

融合 Stackelberg 博弈和联邦学习的多星协作频谱认知方法研究

丁晓进¹, 徐叶辉², 包文², 张更新¹

(1. 南京邮电大学通信与信息工程学院, 江苏 南京 210003; 2. 南京邮电大学物联网学院, 江苏 南京 210003)

摘要: 针对低成本和小型化低轨卫星的监测角度和方向分辨率相对较低、处理能力和峰值功率受限等因素造成单颗低轨卫星频谱认知能力弱的问题, 提出了融合 Stackelberg 博弈和联邦学习的多星协作频谱认知方法。首先, 结合各频谱认知卫星的可用算力、认知性能、处理与传输时延等特性, 建立面向多频谱认知任务的协作卫星选择与算力资源分配算法; 其次, 基于所选择的节点和所分配的算力, 设计低复杂度的多星协作频谱认知策略, 其可自动辨识频谱空洞、检测干扰和识别调制模式。仿真实验结果表明, 相比于单节点认知方法, 所设计多星协作频谱认知策略能显著提升认知性能, 且相比于对比模型, 所设计策略中的模型可在不损失性能时, 模型的参数量和浮点运算量降低分别可达 96.69% 和 93.32%。

关键词: 卫星频谱认知; 多星协作; Stackelberg 博弈; 联邦学习

中图分类号: TN92

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2024034

Study on multi-satellite cooperative spectrum cognitive method integrating Stackelberg game and federated learning

DING Xiaojin¹, XU Yehui², BAO Wen², ZHANG Gengxin¹

1. School of Communications and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

2. School of Internet of Things, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

Abstract: To solve the problem of the weak spectrum-cognitive ability caused by monitoring angle, direction resolution, limited processing ability and peak power for a low-earth-orbit (LEO) satellite, a multi-satellite cooperative spectrum cognitive method integrating Stackelberg game and federated learning was proposed. Firstly, considering the available computing resource, cognitive performance, processing and transmission delay of each spectrum cognitive satellite, a cooperative-satellite selection and computing-resource allocation algorithm was built for multiple spectrum-cognitive tasks. Secondly, based on the selected satellites and the allocated computing resources, a low-complexity multi-satellite cooperative spectrum cognitive strategy was further designed, which could automatically sense the spectrum holes, and detect interference as well as identify the modulation mode. Simulation results demonstrate that compared to the single-node cognitive method, the designed multi-satellite cooperative spectrum cognitive strategy can obtain a better cognitive performance. Moreover, comparing with the existing model, the model utilized in the designed strategy can effectively achieve 96.69% and 93.32% lower number of parameters and required floating point operations per second, whilst maintaining the performance.

Keywords: satellite spectrum cognitive, multi-satellite cooperation, Stackelberg game, federated learning

收稿日期: 2023-08-07; 修回日期: 2023-10-15

基金项目: 国家自然科学基金资助项目 (No.91738201, No.62171234); 2021-JCJQ-LB-006 重点实验室基金资助项目 (No.6142411422118)

Foundation Items: The National Natural Science Foundation of China (No.91738201, No.62171234), The National Key Laboratory Foundation of 2021-JCJQ-LB-006 (No.6142411422118)

0 引言

近年来, 不断涌现以 OneWeb^[1]、Starlink^[2]和 Kuiper^[3]等为代表的低轨卫星星座, 导致频谱资源紧缺问题日益突出。为提高频谱资源利用率, 不同低轨卫星星座间、不同低轨卫星间、低轨卫星星座与地面无线通信系统间的频谱可能会出现重叠^[4]。随着空间信息网络的建设, 对电磁环境的安全要求不断提高, 且电磁环境安全掌控对现代化战争至关重要^[5], 亟需对电磁频谱进行有效监管。考虑卫星具有覆盖地域宽、视角高等特性, 其可实现广域大纵深监测, 且能对地面设备无法监测的卫星上行信号进行监测。因此, 基于卫星(尤其是低轨卫星)进行电磁频谱环境认知成为较优的选择。

当前, 基于卫星进行电磁频谱环境认知已成为研究热点。根据参与认知的卫星数量不同, 可分为单星认知^[6]和多星认知^[7]; 根据认知数据的处理方式不同, 又可分为地面处理^[8]和星上处理^[9]。事实上, 这2种分类方式相互交叉, 即无论是单星认知还是多星认知, 都可采用地面处理或星上处理方式。单星认知具体实现比较简单, 但受限于低成本和小型化要求, 单颗低轨卫星的监测角度和方向分辨率相对较低, 导致单颗低轨卫星的认知能力受限。与此同时, 随着 Starlink 等大规模低轨卫星星座的逐步部署, 多颗低轨卫星同时可视将成为常态, 这也使多星认知具备可行性。多星认知又包括多星组阵认知^[10]和多星协同认知^[7,9], 其中, 多星组阵认知中的主卫星可利用最大化信干噪比等准则对伴飞卫星所接收到的信号进行信号级融合, 以提升接收信号的灵敏度, 但组阵认知要求各伴飞卫星所接收信号间的时延差和频率差可忽略, 难以适用于大规模星座场景; 多星协同认知中融合中心可基于与、或等准则对各个卫星的认知结果进行决策级或特征级融合, 以提升认知性能, 可用于大规模星座场景。在多星协同认知中, 尽管将星上认知数据透明转发到地面信关站(融合中心)并由其进行处理可降低星上处理负担, 但会不可避免地降低认知结果的时效性。实际上, 未来卫星互联网星座普遍会采用星上处理方式, 这种方式可提升时效性, 也会降低卫星到信关站(融合中心)链路的认知数据传输负担。

但是, 现有的卫星频谱认知研究主要聚焦在感知频谱空洞的单项任务上, 这显然无法满足电磁环

境安全掌控要求。为满足该要求, 卫星可能需要同时完成多项任务, 包括但不限于频谱空洞发现、干扰检测和信号特征挖掘等。相比于单任务, 多任务涉及不同任务间的资源分配。如何根据各任务的具体情况设计资源分配算法, 以降低多任务的总处理时延具有重要意义。此外, 将人工智能应用于卫星以辅助其进行频谱认知也获得了研究关注^[4,7]。在这些研究中, 卫星可被视为智能体, 这些智能体在进行模型参数和认知结果融合时可采用与、或等融合准则。这些准则考虑的因素相对较单一, 未综合考虑更多的因素, 如数据集大小和完成任务的性能等。而且, 这些智能算法实现复杂度相对较高, 相比于地面服务器, 卫星处理能力受限。这些有限的处理能力更多被用于处理业务数据, 少部分资源被用于完成频谱认知任务。

针对以上问题, 本文提出了融合 Stackelberg 博弈^[11]和联邦学习^[12]的多星协作频谱认知策略, 兼顾多认知任务时的认知性能和计算能力, 给出了包含协作节点选择、资源分配、协作认知和模型优化的整体解决方案。首先, 针对未来大规模星座同时可用卫星多的特点, 提出了基于 Stackelberg 博弈的协作节点选择与资源分配算法, 挑选协作节点, 并为各任务分配可用的计算资源; 其次, 为支撑多星协作认知, 设计了基于联邦学习的多星协作频谱认知策略, 优化了多星融合准则和神经网络模型的参数数量, 提升频谱认知性能, 降低计算复杂度; 最后, 构建了基于 Kubeedge 的边缘计算平台, 利用其对所提协作频谱认知策略进行了评估验证, 为星上实际测试提供支撑。本文的主要研究工作及贡献如下。

1) 提出了基于 Stackelberg 博弈的协作节点选择与资源分配算法。具体地, 针对融合中心和认知卫星节点, 建立了节点选择与计算资源分配优化问题, 综合考虑融合中心的效用函数值和认知卫星节点的效用函数值, 构建了面向领导者和跟随者的双层 Stackelberg 博弈模型, 实现两者间的平衡。

2) 设计了基于联邦学习的多星协作频谱认知策略, 包括数据预处理、模型设计、模型融合。数据预处理结合短时傅里叶变换和频偏修正, 将频谱数据转化为相应的时频图和星座图, 从而将频谱认知问题转变为图像分类问题; 模型设计通过堆叠次数和输出通道数优化、模型剪枝和量化, 在不损失性能的前提下, 降低轻量级模型的参数

数量；模型融合通过所设计的融合准则将各认知节点的模型参数进行融合，以获得优化的全局融合模型。

3) 仿真实验结果表明，相比于平均分配算法，所提资源分配算法完成 3 种频谱认知任务时总耗时较少；相比于标准的 ShuffleNet 网络，改进后的模型参数量和所需的浮点运算量 (FLOPs, floating point operations per second) 都会显著降低；相比于联邦平均融合准则，所设计的融合准则可提升认知性能；增加认知节点数量可提升认知性能。进一步基于 Kubeedge 和工控板搭建了边缘计算平台，并利用其实际测试了所设计的方法，测试结果表明，通过计算资源的优化分配和模型的低复杂度设计，3 种频谱认知任务可在平台上稳定运行。

1 系统模型

图 1 给出了由一个卫星星座、多个用频节点和一个信关站组成的卫星频谱认知网络，其中卫星星座可用于执行频谱认知功能。针对给定的卫星星座，假设卫星间具有星间链路，且在这些卫星上都部署了神经网络模型。对于给定的某个地理区域，假设某时段同时覆盖该区域的卫星数量为 N ，这些卫星先各自独立进行频谱认知，然后将结果传送到融合中心进行融合。需要说明的是，融合中心可以部署在地面信关站，也可部署在某颗卫星上。

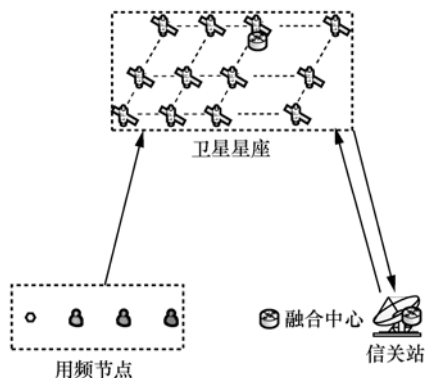


图 1 卫星频谱认知网络

在每颗卫星执行频谱认知功能时，不仅要发现频谱空洞，还要辨识是否存在干扰和识别调制模式等，即每颗卫星需要同时完成多项认知任务。那么，同时执行多项认知任务时的星间协作会涉及以下问题，包括协作卫星节点选择、各卫星内不同任务

间的计算资源分配、模型参数更新、星间认知结果融合等。

考虑 Stackelberg 博弈中包含领导者和跟随者两层模型^[11]，与本文涉及的融合中心和认知卫星两类角色相匹配，且联邦学习也被用于分布式训练网络^[13]。因此本文通过融合 Stackelberg 和联邦学习设计了多星协作频谱认知技术，其总体流程如图 2 所示。

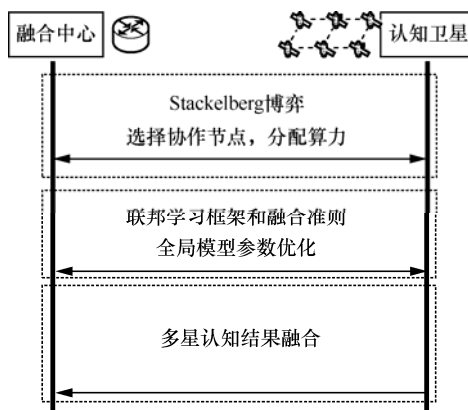


图 2 多星协作频谱认知技术总体流程

具体来说，首先，针对给定地理区域内同时可见的卫星和各认知任务的具体性能要求，分别面向融合中心和认知卫星建立协作节点选择和算力分配优化问题，通过 Stackelberg 博弈来求解该优化问题，以确定参与协作的节点和各节点内不同任务所分配的算力。其次，基于所选择的节点和分配的算力，利用联邦学习框架和所设计的融合准则，优化全局模型参数。当某协作卫星节点要离开给定的地理区域，且有新卫星节点加入时，原节点可通过星间链路将自己的模型参数发送给新加入的节点，以加快全局模型参数优化过程。最后，各协作卫星利用所分配的算力和优化的模型参数，同时进行多项频谱认知任务，并将任务对应的认知结果发送给融合中心进行融合，以提升认知性能。

需要指出的是，所设计的多星协作频谱认知系统具备合理性和可实现性。1) 在未来大规模低轨卫星星座中，某一区域会同时可见多颗卫星，且未来大规模星座往往具有星间链路，这给多星间协作创造了条件；2) 不同卫星间的位置差异会增加卫星所采集频谱数据的异构性，通过卫星间的协作具备提升频谱认知性能的可能；3) 随着星上处理能力的不断提升，星上执行频谱认知任务的可能性不断增强，通过对模型结构和参数进行优化，可降低对星上计

算资源和通信资源的消耗; 4) 不仅星地间可进行知识迁移, 由于同一轨道的卫星间具有较强的相关性, 星间同样可进行知识迁移, 这可在降低星上处理开销的同时, 减少不必要的模型训练开销。

2 基于 Stackelberg 博弈的协作节点选择与资源分配

本节通过刻画能耗、时延和模型完成任务的性能等因素来分别建立融合中心和认知卫星的效用函数, 并以最大化效用函数来建模协作节点选择和资源分配优化问题, 进而基于 Stackelberg 博弈进行优化问题求解。

2.1 协作节点选择与资源分配优化问题建模

给定卫星 n , 用 $f_{n,\max}$ 表示其所能提供的最大计算资源, 即 CPU 的频率, 该卫星分配给任务 j 的计算资源为 $f_{n,j}$, $1 \leq j \leq J$, J 表示卫星要完成的认知任务数量。用 c_n^j 表示卫星 n 处理任务 j 中一个数据集样本所需要的 CPU 的周期数, 则卫星 n 完成一轮任务 j 的本地训练所消耗的时间为

$$T_{n,p}^j = \frac{c_n^j D_n^j}{f_{n,j}} \quad (1)$$

其中, D_n^j 表示任务 j 中数据集总样本量。与此同时, 卫星 n 完成一轮任务 j 的本地训练所消耗的能量为

$$E_{n,p}^j = \gamma c_n^j D_n^j f_{n,j}^2 \quad (2)$$

其中, γ 是计算芯片组的有效电容系数^[13]。

假设融合中心部署在地面信关站 (部署在卫星上的分析是相似的), 卫星 n 通过星间链路将模型参数发给卫星 m , 由其将模型参数转发给融合中心。卫星 m 到融合中心的传输速率为

$$r_m = B_m \text{lb} \left(1 + \frac{P_m |h_m|^2}{B_m N_0} \right) \quad (3)$$

其中, B_m 表示带宽, P_m 表示卫星 m 的发射功率, h_m 表示信道增益, N_0 表示噪声方差。则卫星 n 将任务 j 的模型参数传输到融合中心所需的总时间为

$$T_{n,c}^j = \frac{|w_n^j|}{r_m} + t_{n,\text{ISL}} \quad (4)$$

其中, $|w_n^j|$ 表示任务 j 对应的模型参数量, $t_{n,\text{ISL}}$ 表示卫星 n 将任务 j 对应的模型参数发给卫星 m 的传

输时间。假设每一跳发射功率都为 P_n , 则卫星 n 将任务 j 的模型参数传输到融合中心的能耗为

$$E_{n,c}^j = P_m \frac{|w_n^j|}{r_m} + P_n t_{n,\text{ISL}} \quad (5)$$

对于任务 j , 一轮完整的全局模型更新不仅需要卫星 n 将任务 j 的模型参数传输到融合中心所需的能耗和时间, 还需要考虑融合中心将融合后任务 j 的模型参数传输到卫星 n 的能耗和时间。假设两次传输的能耗和时间都相同, 故总能耗和总时间可以分别表示为

$$E_n^j = E_{n,p}^j I_n^j + 2E_{n,c}^j \quad (6)$$

$$T_n^j = T_{n,p}^j I_n^j + 2T_{n,c}^j \quad (7)$$

其中, I_n^j 表示任务 j 达到正确率 θ_n^j 需要的迭代轮次^[14], 计算式为

$$I_n^j = I_0 \log \left(\frac{1}{1 - \theta_n^j} \right) \quad (8)$$

其中, I_0 表示一个常数。对于任务 j 和给定的数据集样本量 D_n^j , 该任务的正确率定义为

$$\theta_n^j = \frac{1}{D_n^j} \sum_{i=1}^{D_n^j} I \left(S_w(x_n^j(i)), y_n^j(i) \right) \quad (9)$$

其中, $S_w(\cdot)$ 表示模型输出值, $x_n^j(i)$ 和 $y_n^j(i)$ 分别表示认知卫星 n 中任务 j 的第 i 个样本和该样本对应的标签。此外, $I(\cdot)$ 是一个指示函数, 当 $S_w(x_n^j(i))$ 与 $y_n^j(i)$ 相等时, 值为 1, 否则为 0。根据文献[14], 在给定数据集总样本量 D_n^j 时, θ_n^j 的最大值可表示为

$$\theta_{n,\max}^j = (1 - \alpha) - \beta (D_n^j)^\sigma \quad (10)$$

其中, α 为可实现的最小误差, β 为学习率, σ 为衰减率。如果一个认知卫星上的数据集样本量过少, 那么该卫星通常不会被选为协作节点。这主要是由于对于融合中心, 选择具有较高性能的卫星节点作为协作节点时, 这些节点可尽可能快地提供正确率较高的模型参数, 从而在降低训练开销的同时提升融合模型的性能。所选节点可能会对全局模型有较大的贡献度。对于卫星 n 和任务 j , 该卫星中任务 j 对全局融合模型的贡献度可由 $\theta_n^j - \theta_g^j$ 表示, 其中 θ_g^j 为任务 j 在融合中心中全局模型的正确率。基于该贡献度, 融合中心的效用函数可进一步定义为

$$\eta(\mathbf{f}, \boldsymbol{\theta}, S) = \frac{\sum_{j=1}^J \sum_{n=1}^{|S|} \omega_j (\theta_n^j - \theta_g^j)}{\sum_{n=1}^{|S|} T_n^j} \quad (11)$$

其中, ω_j 为任务 j 的权重系数, $\sum_{j=1}^J \omega_j = 1$, $\mathbf{f} = [\{f_{1,1}, \dots, f_{1,J}\}, \dots, \{f_{|S|,1}, \dots, f_{|S|,J}\}]$, $\boldsymbol{\theta} = [\{\theta_1^1, \dots, \theta_1^J\}, \dots, \{\theta_{|S|}^1, \dots, \theta_{|S|}^J\}]$, S 为 N 颗认知卫星中最终被选择参与协作的卫星集合, $|S| \leq N$, $|S|$ 表示集合中卫星数量。

将式(1)、式(7)和式(8)代入式(11)中, 可得

$$\eta(\mathbf{f}, \boldsymbol{\theta}, S) = \frac{\sum_{j=1}^J \sum_{n=1}^{|S|} \omega_j (\theta_n^j - \theta_g^j)}{\sum_{j=1}^J \sum_{n=1}^{|S|} \frac{c_n^j D_n^j}{f_{n,j}} I_0 \log \left(\frac{1}{1 - \theta_n^j} \right) + 2T_{n,c}^j} \quad (12)$$

从式(12)可以看出, 可通过调节计算资源和模型性能来优化效用函数值, 从而给融合中心带来更高贡献。为最大化融合中心的效用函数, 融合中心的优化问题可以被建模为

$$\begin{aligned} & \max_{\mathbf{f}, \boldsymbol{\theta}, S} \quad \eta \\ \text{s.t.} \quad & \text{C1: } \theta_g^j \leq \theta_n^j \leq \theta_{n,\max}^j, \forall n, \forall j \\ & \text{C2: } \sum_{j=1}^J f_{n,j} \leq f_{n,\max}, \forall n \end{aligned} \quad (13)$$

其中, C1 为认知卫星节点模型正确率约束, 当认知卫星节点的正确率 $\theta_{n,\max}^j$ 小于 θ_g^j 时, 该认知卫星节点将不会被选择; C2 为认知卫星节点算力分配约束, 即各任务所分配的算力不能超过最大算力, 且 $1 \leq j \leq J$, $n \in S$ 。

与式(11)类似, 基于贡献度, 认知卫星节点 n 的效用函数可被定义为

$$\mu(\mathbf{f}_n, \boldsymbol{\theta}_n) = \sum_{j=1}^J \frac{\omega_j (\theta_n^j - \theta_g^j)}{E_n^j + \varphi_j T_n^j} \quad (14)$$

其中, φ_j 为任务 j 对时延的敏感系数, φ 越大表示所耗费时间对效用函数影响越大, $\mathbf{f}_n = \{f_{n,1}, f_{n,2}, \dots, f_{n,J}\}$, $\boldsymbol{\theta}_n = \{\theta_n^1, \theta_n^2, \dots, \theta_n^J\}$, $n \in S$ 。在 E_n^j 和 φ 给定时, 认知卫星节点可通过调节投入的

计算资源来优化效用函数值。通常, 对于认知卫星节点而言, 其希望通过仅投入较低的功率和计算资源, 获得较优的本地模型性能。

因此, 认知卫星节点的优化问题可以被建模为

$$\begin{aligned} & \max_{\mathbf{f}_n, \boldsymbol{\theta}_n} \quad \mu \\ \text{s.t.} \quad & \text{C1: } \theta_g^j \leq \theta_n^j \leq \theta_{n,\max}^j, \forall n, \forall j \\ & \text{C2: } \sum_{j=1}^J f_{n,j} \leq f_{n,\max}, \forall n \\ & \text{C3: } T_n^j \leq T_{n,\max}^j, \forall n, \forall j \end{aligned} \quad (15)$$

其中, C3 为认知卫星节点 n 中认知任务 j 所能容忍的时延约束, $T_{n,\max}^j$ 为一次全局模型迭代中所能承受的最大时延阈值, $1 \leq j \leq J$, $n \in S$ 。从式(15)可以看出, 当认知卫星节点的正确率 $\theta_{n,\max}^j < \theta_g^j$ 或时延大于所能承受的最大时延阈值时, 该认知卫星节点将不会被选择参与协作。

2.2 基于 Stackelberg 博弈的问题求解

2.1 节分别针对融合中心和认知卫星节点进行了优化问题建模。从式(13)和式(15)可以看出, 2 个问题都将计算资源和模型性能作为优化变量。融合中心仅考虑了贡献度和时延, 然而, 由于峰值功率受限, 认知卫星节点还考虑了能耗。从式(2)可以看出, 增大算力会导致能耗增加。如果没有有效的激励机制, 认知卫星节点就无法自愿投入融合中心所需的计算资源来完成本地模型训练, 进而会影响全局模型的收敛速度。这也会导致融合中心和认知卫星节点分别求解的计算资源和模型性能不一致的问题。该问题的关键是如何平衡融合中心的效用函数值和认知卫星节点的效用函数值, 从而以较优的方式完成全局模型训练过程。

受 Stackelberg 博弈中领导者和跟随者模型的启发, 本文将融合中心视为领导者, 认知卫星节点视为跟随者, 从而基于 Stackelberg 博弈设计了一种激励机制, 以解决上述问题。基于融合中心所提供的奖励, 认知卫星可在资源分配时做出相应的调整, 其中融合中心向认知卫星 n 提供的奖励可记为 (R_{f_n}, R_{θ_n}) 。这也使认知卫星 n 在考虑自身贡献度、能耗和时延的基础上, 还要结合融合中心所提供的奖励。将认知卫星 n 的效用函数重新定义为

$$\begin{aligned} \Omega_n = & \alpha_n \eta(\mathbf{f}, \boldsymbol{\theta}, S) + \mu(\mathbf{f}_n, \boldsymbol{\theta}_n) + \\ & R_{f_n} \sum_{j=1}^J f_{n,j} + \frac{R_{\theta_n}}{J} \sum_{j=1}^J \theta_n^j \end{aligned} \quad (16)$$

其中, α_n 为 0 到 1 之间的常数, 表示认知卫星节点对融合中心的信任程度; $\eta(\mathbf{f}, \boldsymbol{\theta}, S)$ 和 $\mu(\mathbf{f}_n, \boldsymbol{\theta}_n)$ 分别由式(12)和式(14)给出, R_{f_n} 和 R_{θ_n} 分别表示融合中心对认知卫星 n 所分配计算资源和所获得模型性能的激励。 R_{f_n} 和 R_{θ_n} 可分别表示为

$$R_{f_n} = \frac{1}{\sum_{n=1}^{|S|} \sum_{j=1}^J f_{n,j}} \sum_{j=1}^J f_{n,j} \quad (17)$$

$$R_{\theta_n} = \frac{1}{\sum_{n=1}^{|S|} \sum_{j=1}^J \theta_n^j} \sum_{j=1}^J \theta_n^j \quad (18)$$

利用重新定义的效用函数, 本文将融合中心和认知卫星的双层 Stackelberg 博弈问题建模为

$$\begin{aligned} & \text{领导者:} && \max_{\mathbf{f}, \boldsymbol{\theta}, S} \eta \\ & \text{跟随者:} && \max_{\mathbf{f}_n, \boldsymbol{\theta}_n} \Omega_n \\ \text{s.t.} &&& \text{C1: } \theta_n^j \leq \theta_n^j \leq \theta_{n,\max}^j, \forall n, \forall j \\ &&& \text{C2: } \sum_{j=1}^J f_{n,j} \leq f_{n,\max}, \forall n \\ &&& \text{C3: } T_n^j \leq T_{n,\max}^j, \forall n, \forall j \end{aligned} \quad (19)$$

其中, $1 \leq j \leq J$, $n \in S$ 。为解决该问题, 本文进一步设计了一种基于 Stackelberg 博弈的节点选择和算力分配算法, 主要包括四部分, 如算法 1 所示。第一部分, 领导者执行认知卫星节点选择, 获得参与协作的跟随者, 包括第 1) 行; 第二部分, 领导者利用 SCIP (solving constraint integer program) 求解器^[15]求解优化问题, 并计算对跟随者的激励值, 包括第 3)~ 5) 行; 第三部分, 跟随者求解优化问题, 并将求解结果发送给领导者, 包括第 6) 行; 第四部分, 领导者基于跟随者所发送的求解结果, 判断是否满足停止迭代条件, 包括第 7)~ 12) 行, 如未满足, 则重复前述步骤, 否则停止迭代。此外, 后续的仿真分析也表明, 该算法只需很少的迭代次数就能够收敛。

算法 1 基于 Stackelberg 博弈的节点选择和算力分配算法

输入 认知卫星 n , 认知卫星节点中各认知任务的数据集样本量 D_n^j , 认知卫星节点处理器最大可用的频率 $f_{n,\max}$, 认知卫星节点总的任务数 J ,

认知卫星节点中任务所能承受的最大时延 $T_{n,\max}^j$, 任务 j 对时延的敏感系数 φ_j , 认知卫星节点对融合中心的信任程度系数 α_n , 博弈停止迭代条件 \mathcal{G} , 最大迭代次数 N_{τ_1} , $1 \leq j \leq J$, $1 \leq n \leq N$

输出 S 、 \mathbf{f}^* 和 $\boldsymbol{\theta}^*$

初始化 初始化各节点中不同任务所分配的算力 \mathbf{f} 、不同任务的模型正确率 $\boldsymbol{\theta}$ 和各任务的权重系数 ω_j , 迭代次数 $\tau_1 = 0$

- 1) 领导者根据约束 C1 和 C3, 执行认知卫星节点选择, 将满足约束的卫星放入卫星集合 S ;
- 2) 循环
- 3) 领导者利用 SCIP 求解器求解 $\max_{\mathbf{f}, \boldsymbol{\theta}} \eta$, 获得本次迭代优化的 η_{τ_1} 、 \mathbf{f}_{τ_1} 、 $\boldsymbol{\theta}_{\tau_1}$;
- 4) 领导者利用式(17)和式(18)计算本次迭代中各跟随者激励值 R_{f_n, τ_1} 、 R_{θ_n, τ_1} , $n \in S$;
- 5) 领导者将计算的 R_{f_n, τ_1} 、 R_{θ_n, τ_1} 发送至对应的追随者;
- 6) 追随者基于接收到的 R_{f_n, τ_1} 、 R_{θ_n, τ_1} 和 SCIP 求解器, 求解 $\max_{\mathbf{f}_n, \boldsymbol{\theta}_n} \Omega_n$, 得到 $\{f'_{n,j, \tau_1}, \theta'^j_{n, \tau_1}\}$, 并将 $\{f'_{n,j, \tau_1}, \theta'^j_{n, \tau_1}\}$ 发送至领导者, $1 \leq j \leq J$, $n \in S$;
- 7) 领导者基于跟随者发送的 $\{f'_{n,j, \tau_1}, \theta'^j_{n, \tau_1}\}$ 和式(12), 获得 η'_{τ_1} , 并计算 $|\Delta\eta| = |\eta'_{\tau_1} - \eta_{\tau_1}|$, $n \in S$;
- 8) if $|\Delta\eta| \leq \mathcal{G}$ 或 $\tau_1 \geq N_{\tau_1}$
- 9) $\mathbf{f}^* = \left[\{f'_{1,1, \tau_1}, \dots, f'_{1,J, \tau_1}\}, \dots, \{f'_{N^*,1, \tau_1}, \dots, f'_{N^*,J, \tau_1}\} \right]$
 $\boldsymbol{\theta}^* = \left[\{\theta'^1_{1, \tau_1}, \dots, \theta'^J_{1, \tau_1}\}, \dots, \{\theta'^1_{N^*, \tau_1}, \dots, \theta'^J_{N^*, \tau_1}\} \right], N^* = |S|$
- 10) break
- 11) else
- 12) $\tau_1 = \tau_1 + 1$, 返回步骤 4)
- 13) end if

3 基于联邦学习的多星协作频谱认知

本节介绍了基于联邦学习的多星协作频谱认

知策略，包括数据预处理与评估指标、模型设计、模型训练与结果融合。本节给出了 3 种典型的频谱认知任务，即频谱感知、干扰检测和调制模式识别。其中，频谱感知可发现频谱是否被占用；干扰检测可发现被占用的频谱中是否存在干扰；调制模式识别可用于检测不存在干扰时信号的调制模式。

3.1 数据预处理与评估指标

在第 t 个感知时隙，认知卫星 n 接收到的信号可被表示为

$$x_n(t) = s(t) + n(t) \quad (20)$$

其中， $s(t)$ 表示目标信号， $n(t)$ 表示加性白高斯噪声。为分析信号特征，借助短时傅里叶变换 (STFT, short time Fourier transform) 对接收到的信号进行预处理，接收信号 $x_n(t)$ 经 STFT 后为

$$X_n(\Omega, t) = \int_{-\infty}^{+\infty} x_n(\tau)g(\tau - t)e^{-j2\pi\Omega\tau}d\tau \quad (21)$$

其中， $g(\cdot)$ 表示窗函数， Ω 为频率。对 STFT 的结果取模平方运算，可得到信号的时频图。图 3 分别给出了频谱未被占用和被占用 2 种情况下的时频图。如图 3 所示，如果频带被占用，相应区域会呈现明显的亮带，否则较暗，从而未被占用和被占用的时频图会有差异。这也意味着可将频谱感知问题转化为图像分类问题。




图 3 频谱未被占用和被占用 2 种情况下的时频图

当判定频谱被占用时，可进一步辨别是否存在干扰。这里的干扰是指待认知的频谱被多个用频节点同时占用所造成的干扰。无干扰和有干扰时的时频图如图 4 所示。假设不同节点的信号在带宽或功率上会存在差异，如图 4(b)所示，当存在干扰时，由于不同信号间带宽或功率的差异，在时频图上呈现出不同宽度和深浅程度的亮带，从而基于该图可辨别是否存在干扰。




图 4 无干扰和有干扰时的时频图

此外，当检测到待认知的频谱中不存在干扰时，还可进一步识别信号的调制样式。然而，由于实际接收的信号会存在一定的频偏，需先消除频偏。以 M 元相移键控 (MPSK) 信号为例，用 $x_n^m(t)$ 表示 $x_n(t)$ 的 m 次方，对其进行 N_{fft} 点的快速傅里叶变换后可得 X'_n 。进而分析 X'_n 中最大幅度对应的位置为

$$O = \begin{cases} \arg \max(|X'_n|), \arg \max(|X'_n|) \leq \frac{N_{\text{fft}}}{2} \\ \arg \max(|X'_n|) - N_{\text{fft}}, \text{其他} \end{cases} \quad (22)$$

通过所发现的位置 O 和信号的采样率 f_s ，根据文献[16]，可估计出信号的频偏为

$$f_{\text{offset}} = \frac{f_s(O-1)}{N_{\text{fft}}m} \quad (23)$$

利用所估计出的频偏，对接收到的信号进行频偏修正，并绘制星座图，如图 5 所示。本文考虑了 BPSK、QPSK、8PSK、16QAM 这 4 种调制方式，基于图 5，可识别信号调制样式，从而也可将调制模式识别问题转化为图像分类问题。




图 5 不同调制模式的星座图

至此，已完成 3 种频谱认知任务的数据预处理工作，后续将通过所设计的神经网络来进一步完成这 3 种频谱认知任务。在完成这 3 种任务时，需要利用相应的评估指标。

对于频谱感知任务，基于纽曼-皮尔逊定理，似然比可被用于辅助神经网络进行判决^[7]。当似然比大于检测阈值 χ 时，表明频谱被占用，则检测状态为 $\hat{H} = H_1$ ；否则，频谱未被占用，即 $\hat{H} = H_0$ 。其中， H_0 表示频谱未被占用， H_1 表示频谱被占用。检测阈值 χ 为

$$\chi = \mathbf{Y}_{H_0}(\lfloor \psi L \rfloor) \quad (24)$$

其中, ψ 表示虚警概率, $\lfloor \cdot \rfloor$ 表示向下取整操作, L 表示样本数量, \mathbf{Y}_{H_0} 表示频谱未被占用时 L 个频谱感知样本的似然比经降序排列后的数组, $\mathbf{Y}_{H_0}(\lfloor \psi L \rfloor)$ 表示 \mathbf{Y}_{H_0} 数组中的第 $\lfloor \psi L \rfloor$ 个值。进而可利用正确检测概率 P_d 来统计判决性能, P_d 的定义式为

$$P_d = \Pr(\hat{H} = H_1 | H_1) \quad (25)$$

对于干扰检测与调制模式识别任务, 所采用的指标为式(9)所示的正确率。

3.2 模型设计

考虑星上可用于频谱认知任务的算力和通信资源受限, 为降低星上算力和通信资源的开销, 需要设计低复杂度的网络模型, 且要尽可能降低星间交互数据量和交互次数。近年来, 已有不少轻量级神经网络模型, 包括 EfficientNet^[17]、MobileNet^[18]、ShuffleNet^[19]等, 将频谱感知、干扰检测和调制模式识别任务转化为图像分类任务, 这些任务的分类类别相对较少。考虑 ShuffleNet 模型

使用分组卷积以及通道随机重排技术提升了对图像特征的提取性能, 且经多次实验评估后, 选择基于 ShuffleNetV2 模型进行改进设计, 模型结构如图 6 所示, 其中 DWConv 表示深度可分离卷积。

为降低模型的复杂度, 本文通过实验评估, 对 Stage2~Stage4 的堆叠次数和输出通道数 N_c 进行了裁减, 改进后的模型结构如表 1 所示。

表 1 改进后的模型结构

层名称	输出大小	池化尺寸	步长	堆叠次数	输出通道数
频谱图像	224×224	—	—	—	3
Conv1	112×112	3×3	2	1	24
MaxPool	56×56	3×3	2	1	24
Stage2	28×28	—	2	1	36
Stage3	14×14	—	2	1	48
Stage4	7×7	—	2	1	96
Conv5	7×7	1×1	1	1	190
GlobalPool	1×1	7×7	—	—	—
FC+Softmax	—	—	—	—	$N \times 1$

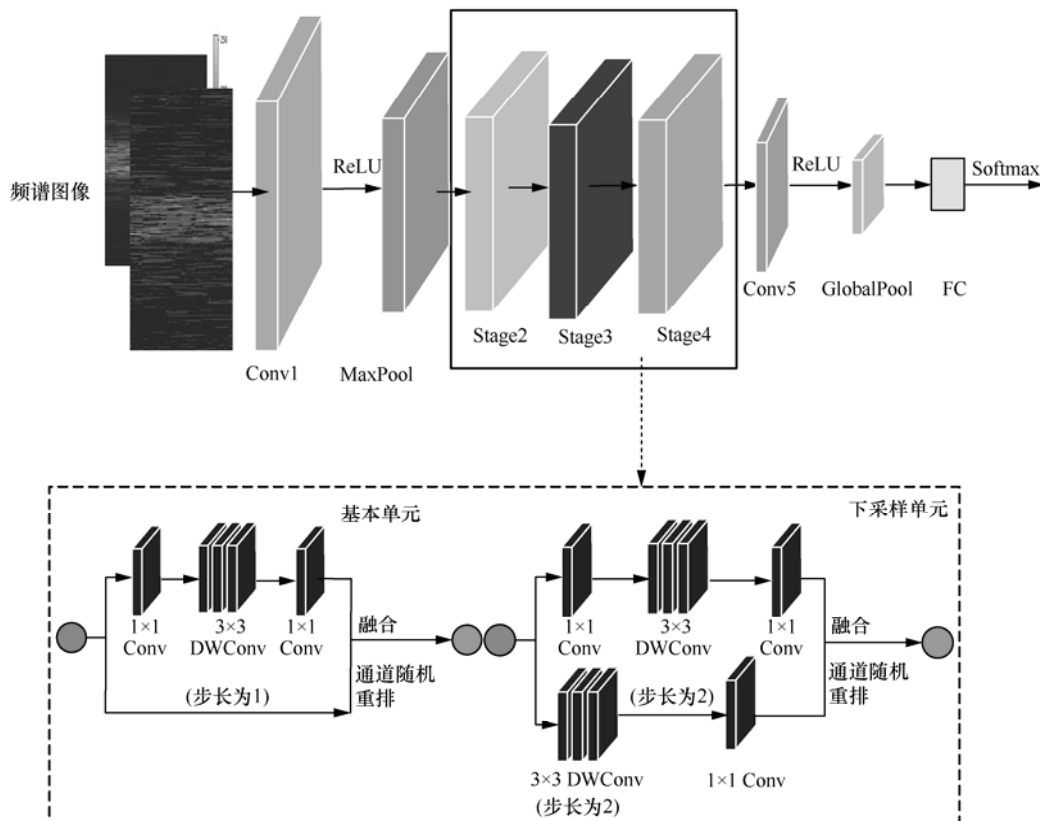


图 6 模型结构

模型训练过程中进一步运用了模型剪枝和量化技术^[20]以降低模型计算量。不同于 Dropout 层在模型训练之前就随机去除一些神经网络节点间的连接，剪枝技术可在模型训练过程中将隐藏层中的部分较小且对模型推理几乎没有作用的权重置为 0，以减少所需的计算量。对于待剪枝的某一神经网络层，首先，计算该层中每个通道对应的神经元权重的 L2 范数；其次，将计算的范数进行降序排列；再次，结合所设置的剪枝率，获得待剪枝的通道数 C_p ，即 $C_p = \lfloor \text{该层中总通道数} \times \text{剪枝率} \rfloor$ ；最后，将排在后面的 C_p 个通道进行剪枝。

进而基于模型量化技术，建立浮点模型和定点模型间的映射关系，可将量化前的浮点模型（如 32 位浮点数）转化为定点模型（如 8 位整数），从而降低算力开销和认知卫星节点与融合中心的通信开销。相应地，融合中心可通过反量化恢复浮点模型。评估结果表明，相比于标准的 ShuffleNetV2，通过堆叠次数和输出的通道数优化、剪枝和量化后的模型参数数量明显减少，显著降低了模型计算量，且改进后的模型在 3 种频谱认知任务上能够取得较好的性能。为表述方便，将改进的模型记为结合堆叠次数和输出的通道数优化、剪枝和量化的 ShuffleNetV2（ShuffleNetV2-RCPQ, ShuffleNetV2 with reduced channel, pruning and quantization）模型。此外，为降低模型部署负担，3 种频谱认知任

务都使用了同样的 ShuffleNetV2-RCPQ 模型。

3.3 模型训练与结果融合

3.2 节已初步设计了神经网络，本节进一步基于联邦学习架构，将所设计的模型部署到认知卫星和融合中心，以完成模型训练和实际的频谱认知任务的在线测试。其中，模型训练又包括模型在认知卫星处完成本地训练、融合中心融合模型与融合后的模型更新三部分。基于联邦学习的模型参数融合框架如图 7 所示。首先，参与协作的各认知卫星基于各自的数据和剪枝技术独立训练从融合中心获得的模型，在训练完成后对模型进行量化，将量化后的模型参数发送给融合中心；其次，融合中心对量化后的模型参数进行反量化，并进一步基于所设计的融合准则将所有认知卫星发送的模型参数进行融合；最后，融合中心将融合后的模型参数发送给各认知卫星。不断重复该训练过程，直至融合中心模型收敛。

认知卫星 n 在训练任务 j 时所采用的损失函数为

$$f(w_{n,k_r}^j) = -\frac{1}{D_n^j} \sum_{i=1}^{D_n^j} \sum_{m=1}^{M_j} y_{im}^j \log(p_{im}^j) \quad (26)$$

其中， M_j 为任务 j 的分类类别数； y_{im}^j 为符号函数，如果任务 j 的样本 i 对应的真实类别等于 m ， $y_{im}^j = 1$ ，否则 $y_{im}^j = 0$ ； p_{im}^j 为将任务 j 的样本 i 对应的类别预测为类别 m 概率； w_{n,k_r}^j 为认知卫星 n 中任

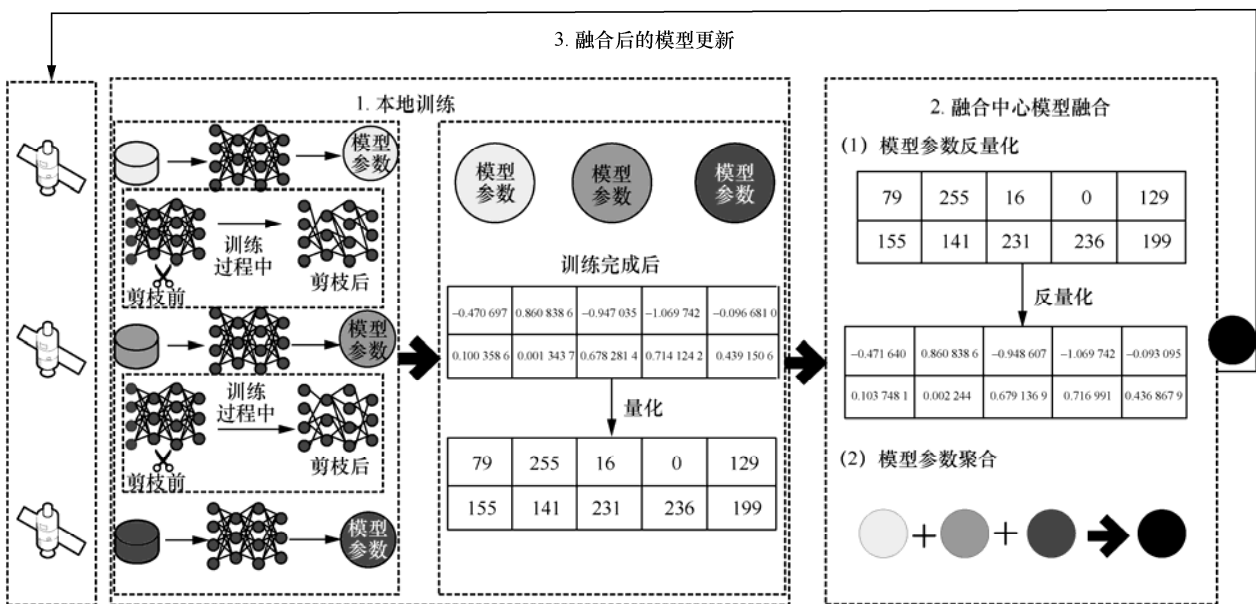


图 7 基于联邦学习的模型参数融合框架

务 j 在第 k_τ 轮本地迭代时的模型参数； $1 \leq j \leq J$ ； $n \in S$ 。

同时，各认知卫星的训练目标是损失值最小。对认知卫星 n 中任务 j 而言，其训练目标优化函数为

$$\min f(w_{n,k_\tau}^j) \quad (27)$$

利用上述优化函数，各认知卫星可完成本地训练，且在本地训练完成后将模型参数发送到融合中心，融合中心基于融合准则进一步融合各认知卫星的模型参数。考虑广泛使用的联邦平均（FedAvg, federated averaging）准则^[21]仅将不同认知卫星节点的模型参数进行简单的求和取平均，未考虑其他因素，如各认知卫星的频谱认知任务的样本数据量和激励值等因素。综合考虑这些因素，改进的结合激励值的融合准则 FedAvg-Rw（federated averaging with reward）可描述如下

$$W_j^{\tau+1} = \frac{1}{\sum_{n \in S} D_n^j R_{\theta_n}} \sum_{n \in S} D_n^j R_{\theta_n} w_{n,\tau}^j \quad (28)$$

其中， R_{θ_n} 为融合中心认知卫星 n 激励值， $w_{n,\tau}^j$ 为认知卫星 n 在第 τ 次全局迭代时上传给融合中心的任务 j 对应的模型参数， $W_j^{\tau+1}$ 为第 τ 次迭代经融合中心融合后的任务 j 对应的模型参数。

与认知卫星处的训练目标类似，融合中心的训练优化目标为

$$\min f(W_j^{\tau+1}) \quad (29)$$

当融合中心模型迭代至收敛后，融合中心会将训练好的模型参数发送给各认知卫星，具体训练过程如算法 2 所示。

算法 2 融合 Stackelberg 和联邦学习的模型训练算法

输入 可用认知卫星数集合 S_{sat} ，各认知卫星上不同的频谱认知任务的数据集 $\left\{ (X_1^j, Y_1^j), \dots, (X_{|S_{\text{sat}}|}^j, Y_{|S_{\text{sat}}|}^j) \right\}$ ，频谱认知任务的数量 J ，全局神经网络模型 W ，全局模型训练所允许的最大迭代次数 $N_{g,\tau}$ ，认知卫星节点处理器最大可用的频率 $f_{n,\max}$ ，各任务全局模型训练停止性能指标阈值 I_j ， $1 \leq j \leq J$

输出 优化后各任务对应的网络参数 W_j^*

初始化 初始化融合中心中各任务的模型参数 W_j^0 和模型性能参数 $\theta_{g,0}^j$ ，将全局模型训练迭代系

数 τ 和任务对应模型训练完成标志 F_j 设置为 0， $1 \leq j \leq J$ 。

- 1) 针对 F_j 为 0 的所有任务，基于 $\theta_{g,\tau}^j$ 、 S_{sat} 、 J 和 $f_{n,\max}$ ，调用算法 1，获得 S 、 f^* 和 θ^* ；
- 2) 融合中心下发模型参数 W_j^τ 、 f^* 和 θ^* 给集合 S 中的各认知卫星；
- 3) 循环
- 4) 集合 S 中的各认知卫星开始本地模型训练，当模型性能达到 θ_n^j 或达到本地训练的最大迭代次数时停止训练，并将量化后的模型参数发送给融合中心， $1 \leq j \leq J$ ， $n \in S$ ；
- 5) 融合中心利用式(28)进行模型参数融合，获得融合后各任务对应的模型参数 W_j ；
- 6) 融合中心分别利用融合后各任务对应的模型参数检验该模型的正确率，获得 $\theta_{g,\tau}^j$ ， $1 \leq j \leq J$ ；
- 7) if $\theta_{g,\tau}^j \geq I_j$ 或 $\tau \geq N_{g,\tau}$
- 8) 判断 τ 是否大于或等于 $N_{g,\tau}$ ，如果是，将 F_j 为 0 的任务对应的模型参数发送给各认知卫星， $W_j^* = W_j$ ，退出循环；否则， $W_j^* = W_j$ ， $F_j = 1$ ， $n \in S$ ，停止该任务的模型训练，并将该任务的模型参数发送给各认知卫星，进而判断是否满足 $\theta_{g,\tau}^j \geq I_j$ ，即 $\forall F_j = 1$ ， $1 \leq j \leq J$ ，如满足，退出循环，否则， $\tau = \tau + 1$ ，并返回步骤 4)；
- 9) else
- 10) $\tau = \tau + 1$ ，并返回步骤 4)
- 11) end if

训练完成后，各认知卫星可基于融合后的模型进行频谱认知任务的在线测试，即各认知卫星可基于所接收的频谱数据执行频谱认知任务，并将模型未分类的输出结果 C_n^j 发送给融合中心， $1 \leq j \leq J$ ， $n \in S$ ，由其融合后再进行分类判决。具体融合过程可表示为

$$C_{n,\text{fusion}}^j = \sum_{n \in S} \frac{R_{\theta_n}}{\sum_{n \in S} R_{\theta_n}} C_n^j \quad (30)$$

融合 Stackelberg 和联邦学习的模型训练算法的流程如图 8 所示。

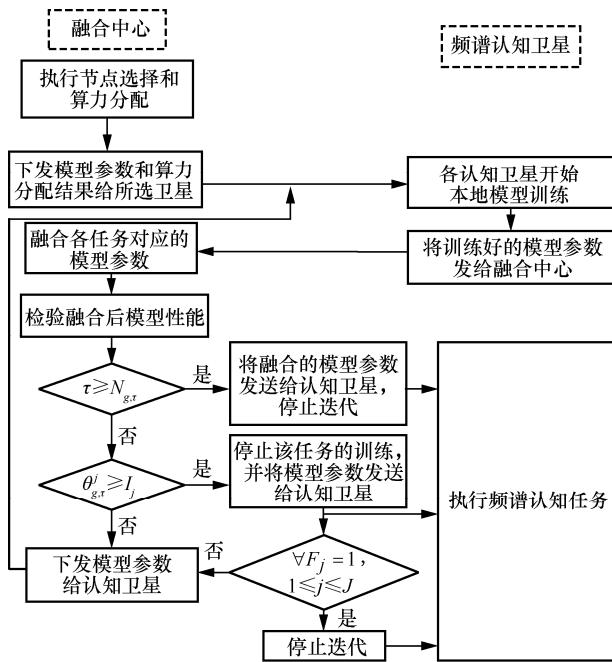


图 8 融合 Stackelberg 和联邦学习的模型训练算法的流程

4 仿真评估

本节首先介绍所采用的数据集；其次，评估了基于 Stackelberg 博弈的资源分配算法的收敛性，给出了所设计的 ShuffleNetV2-RCPQ 模型在 FedAvg-Rw 和传统 FedAvg 融合准则下的训练性能，分别测试了 3 种频谱认知任务的正确率，并分析了模型复杂度；最后，搭建了基于 Kubeedge^[22]、三台工控板和一台笔记本电脑的边缘计算平台，并将设计的模型部署在该平台进行实物测试验证，其中工控板配置为 Intel Atom x5-Z8350 4 核处理器，无 GPU，主频为 1.44 GHz，笔记本配置是 AMD Ryzen 7 4800H，主频为 2.9 GHz，GPU 为 RTX2060，内存为 64 GB，神经网络建立在 PyTorch 框架上。此外，给定区域可用认知卫星和传输时延分析都是基于如下卫星星座，该星座参数如下：星座轨道数为 72 条，每条轨道均匀分布 22 颗卫星，轨道倾角为 53°，轨道高度为 550 km、每颗卫星拥有 4 条卫星链路，星间链路采用最短路径路由策略。给定区域的经纬度信息为 (23.5°N ~ 23.75°N, 119.47°E ~ 119.7°E)，融合中心的经纬度信息为 (32°N, 119°E)。

需要指出的是，仿真评估具有合理性和有效

性，具体介绍如下。在验证所选区域内，同时可见的卫星数量可达 10 颗以上，这为多星间协作创造了条件；使用的频谱数据都是基于实际设备进行采集的，所采集的信噪比范围较宽，且在所采集的数据中添加了时延和频差，模拟了低轨卫星的动态性影响，通过该数据进行模型训练，可有效提升模型的泛化能力；验证时详细评估了所提策略在完成频谱认知时的性能，性能评估结果证明了所提策略的有效性；评估了模型的参数数量和所需的浮点运算量的降低情况，并给出了完成每种频谱认知任务的耗时分析，证明了所提策略可降低所需消耗的计算资源；在全虚拟仿真的基础上，进行了半实物原型实测，实测结果与仿真结果吻合度较高。

4.1 频谱数据采集

频谱数据是利用如图 9 所示的设备进行采集的，在接收到的卫星信号中，利用合路器添加了信号源所发送的信号，测量频率范围为 2 170 ~ 2 200 MHz，带宽为 30 MHz。考虑当前难以获得实际的低轨卫星频谱数据，本文将采集到的数据进行了随机打乱，并划分成多份，以模拟多颗低轨卫星的频谱数据。

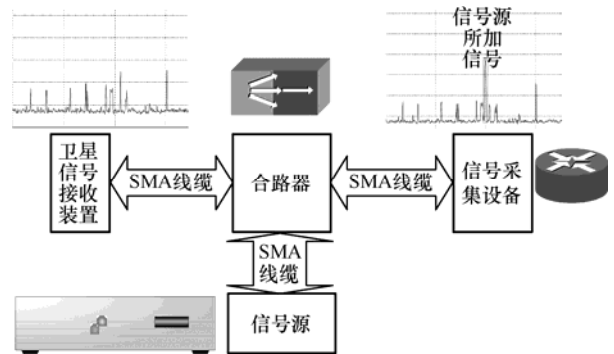


图 9 数据采集设备

4.2 仿真结果

存在 3 个频谱认知卫星（客户端）和 3 个频谱认知任务时，计算资源利用率 $\frac{f_{n,j}}{f_{n,max}}$ 与迭代次数 τ 的关系如图 10 所示，其中， $1 \leq j \leq 3$ ， $1 \leq n \leq 3$ ，客户端 1~客户端 3 中 3 种任务的数据集样本总量分别为 1 000 条、1 400 条和 2 000 条，且客户端 3 中 3 种任务的数据量分别是 1 000 条、600 条和 400 条。从图 10 可以看出，计算资源利用率很快就趋于收敛，这也论证了算

法 1 的收敛性。需要说明的是, 考虑到能耗, 每个客户端中的算力都没有全部用满, 即 3 种任务所分配的算力总和小于最大可用算力。




图 10 计算资源利用率与迭代次数的关系

3 个客户端的激励值与迭代次数的关系如图 11 所示。从图 11 可以看出, 3 个客户端的激励值较快收敛, 表明 3 个客户端通过较少的迭代次数就能满足全局融合所需的性能。需要说明的是, 激励值与客户端提供的资源呈正相关, 且规定所有客户端激励值总和为 1。因此, 当给客户端 2 和客户端 3 的激励值上升时, 给客户端 1 的激励值就会相应下降。




图 11 激励值与迭代次数的关系

模型训练阶段利用 FedAvg-Rw 和 FedAvg 融合准则下, 模型损失值与迭代次数 τ 的关系如图 12

所示。从图 12 可以看出, 随着迭代次数的增加, 模型损失值将趋于收敛, 且基于所设计的 FedAvg-Rw 准则可更快收敛。图 12 还表明, 相比于传统的 FedAvg 融合准则, 所设计的 FedAvg-Rw 准则可取得较低损失值(单项任务对应的模型损失值或 3 种任务对应的模型平均损失值)。

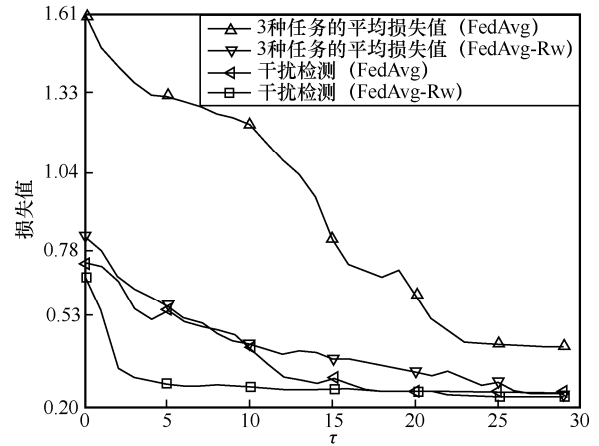


图 12 模型损失值与迭代次数的关系

模型训练阶段利用 FedAvg-Rw 和 FedAvg 融合准则时, 模型正确率与迭代次数 τ 的关系如图 13 所示。图 13 表明, 无论是单项任务对应的模型正确率还是 3 种任务对应的模型平均正确率, 所设计的 FedAvg-Rw 都可比传统的 FedAvg 准则取得一定的性能优势。从图 13 还可以看出, 相比于 FedAvg 准则, 基于 FedAvg-Rw 准则的模型正确率可更快收敛。综合图 12 和图 13, 所设计的 FedAvg-Rw 准则在模型损失值、模型正确率和模型收敛速度方面都具有一定的优势。




图 13 模型正确率与迭代次数的关系

干扰检测任务（图 13 中的干扰检测（FedAvg））中，ShuffleNetV2 模型在不同剪枝率下的性能对比如表 2 所示。由表 2 可以看出，基于所利用的剪枝准则，随着剪枝率的增加，ShuffleNetV2 模型性能也会相应下降。基于表 2 和任务正确率指标，可确定需设置的剪枝率。需要指出的是，在实际剪枝过程中，考虑通道数较少的层中参数数量不大，本文没有对其进行剪枝，评估时只对通道数大于 48 的层进行了剪枝。

表 2 干扰检测任务中，ShuffleNetV2 模型在不同剪枝率下的性能对比

剪枝率	正确率
0	81.14%
5%	81.09%
10%	80.95%
19%	73.15%
22%	72.51%
25%	70.61%
30%	66.97%

图 14 展示了所设计的 ShuffleNetV2-RCPQ 模型、传统 ShuffleNetV2 模型和能量检测方法在不同信噪比下，频谱感知任务的正确检测概率 P_d ，其中虚警概率为 0.01，能量检测的样本数量为 1 024。从图 14 可以看出，ShuffleNetV2-RCPQ 模型和 ShuffleNetV2 模型可取得比能量检测方法更好的正确检测概率，且 ShuffleNetV2-RCPQ 模型的性能与传统 ShuffleNetV2 模型的性能相当。此外，增加协作认知卫星数量，频谱感知任务的正确检测概率也相应提升。

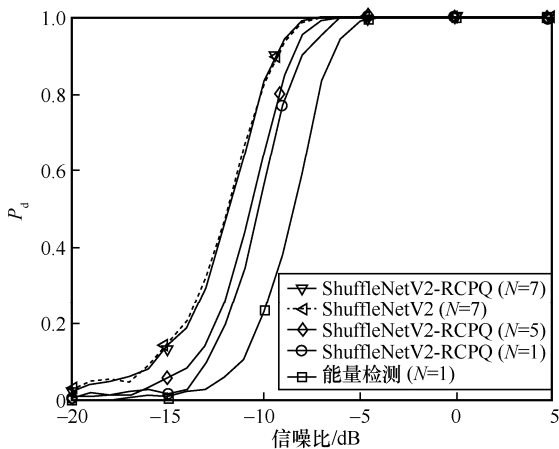


图 14 在不同信噪比下，频谱感知任务的正确检测概率

所设计的 ShuffleNetV2-RCPQ 模型和传统 ShuffleNetV2 模型在完成干扰检测任务时的正确率如图 15 所示。图 15 表明，ShuffleNetV2-RCPQ 模型可取得与传统 ShuffleNetV2 模型相似的干扰检测正确率，且正确率还会随着协作卫星数量的增加而提高。

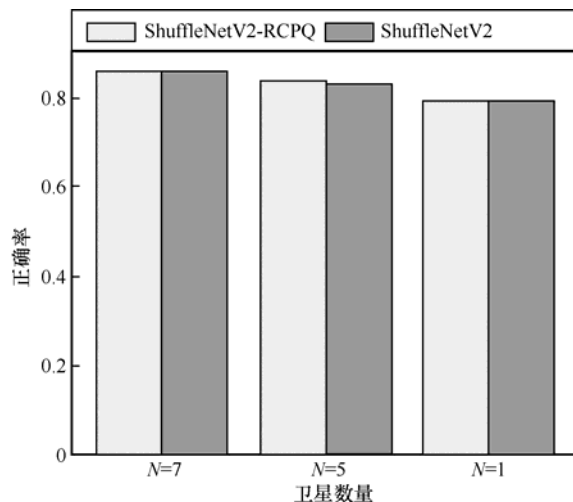


图 15 不同模型完成干扰检测任务时的正确率

在不同信噪比下，所设计的 ShuffleNetV2-RCPQ 模型和传统 ShuffleNetV2 模型在完成调制模式识别任务时的正确率如图 16 所示。从图 16 可以看出，在 BPSK、QPSK、8PSK 和 16QAM 调制模式中，所设计的 ShuffleNetV2-RCPQ 模型的识别正确率都随着信噪比的增加而相应增大，且能维持与传统 ShuffleNetV2 模型相当的正确率。




图 16 不同模型完成调制模式识别任务时的正确率

频谱感知任务中，ShuffleNetV2-RCPQ 模型在不同协作卫星数量时的正确率和能效如表 3 所示。对于

给定任务 j ，其能效的计算式为能效 = $\frac{\text{正确率}}{\text{总能效} E_n^j}$ 。

由表 3 可以看出，尽管本文所提策略可通过节点间协作来提升频谱感知性能，但能效会随着协作节点数量的增加而降低。这主要是由于协作节点数量增加到一定程度后，所能获得的性能增益的增幅明显降低，但总能耗却会显著提升，从而导致能效的降低。对于所评估的频谱感知任务，综合考虑正确率和能效，当协作节点数量达到 $N = 5$ 时，将不需要再增加协作节点数量。

表 3 ShuffleNetV2-RCPQ 模型在不同协作卫星数量时的正确率和能效

卫星数量	正确率	能效
1	83.44%	0.73%
3	85.26%	0.25%
5	91.47%	0.16%
7	91.86%	0.09%

ShuffleNetV2-RCPQ 模型与 ShuffleNetV2 模型的参数量和 FLOPs 如表 4 所示。从表 4 可以看出，相比于传统的 ShuffleNetV2 模型，ShuffleNetV2-RCPQ 模型的参数量和所需的 FLOPs 都显著降低，其中参数量和 FLOPs 分别降低了 96.69% 和 93.32%，这极大降低了模型的复杂度。结合图 13~图 15 来看，与传统 ShuffleNet 相比，所设计的 ShuffleNetV2-RCPQ 模型不仅复杂度低，且并没有牺牲 3 种频谱认知任务的性能，这证明了所设计模型的优势和实用性。

表 4 ShuffleNetV2-RCPQ 模型与 ShuffleNetV2 模型的参数量和 FLOPs

模型	参数量	FLOPs
ShuffleNetV2	1 256 679	151 687 864
ShuffleNetV2-RCPQ	41 499	10 135 344

本节在所提 Stackelberg 博弈的算力分配算法和传统平均算力分配算法下，基于相同处理器主频，对比了 ShuffleNetV2-RCPQ 模型与 ShuffleNetV2 模型在完成 3 种频谱认知任务的时间，结果如表 5 所示。从表 5 可以看出，基于所提 Stackelberg 博弈的算力分配算法，ShuffleNetV2-RCPQ 模型的时间明显低于 ShuffleNetV2 模型的时间。此外，针对 ShuffleNetV2-

RCPQ 模型，相比于传统的平均算力分配算法，所提基于 Stackelberg 博弈的算力分配算法依然可降低 ShuffleNetV2-RCPQ 模型在完成 3 种频谱认知任务的总时间。表 5 中仅给出了客户端 3 完成任务的时间分析，其他客户端的时间相类似。

表 5 不同模型完成 3 种频谱认知任务的时间对比

模型	频谱感知时间/s	干扰检测时间/s	调制模式时间/s	总时间/s
ShuffleNetV2 (结合基于 Stackelberg 的博弈的分配算法)	27.228 8	43.374 6	62.167	132.770 4
ShuffleNetV2-RCPQ (结合基于 Stackelberg 的博弈的分配算法)	11.194	17.760 6	28.990	57.944 6
ShuffleNetV2-RCPQ (平均分配)	10.872	17.152 2	32.742	60.766 2

4.3 基于边缘计算平台的测试验证

为进一步验证所设计的频谱认知技术在实际平台上的运行情况，本节基于 Kubernetes 和 Kubeedge^[22] 搭建了边缘计算平台。如图 17 所示，Kubernetes 部署在一台笔记本电脑上，Kubeedge 部署在三台工控板上，其中，笔记本代表融合中心，工控板代表频谱认知卫星。三台工控板与笔记本电脑间通过无线进行数据交互，可支持联邦学习架构的运行。融合中心（笔记本电脑）可通过网络将任务配置到各认知卫星（工控板）中，还可通过 yaml 文件将优化求得的各认知卫星中不同频谱认知任务的算力分配结果配置给各认知卫星。从图 17 可以看出，3 种频谱认知任务可在认知卫星和融合中心稳定运行，初步证明了实际运行的可行性。

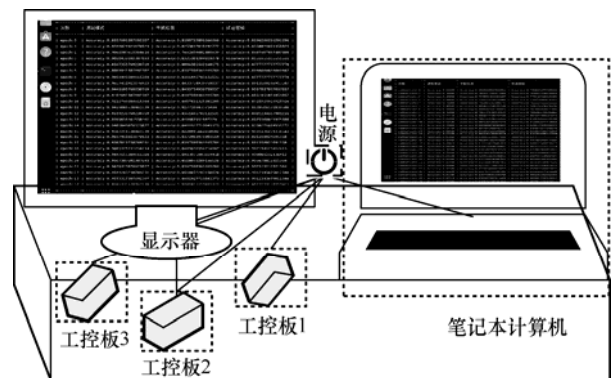


图 17 所设计的协作频谱认知技术在所构建的边缘计算平台上测试验证

表 6 进一步将边缘计算平台的测试与仿真结果进行了对比。由表 6 可以看出，2 种评估方式可取

得相当的性能，这也说明半实物原型实测结果的有效性。

表 6 边缘计算平台的测试与仿真结果对比

评估方式	频谱感知性能 (P_d)	干扰检测性能 (正确率)	调制模式性能 (正确率)
测试	90.63%	83.69%	85.51%
仿真	90.85%	84.81%	86.60%

5 结束语

针对单星频谱认知性能低、星上算力和峰值功率受限等特性，本文提出了融合 Stackelberg 博弈和联邦学习的多星协作频谱认知方法，包括基于 Stackelberg 博弈的协作节点选择与资源分配算法、基于联邦学习的多星协作频谱认知策略。仿真实验结果表明，所提多星协作频谱认知方法能显著提升频谱认知性能，且所设计模型的数量和模型所需的 FLOPs 均明显低于传统的 ShuffleNetV2 模型。

参考文献：

[1] YIN L, YANG R N, YANG Y Z, et al. Beam pointing optimization based downlink interference mitigation technique between NGSO satellite systems[J]. IEEE Wireless Communications Letters, 2021, 10(11): 2388-2392.

[2] CHEN Q, GIAMBENE G, YANG L, et al. Analysis of inter-satellite link paths for LEO mega-constellation networks[J]. IEEE Transactions on Vehicular Technology, 2021, 70(3): 2743-2755.

[3] KASSING S, BHATTACHERJEE D, ÁGUAS A B, et al. Exploring the “Internet from space” with Hypatia[C]//Proceedings of the ACM Internet Measurement Conference. New York: ACM Press, 2020: 1-16.

[4] SU Y T, LIU Y Q, ZHOU Y Q, et al. Broadband LEO satellite communications: architectures and key technologies[J]. IEEE Wireless Communications, 2019, 26(2): 55-61.

[5] CLARK B, GUNZINGER M. Winning the airwaves: regaining America’s dominance in the electromagnetic spectrum[R]. 2015.

[6] ZHANG C, JIANG C X, JIN J, et al. Spectrum sensing and recognition in satellite systems[J]. IEEE Transactions on Vehicular Technology, 2019, 68(3): 2502-2516.

[7] DING X J, NI T, ZOU Y L, et al. Deep learning for satellites based spectrum sensing systems: a low computational complexity perspective[J]. IEEE Transactions on Vehicular Technology, 2023, 72(1): 1366-1371.

[8] 王嘉煜, 陈思宏, 张睿丹. 浅析一种基于 DTP 的卫星载波监视流程及方法[J]. 中国设备工程, 2022(12): 3-6.

WANG J Y, CHEN S H, ZHANG Q D. Analysis of a satellite carrier monitoring process and method based on DTP[J]. China Plant Engineering, 2022(12): 3-6.

[9] JIA M, LIU X, YIN Z S, et al. Joint cooperative spectrum sensing and spectrum opportunity for satellite cluster communication networks[J]. Ad Hoc Networks, 2017, 58: 231-238.

[10] WANG Y F, DING X J, HONG T, et al. Distributed-satellite-clusters-based spectrum sensing with two-stage phase alignment[J]. Sensors, 2022, 22(11): 3983.

[11] 黄旭民, 张昉, 余荣, 等. 基于 Stackelberg 博弈的无人机辅助无线供能物联网能量优化[J]. 通信学报, 2022, 43(12): 146-156.

HUANG X M, ZHANG Y, YU R, et al. Stackelberg game based energy optimization for unmanned aerial vehicle assisted wireless-powered Internet of things[J]. Journal on Communications, 2022, 43(12): 146-156.

[12] CHEN Z B, XU Y Q, WANG H B, et al. Federated learning-based cooperative spectrum sensing in cognitive radio[J]. IEEE Communications Letters, 2022, 26(2): 330-334.

[13] SUN W, LIAN S, ZHANG H, et al. Lightweight digital twin and federated learning with distributed incentive in air-ground 6G networks[J]. IEEE Transactions on Network Science and Engineering, 2023, 10(3): 1214-1227.

[14] YANG Z H, CHEN M Z, SAAD W, et al. Energy efficient federated learning over wireless communication networks[J]. IEEE Transactions on Wireless Communications, 2021, 20(3): 1935-1949.

[15] ACHTERBERG T. SCIP: solving constraint integer programs[J]. Mathematical Programming Computation, 2009, 1(1): 1-41.

[16] CIBLAT P, GHOGHO M. Blind NLLS carrier frequency-offset estimation for QAM, PSK and PAM modulations: performance at low SNR[J]. IEEE Transactions on Communications, 2006, 54(10): 1725-1730.

[17] AN Z L, ZHANG T Q, SHEN M, et al. Series-constellation feature based blind modulation recognition for beyond 5G MIMO-OFDM systems with channel fading[J]. IEEE Transactions on Cognitive Communications and Networking, 2022, 8(2): 793-811.

[18] 任杰, 高岭, 于佳龙, 等. 面向边缘设备的高能效深度学习任务调度策略[J]. 计算机学报, 2020, 43(3): 440-452.

REN J, GAO L, YU J L, et al. Energy-efficient deep learning task scheduling strategy for edge device[J]. Chinese Journal of Computers, 2020, 43(3): 440-452.

[19] CHEN Z B, XU Y Q, WANG H B, et al. Deep STFT-CNN for spectrum sensing in cognitive radio[J]. IEEE Communications Letters,

2021, 25(3): 864-868.

- [20] 张帆, 黄赟, 方子苗, 等. 卷积神经网络的损失最小训练后参数量化方法[J]. 通信学报, 2022, 43(4): 114-122.

ZHANG F, HUANG Y, FANG Z Z, et al. Lost-minimum post-training parameter quantization method for convolutional neural network[J]. Journal on Communications, 2022, 43(4): 114-122.

- [21] LUO B, LI X, WANG S Q, et al. Cost-effective federated learning in mobile edge networks[J]. IEEE Journal on Selected Areas in Communications, 2021, 39(12): 3606-3621.

- [22] YANG T T, NING J H, LAN D P, et al. Kubeedge wireless for integrated communication and computing services everywhere[J]. IEEE Wireless Communications, 2022, 29(2): 140-145.

[作者简介]



丁晓进 (1981-), 男, 江苏兴化人, 博士, 南京邮电大学副教授, 主要研究方向为卫星物联网、频谱智能认知等。



徐叶辉 (1999-), 男, 江苏兴化人, 南京邮电大学硕士生, 主要研究方向为卫星通信。



包文 (1999-), 女, 江苏扬州人, 南京邮电大学硕士生, 主要研究方向为卫星通信。



张更新 (1967-), 男, 浙江平湖人, 博士, 南京邮电大学教授、博士生导师, 主要研究方向为卫星通信、深空通信、空间信息网络等。