\Psi'} D(\Psi' | \tilde{\Psi}; \theta_d) \right\|_2 - 1 \right)^2 \right] \end{aligned} \quad (4)$$

式中: $V(D, G)$ 为GANs的代价函数; $\lambda=10$ 为惩罚因子; Ψ' 为用于计算式(4)中最后一项(即惩罚项)的样本,而分布 $p_{\text{gp}}(\Psi')$ 通过对与分布 $p_{\text{data}}(\Psi)$ 和分布 $p_g(\hat{\Psi})$ 相关的点对均匀采样而得到^[16]。具体而言,样本 Ψ' 由两部分相加组成,其中一部分是真实样本 Ψ 乘以一随机数 $\epsilon \sim u(0, 1)$,另一部分则是模拟样本 $\hat{\Psi}$ 乘以 $(1 - \epsilon)$ 。面向三维频谱态势补全的3D-UCGAN结构的训练框架示意图如图5(a)所示,图5(b)则展现了训练过程中样本 Ψ' 的实现方式。

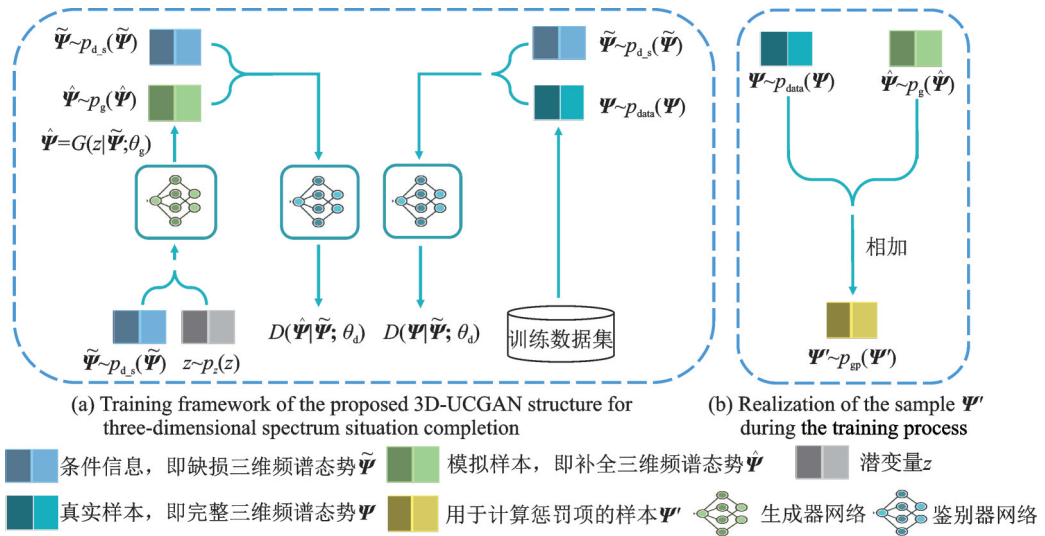


图5 3D-UCGAN结构的生成对抗机制

Fig.5 Generative adversarial mechanism of the proposed 3D-UCGAN structure

(2) 网络搭建

三维频谱态势补全问题的实质在于对每个未布置SU的栅格处频谱数据进行补全。因此,借用DL领域中像素级语义分割的概念^[23],同样可以将三维频谱态势补全视作“像素级补全”。因此,在面向三维频谱态势补全的生成器网络中引入一种经典的语义分割网络,即具备U形结构的网络(U-shaped net, U-net)的搭建思想^[24]。具体而言,先采用三维卷积层进行下采样,以实现电磁频谱空间的环境特征提取;再采用三维转置卷积层进行上采样,以恢复态势尺寸,并获得每个栅格的补全信息;同时将上采样和下采样过程中对应层的输出三维特征图在通道维度进行拼接,以实现多尺度特征融合。

因此,将所提出的面向三维频谱态势补全的GANs结构称作3D-UCGAN,其生成器网络结构如图6所示,其中每层网络为三维卷积层或三维转置卷积层,共6层。图中 $h_l=(k, s, p)$ 指第 l 层的卷积核大小、计算步长 s 和补零层数 p 等超参数的设置情况。而当 $l=0, \dots, 5$ 时, F_l 指网络中第 $(l+1)$ 层的输入数据通道数;而当 $l=6$ 时, F_l 则指生成器网络输出层(即第6层)的输出数据通道数。3D-UCGAN的鉴别器网络如图7所示,其中每层网络为三维卷积层或全连接层,共4层。不同于文献[17],本文不仅通过减少网络层数的方式来降低训练复杂度,还以条件信息(即缺损三维频谱态势 $\tilde{\Psi}$)作为额外的输入来提升网络的鉴别能力。图中 $h_l=(k, s, p)$ 仍指第 l 层卷积层的超参数设置情况。当 $l=0, \dots, 2$ 时, F_l 指网络中第 $(l+1)$ 层卷积层的输入数据通道数;而当 $l=3$ 时, F_l 则指鉴别器网络第3层卷积层的输出数据通道数。

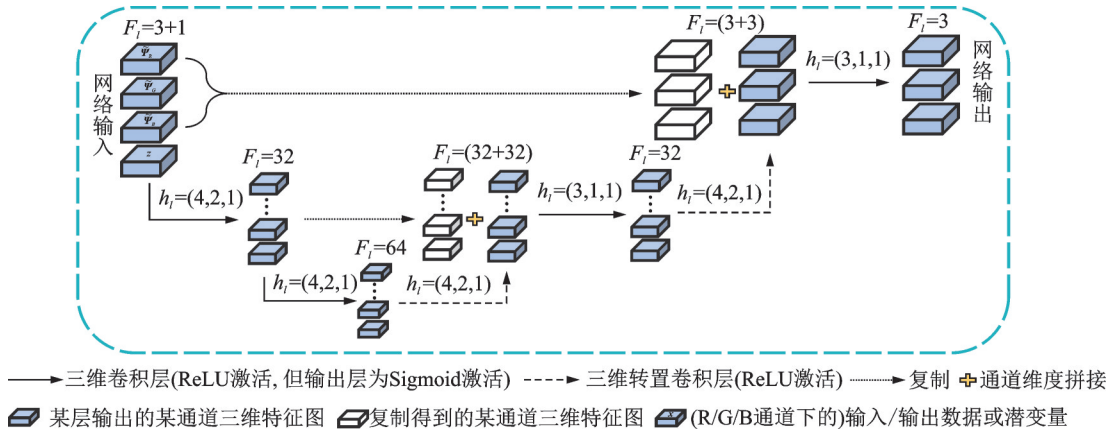


图6 3D-UCGAN结构的生成器网络

Fig.6 Generator network of 3D-UCGAN structure

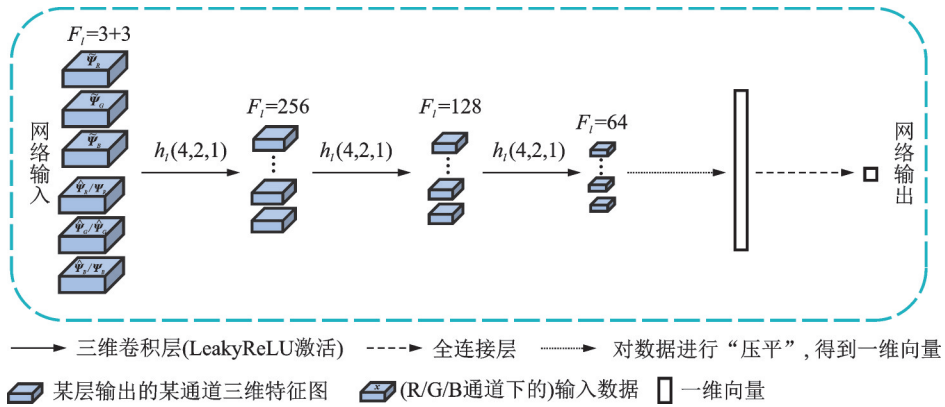


图7 3D-UCGAN结构的鉴别器网络

Fig.7 Discriminator network of 3D-UCGAN structure

3 性能评估

本节通过仿真测试对所提出的基于3D-UCGAN的三维频谱态势补全算法的性能进行评估。基于Python3.7.0的Pytorch 1.0框架建立了3D-UCGAN模型,并在Nvidia GeForce RTX 2080图形处理单元上进行该模型的训练和测试工作,以实现算法的离线训练和在线部署阶段。

基于本文建立的系统模型,设定三维目标区域 A 的大小为 $L \times W \times H = 240 \text{ m} \times 240 \text{ m} \times 80 \text{ m}$,并将其

分为 $N_L \times N_W \times N_H = 48 \times 48 \times 16$ 个栅格,即每栅格为体积为 5 m^3 的立方体。同时,设定 PUs 数量 N_T 从 $1 \sim 5$ 中随机选择,而次级用户数量 N_R 默认为 5 504 个,即采样率 $\alpha \approx 15\%$ 。对于信号传播模型,假设参考距离 $d_0 = 0.01 \text{ km}$,频率 $f \in (25 \text{ MHz}, 125 \text{ MHz})$,即三维频谱态势切片 $\Psi(x, f), \forall x \in A$ 的频率所属范围。

对于算法的离线训练阶段,设置 30 000 组三维频谱态势切片 $\Psi(x, f), \forall x \in A$ 作为 3D-UCGAN 的训练数据,并使用自适应矩估计(Adaptive moment estimation, Adam)算法作为 3D-UCGAN 的学习算法。同时,设置 3D-UCGAN 中生成器网络和鉴别器网络的学习率为 0.000 1,批训练大小为 4,训练轮数为 20。进一步地,为了提高 3D-UCGAN 的泛化能力,在训练数据中,设置每 10 000 组数据的路径损耗因子和噪声功率(单位:mW)是不同的,依次为 $n = 8, \sigma^2 = 10^{-5}, n = 4, \sigma^2 = 10^{-5}, n = 4, \sigma^2 = 10^{-3}$ 。需要说明的是,为了使 SUs 在不同频率下的接收功率更符合实际情况,设定每组频谱数据的发射功率(单位:mW)随机从向量 $[67, 467, 867, 1000, 1000, 1000, 867, 467, 67]$ 中进行抽取(即假设 SUs 工作频率与 PUs 中心频率可能不一致的情况)。而对于算法的在线部署阶段,使用 10 000 组三维频谱态势切片 $\Psi(x, f), \forall x \in A$ 作为测试数据,其中路径损耗因子 $n = 6$ 和噪声功率 $\sigma^2 = 10^{-5} \text{ mW}$,其余设置与训练数据相同。注意,利用 L_2 损失函数,即均方误差(Mean squared error, MSE)来评价每组训练/测试数据的态势补全性能,其计算公式为

$$\text{MSE} = \frac{1}{N_L \times N_W \times N_H} \sum_{x \in A} (\Psi(x, f) - \hat{\Psi}(x, f))^2 \quad (5)$$

首先将所提出的基于 3D-UCGAN 的三维频谱态势补全算法与传统 IDW 算法进行性能对比。IDW 算法假定不存在 SU 的栅格处接收功率谱仅取决于该栅格与 SUs 之间的距离 $\{d_m\}_{m=1}^{N_R}$,其中第 m 个栅格处 SU 实测数据对该栅格的影响受反距离幂值 $\frac{1}{(d_m)^{n_p}}$ 的控制。本文设置幂值 $n_p = 2$ 。图 8 展示了

随机选取的某次测试三维频谱态势补全结果,且为了更方便读者观察,对补全结果进行颜色映射处理。从图 8 可以看出,所提算法的补全结果与原完整三维频谱态势相差不大,几乎准确描绘了若干 PUs 的有效辐射范围;而对于 IDW 算法的补全结果,却只能从中依稀观察到 PUs 辐射范围的粗略轮廓。进一步地,根据所提算法与传统 IDW 算法对测试数据的频谱态势补全结果,在图 9 中给出了所提算法与传统 IDW 算法于不同采样率时的平均 MSE 对比,且将针对测试数据的 MSE 称作测试误差。可以看出,所提算法与 IDW 算法的三维频谱态势补全性能均随着采样率的提高而提高,但所提算法的平均 MSE 明显低于 IDW 算法,且受采样率影响较小。因此,所提出的基于 3D-UCGAN 的三维频谱态势补全算法性能远优于 IDW 算法的补全性能。

其次,为了验证本文所提出的 3D-UCGAN 结构对三维频谱态势补全算法的性能提升,将其与




图 8 随机选取的某次测试三维频谱态势补全结果

Fig.8 Three-dimensional spectrum situation completion results of a randomly selected test

基于文献[17]经卷积层扩展后的3D-MEGAN结构进行对比。在所提出的基于GANs的三维频谱态势补全算法中,分别基于3D-UCGAN与3D-MEGAN结构执行算法的离线训练和在线部署阶段,并在图10中对两种结构在不同训练轮数时的平均MSE进行比较,其中针对训练数据的MSE被称作训练误差。从图10中可以看出,无论关注于训练误差还是测试误差,基于3D-UCGAN结构的频谱态势补全算法在训练轮数为1或2时就已经收敛;但对于3D-MEGAN结构,其在训练轮数大于12时才趋于收敛。并且,3D-UCGAN结构下的算法补全误差小于3D-MEGAN结构下的补全误差。因此,所提出的3D-UCGAN结构能有效降低频谱态势补全算法的补全误差和训练时间。

最后,通过所提出的基于3D-UCGAN的三维频谱态势补全算法,图11和图12分别对所提出的

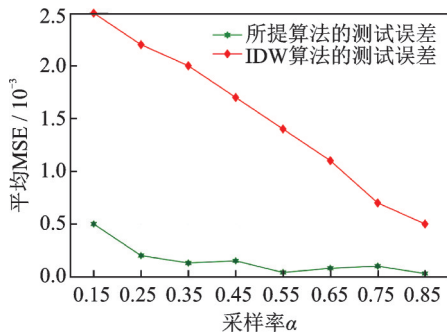


图9 所提算法与IDW算法于不同采样率时的三维频谱态势补全性能的对比

Fig.9 Comparison of three-dimensional spectrum situation complement performance between the proposed algorithm and the IDW algorithm at different sampling rates




图11 基于灰度预处理与基于RGB预处理的三维频谱态势补全算法于不同训练轮数时的性能对比(采样率 $\alpha = 15\%$)

Fig.11 Performance comparison of three-dimensional spectrum situation complement algorithm based on grayscale preprocessing and RGB preprocessing at different training epochs (sampling rate $\alpha = 15\%$)

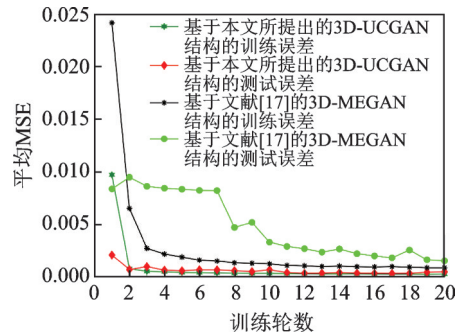


图10 基于3D-UCGAN结构与基于3D-MEGAN结构的三维频谱态势补全算法于不同训练轮数时的性能对比(采样率 $\alpha = 15\%$)

Fig.10 Performance comparison of three-dimensional spectrum situation complement algorithm based on the 3D-UCGAN structure and the 3D-MEGAN structure at different training epochs (sampling rate $\alpha = 15\%$)




图12 基于所提再处理方法与基于文献[17]再处理方法的三维频谱态势补全算法于不同训练轮数时的性能对比(采样率 $\alpha = 15\%$)

Fig.12 Performance comparison of three-dimensional spectrum situation complement algorithm based on the proposed post-processing method and the method in Ref. [17] at different training epochs (sampling rate $\alpha = 15\%$)

数据预处理和再处理方法下的算法补全性能进行了探讨。从图 11 可以看出,基于 RGB 的数据预处理方法大大减慢了 3D-UCGAN 的训练收敛速度,以至于当训练轮数达到 20 时,其训练误差仍大于基于灰度预处理时的最大训练误差。因此,本文所提出的基于灰度的数据预处理方法能进一步加快网络训练的收敛速度,且无须进一步比较不同数据预处理方法下的测试误差情况。而由于数据再处理方法运用在算法的离线部署阶段,因此本文在图 12 中只比较了不同数据再处理方法下的测试误差情况。从图 12 中可以看出,所提出的数据再处理方法确实能较好地对比谱态势的补全精度进行改进。

4 结束语

本文对三维电磁频谱空间的频谱态势补全问题进行了充分探索,所提出的补全方法可以有效地降低态势补全误差,以辅助通信系统在目标区域内提升频谱利用率。仿真结果证明,本文所提出的三维频谱态势补全算法在态势补全精度方面优于传统基于插值的方法,并且可以在较短的网络训练时间下得到能对缺损频谱态势进行精确补全的生成器网络。

参考文献:

- [1] 刘东,吴启晖,TONY Q S Q. 面向航空 6G 的频谱认知智能管控[J]. 物联网学报,2020,4(1): 12-18.
LIU Dong, WU Qihui, TONY Q S Q. Spectrum cognitive intelligent management and control for aviation 6G[J]. Chinese Journal on Internet of Things, 2020, 4(1): 12-18.
- [2] 尤肖虎,尹浩,邬贺铨. 6G 与广域物联网[J]. 物联网学报,2020,4(1): 3-11.
YOU Xiaohu, YIN Hao, WU Hequan. On 6G and wide-area IoT[J]. Chinese Journal on Internet of Things, 2020, 4(1): 3-11.
- [3] FENG Z, QIU C, FENG Z, et al. An effective approach to 5G: Wireless network virtualization[J]. IEEE Communications Magazine, 2015, 53(12): 53-59.
- [4] XU Y, WANG J, WU Q, et al. Opportunistic spectrum access in unknown dynamic environment: A game-theoretic stochastic learning solution[J]. IEEE Transactions on Wireless Communications, 2012, 11(4): 1380-1391.
- [5] MITOLA J, MAGUIRE G Q. Cognitive radio: Making software radios more personal[J]. IEEE Personal Communications, 1999, 6(4): 13-18.
- [6] 吴启晖,唐梦云. 基于张量补全的多维频谱地图构建[J]. 信号处理,2017,33(S1): 47-52.
WU Qihui, TANG Mengyun. Multi-dimensional spectrum map construction based on tensor completion[J]. Signal Processing, 2017, 33 (S1): 47-52.
- [7] 路镜涵,查淞,黄纪军,等. 基于观测值差值的频谱地图的补全方法[J]. 微波学报,2018,34(S2): 426-430.
LU Jinghan, CHA Song, HUANG Jijun, et al. Spectrum map completion method based on difference of observation values[J]. Journal of Microwaves. 2018, 34(S2): 426-430.
- [8] DEBROY S, BHATTACHARJEE S, CHATTERJEE M. Spectrum map and its application in resource management in cognitive radio networks[J]. IEEE Transactions on Cognitive Communications and Networking, 2015, 1(4): 406-419.
- [9] TANG M, DING G, WU Q, et al. A joint tensor completion and prediction scheme for multi-dimensional spectrum map construction[J]. IEEE Access, 2016, 4: 8044-8052.
- [10] BI S, LYU J, DING Z, et al. Engineering radio maps for wireless resource management[J]. IEEE Wireless Communications, 2019, 26(2): 133-141.
- [11] HUISMAN O, DE BY R A. Principles of geographic information systems[J]. ITC Educational Textbook Series, 2009, 1: 17.
- [12] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]//Proceedings of Advances in Neural Information Processing Systems. New York: Curran Associates, 2014: 2672-2680.
- [13] HU T, HUANG Y, ZHU Q, et al. Channel estimation enhancement with generative adversarial networks[J]. IEEE Transactions on Cognitive Communications and Networking, 2020, 7(1): 145-156.
- [14] MIRZA M, OSINDERO S. Conditional generative adversarial nets[EB/OL]. (2014-11-06)[2020-09-01]. <https://arxiv.org/>

abs/1411.1784.

- [15] CRESWELL A, WHITE T, DUMOULIN V, et al. Generative adversarial networks: An overview[J]. *IEEE Signal Processing Magazine*, 2018, 35(1): 53-65.
- [16] GULRAJANI I, AHMED F, ARJOVSKY M, et al. Improved training of wasserstein gans[C]//*Proceedings of Advances in Neural Information Processing Systems*. New York: Curran Associates, 2017: 5767-5777.
- [17] 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.
- [18] WU Q, SHEN F, WANG Z, et al. 3D spectrum mapping based on ROI-Driven UAV deployment[J]. *IEEE Network*, 2020, 34(5): 24-31.
- [19] ALHOURANI A, KANDEEPAN S, JAMALIPOUR A. Modeling air-to-ground path loss for low altitude platforms in urban environments[C]//*Proceedings of 2014 IEEE Global Communications Conference*. [S.l.]: IEEE, 2014: 2898-2904.
- [20] ANDERSEN J B, RAPPAPORT T S, YOSHIDA S. Propagation measurements and models for wireless communications channels[J]. *IEEE Communications Magazine*, 1995, 33(1): 42-49.
- [21] 蔡跃明. 现代移动通信[M]. 北京:机械工业出版社, 2017.
CAI Yueming. *Modern mobile communications*[M]. Beijing: China Machine Press, 2017.
- [22] GOODFELLOW I, BENGIO Y, COURVILLE A, et al. *Deep learning*[M]. Cambridge: MIT Press, 2016.
- [23] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.]: IEEE, 2015: 3431-3440.
- [24] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[C]//*Proceedings of International Conference on Medical Image Computing and Computer-assisted Intervention*. Cham: Springer, 2015: 234-241.

作者简介:



胡田钰(1996-),男,硕士研究生,研究方向:频谱态势的感知与补全、生成对抗网络、机器学习, E-mail: huty@nuaa.edu.cn。



吴启晖(1970-),通信作者,男,教授,博士生导师,研究方向:认知无线网络算法和优化、软件无线电、无线通信, E-mail: wuqihui2014@sina.com。



黄洋(1989-),男,副教授,研究方向:无线通信、MI-MO系统、凸优化、机器学习、通信信号处理, E-mail: yang.huang.ceie@nuaa.edu.cn。

(编辑:陈珺)