

文章编号:1007-5321(2020)06-0051-08

DOI:10.13190/j.jbupt.2020-162

IRS 辅助的边缘智能系统中基于数据重要性感知的资源分配

田 辉¹, 倪万里¹, 王 雯¹, 郑景桁¹, 贺 硕²

(1. 北京邮电大学 网络与交换技术国家重点实验室, 北京 100876; 2. 郑州大学 信息工程学院, 郑州 450001)

摘要: 针对智能反射面(IRS)辅助的边缘智能系统中模型参数汇聚的问题,提出一种基于数据重要性感知的资源分配算法. 利用凸优化和分支定界等方法交替优化用户的发射功率、传输次数和智能反射面的相移矩阵. 仿真结果表明,所提算法能够基于本地数据的重要性差异有效汇聚分布式智能体的模型参数,并最大化加权速率.

关键词: 智能反射面; 模型汇聚; 重要性感知; 资源分配

中图分类号: TN929.5

文献标志码: A

Data-Importance-Aware Resource Allocation in IRS-Aided Edge Intelligent System

TIAN Hui¹, NI Wan-li¹, WANG Wen¹, ZHENG Jing-heng¹, HE Shuo²

(1. State Key Laboratory of Networking and Switching Technology, Beijing University of Posts and Telecommunications, Beijing 100876, China;

2. School of Information Engineering, Zhengzhou University, Zhengzhou 450001, China)

Abstract: In order to solve the problem of model aggregation in intelligent reflecting surface (IRS) aided edge intelligent system, a data-importance-aware resource allocation algorithm is proposed by using convex optimization and branch-and-bound methods to alternately design the user's uplink power, transmission time, and the phase shifts of IRS. Simulation results show that the proposed algorithm can effectively aggregate the model parameters of the distributed agents based on the importance difference of local data, and can maximize the uplink weighted sum rate.

Key words: intelligent reflecting surface; model aggregation; importance aware; resource allocation

未来第 6 代移动通信系统(6G, the sixth generation of mobile communications system)的作用之一就是基于无处不在的大数据将人工智能(AI, artificial intelligence)能力赋予各类应用^[1]. 然而,精准高效的 AI 算法需要强大的算力和高质量的训练数据支撑,边缘设备有限的计算能力和用户的数据隐私安全需求在一定程度上阻碍了 AI 的发展. 边缘智能系统作为 AI 的“最后一公里”,通过将 AI 能力赋予数据源头,提高了 AI 服务在低时延、数据安全、独立

运行等方面的性能表现^[1-2],并进一步推动了 6G 网络的智能泛在化. 具体地,边缘智能系统可以①通过借助边缘计算技术,将计算任务卸载到边缘智能体,实现边缘计算能力的高效利用;②通过执行分布式学习,各边缘智能体挖掘海量数量信息,训练生成满足场景需求的模型;③通过上下文信息交互,基站(BS, base station)获取各边缘智能体的训练模型参数,感知模型对全局模型的重要性程度,并驱动全局模型的训练. 在通信过程中,BS 与各边缘用户

收稿日期: 2020-09-02

基金项目: 国家重点研发计划项目(2019YFC1511400)

作者简介: 田 辉(1963—),女,教授,博士生导师, E-mail: tianhui@bupt.edu.cn.

只交互训练模型参数,而无原始数据,这样既保障了数据的安全性,同时也实现了有限通信资源的高效利用^[3].

在边缘智能系统的背景下,未来 6G 网络将会催生出一系列全新的应用场景,如智慧医疗^[4]、智能交通^[5]等.同时移动通信的业务需求也会更多样化、严苛化,如时延、能效和通信可靠度等指标的动态范围更大,峰值指标更高.为了充分挖掘边缘智能系统的潜能,满足上述应用和业务指标的需求,设计高效的资源管理算法是需要解决的关键问题.然而,现有的资源管理算法在服务未来 6G 网络边缘智能系统时面临以下问题:首先,由于应用场景的差异性,边缘智能体需要收集、处理的数据和训练模型具有强烈的异构性,如智慧医疗中的智能疾病筛查系统,智能交通中的交通信息服务系统等.因此,6G 网络需要对多维度的网络资源进行细粒度的精确配置^[6];其次,分布式智能应用场景规模的激增要求无线通信技术以不同场景收集到的原始数据为基础进行差异化的分布式学习,并将其训练得到的模型参数在交互过程中上传给 BS,以此驱动 BS 全局模型的训练^[7].这种分布式的数据处理模式大大缓和了数据规模的压力,但考虑到不同智能体的数据对全局模型训练的重要性程度存在差异,边缘智能体的数据聚合过程需要考虑各自训练结果对汇聚全局模型的有效性.为保证全局模型训练的精度,模型汇聚过程中除了模型参数信息外,BS 同样需要借助与用户的上下文感知,作出对其模型重要性的判断.因此,需要充分考虑 6G 分布式智能系统的以上特点,解决分布式机器学习在无线通信系统中实施的可行性问题,根据本地学习模型对全局模型效果的差异化来设计相应的资源分配策略,即是学习驱动的资源分配.

目前已有学者针对上述问题展开了研究.其中,智能反射面(IRS, intelligent reflecting surface)作为一项能够重构无线传播环境的新技术受到了广泛的关注^[8-10],同时也提供了一种资源分配设计的新思路. IRS 是由众多无源反射元件构成的均匀平面阵列,每个反射单元均可巧妙地调整入射信号的振幅和相位,从而使得信号的方向和强度在接收端高度可控.该特性使得 IRS 能够辅助系统依据各边缘智能体的需求增强或抑制定向信号,形成满足差异化通信需求的细粒度的三维无源波束,从而以更高的自由度为边缘智能系统构建出智能可控的无线环

境,协同系统实现精准、高效的资源分配^[8].在 IRS 辅助的多输入多输出(MIMO, multiple-input multiple-output)系统^[11]、IRS 辅助的正交频分复用(OFDM, orthogonal frequency division multiplexing)系统^[12]、IRS 辅助的非正交多址(NOMA, non-orthogonal multiple access)系统^[13]等研究中均可看到该项技术可大幅改善系统的性能.具体地, Wu 等^[8]提出了有关 IRS 辅助的无线网络的概述,包括其在无线通信中的主要应用、相对于现有技术的竞争优势、硬件体系结构、波束成形设计、信道估计和网络部署等.而在数据汇聚的理论研究方面, Jiang 等^[9]提出通过部署 IRS 提高无线计算(AirComp, over-the-air computation)系统的性能,从而实现超高速的数据聚合. Yu 等^[14]提出在大规模云无线接入网(C-RAN, cloud radio access network)中引入 IRS 来充分发挥 AirComp 系统的优势.但这些研究并未面向 6G 边缘智能系统,且关于各边缘智能体数据的重要性差异及模型聚合不确定性的研究尚少.

考虑到无线网络中环境噪声及其不确定性将给分布式智能体的模型聚合带来干扰和误差,并且不同的数据源将对全局模型训练具有差异性贡献.因此,为应对 6G 网络中海量设备带来的数据聚合挑战,利用 IRS 可重置无线传播环境的特性,将其引入边缘智能系统,同时考虑各智能体训练模型对汇聚的有效程度,提出一种基于重要性感知的资源管理算法.首先构建了部署 IRS 的边缘智能系统通信场景,确定了用户侧模型数据的并行传输方案;之后在 BS 可借助与用户交互过程感知数据重要性的前提下,通过联合优化用户发射功率、重传次数和 IRS 的相移矩阵来最大化 BS 在单次模型汇聚中的加权和速率;最后分别选取无 IRS 和无重要性感知分配方案作为对比,验证了所提算法在提升无线通信系统数据聚合能力方面的有效性.

1 系统模型与问题建立

1.1 系统模型

图 1 所示为 IRS 辅助的边缘智能系统,包括 BS、IRS 和 K 个具备 AI 能力的地面用户(边缘智能体).假设所有地面用户和 BS 都配备有单天线, IRS 具有 M 个低成本的被动反射单元.各边缘智能体执行分布式学习,以收集到的数据为基础完成模型训练后,将模型参数上传给 BS,同时 BS 在模型汇聚过程中借助与智能体的交互感知其数据的重要程

知获得 α_k , 对于不同的聚合间隔, 重要性权重可根据上下文信息来改变. 由于笔者着眼于单次模型汇聚中的资源分配问题, 所以 α_k 为常数. 目标是在用户功率约束 P_{\max} 、传输预算约束 N 以及 Θ 的单位模值约束下, 通过联合优化用户的发射功率、相移矩阵和重传次数来最大化 BS 在单次模型汇聚中的加权和速率. 因此, 该优化问题构建为

$$\max_{p_k, n_k, \Theta_k} \sum_{k=1}^K \alpha_k n_k R_k \quad (8a)$$

$$\text{s. t. } \varepsilon_k \leq \varepsilon_{\max}, \forall k \quad (8b)$$

$$0 \leq p_k \leq P_{\max}, \forall k \quad (8c)$$

$$\sum_{k=1}^K n_k = N \quad (8d)$$

$$\phi_m \in [0, 2\pi], \forall m \quad (8e)$$

$$n_k \in \{1, 2, \dots, N\}, \forall k \quad (8f)$$

其中条件约束式(8b)和式(8c)分别表示传输的可靠性要求和功率限制. 式(8d)表示所有用户均满足传输预算限制. 由于连续变量 p_k 和整数变量 n_k 共存, 且在目标函数和约束式(8b)中紧密耦合, 所以加权和速率最大化问题[式(8a)]是一个混合整数非线性规划(MINLP, mixed integer nonlinear programming)问题. 这类问题的复杂度是 NP 难的, 并且缺乏获得其全局最优解的标准方法.

此外, 观察到目标函数式(8a)中的优化变量 p_k, Θ_k 均位于对数函数的真数部分, 直接求解会带来复杂的导数形式. 为易于求解, 将原问题转化为以目标函数为多项式形式的等效加权和均方误差(WMSE, weighted mean square error)问题^[17]. 与等效加权和最大化问题相似, WMSE 最大化问题也是一种常见的效用最大化问题. WMSE 可以评价数据的变化程度, 其值越小, 说明预测模型的结果与实验数据的差异越小. 因此, 将式(8a)~(8f)等效为 WMSE 问题不仅可以简化求解过程, 同时通过最小化 WMSE, 可以有效降低各分布式模型传递的信息误差, 进而保证 BS 处全局模型训练的精确度. 但由于问题的等效并未消除变量之间的耦合关系, 故可进一步使用基于交替优化^[15](AO, alternating optimization)的资源分配算法次优地解决 WMSE 问题.

2 算法设计

将噪声视为干扰, 并考虑线性接收波束成形策略, 从而表示出预估信号^[18]:

$$\hat{s}_k = u_k^* y_k \quad (9)$$

其中 u_k 为用户 k 的解码因子. 随后, 推导出用户 k 的最小 MSE 为

$$E_k = E(|\hat{s}_k - s_k|^2) = u_k^* (h_k p_k h_k^* + \sigma^2) u_k - u_k^* h_k \sqrt{p_k} - u_k h_k^* \sqrt{p_k} + 1 \quad (10)$$

其中 $h_k = \mathbf{h}_{\text{ra}} \Theta_k \mathbf{h}_{\text{kr}} + h_{\text{ka}}$. 进一步, 通过引入变量 q_k , 将加权和速率最大化问题转化为^[18]

$$\max_{u_k, q_k > 0, p_k, n_k, \Theta_k} \sum_{k=1}^K \alpha_k n_k [\text{lb}(q_k) - q_k E_k + 1] \quad (11a)$$

$$\text{s. t. } (8b), (8c), (8d), (8e), (8f) \quad (11b)$$

转化后的式(11a)能够借助 AO 算法有效解决问题, 具体方法是在固定其他变量的条件下迭代优化某个变量, 直至算法收敛, 下面给出详细过程.

2.1 辅助变量的优化

首先, 当固定其他变量时, 解码因子 u_k 的优化子问题为

$$\max_{u_k} \sum_{k=1}^K \alpha_k n_k [\text{lb}(q_k) - q_k E_k + 1] \quad (12)$$

将 E_k 代入式(12)中, 同时为了简便, 删除常数项, 该问题可以转化为

$$\min_{u_k} \sum_{k=1}^K \alpha_k n_k q_k g_k \quad (13)$$

其中

$$g_k = u_k^* (h_k p_k h_k^* + \sigma^2) u_k - u_k^* h_k \sqrt{p_k} - u_k h_k^* \sqrt{p_k}$$

可以证明, 式(13)是关于 u_k 的凸问题, 因此可得到 u_k 的最优解为

$$u_k^{\text{opt}} = \frac{h_k \sqrt{p_k}}{p_k |h_k|^2 + \sigma^2} \quad (14)$$

其次, 当给定其他变量时, q_k 的优化子问题可表示为

$$\max_{q_k > 0} \sum_{k=1}^K \alpha_k n_k [\text{lb}(q_k) - q_k E_k + 1] \quad (15)$$

显然, 式(15)是关于 q_k 的凸问题, 因此可得 q_k 的最优解:

$$q_k^{\text{opt}} = E_k^{-1} \quad (16)$$

此外, 将求得的辅助变量的最优解代入转化后的目标函数式(11a), 可推导得到

$$\text{lb}(q_k) - q_k E_k + 1 = \text{lb}(E_k^{-1}) = \text{lb}\left(1 + \frac{|h_k|^2 p_k}{\sigma^2}\right) = R_k$$

即证得转化后的式(11)与式(8)等价.

2.2 用户发射功率的优化

固定其他优化变量并忽略式(11a)中的常数项, 将用户发射功率 p_k 的优化子问题表述为

$$\begin{aligned}
\max_{p_k} \sum_{k=1}^K & -\alpha_k n_k q_k (|u_k h_k|^2 p_k + |u_k|^2 \sigma^2) + \\
& \sum_{k=1}^K \alpha_k n_k q_k u_k^* h_k \sqrt{p_k} + \\
& \sum_{k=1}^K \alpha_k n_k q_k u_k h_k^* \sqrt{p_k} - \sum_{k=1}^K \alpha_k n_k q_k \quad (17a) \\
\text{s. t. } & (8b), (8c) \quad (17b)
\end{aligned}$$

依据 1.2 节所述的 3 种情况分别考虑上述优化问题。

仅考虑用户-BS 链路时, ε_k^i 通过式(5)计算. 定义 $D_k = (\varepsilon_{\max})^{\frac{1}{n_k}}$ 以简化表达, 同时将约束条件 $\delta_k/2 - p_k \leq 0, \forall k$ 添加至优化问题[式(17a)], 以保证其凸性, 其中 $\delta_k = (2^{\bar{R}_k} - 1)\sigma^2$. 优化问题转化为

$$\begin{aligned}
\min_{p_k} \sum_{k=1}^K & \alpha_k n_k q_k (|u_k h_k|^2 p_k + |u_k|^2 \sigma^2) - \\
& \sum_{k=1}^K \alpha_k n_k q_k u_k^* h_k \sqrt{p_k} - \\
& \sum_{k=1}^K \alpha_k n_k q_k u_k h_k^* \sqrt{p_k} + \sum_{k=1}^K \alpha_k n_k q_k \quad (18a) \\
\text{s. t. } & \varepsilon_k^i - D_k \leq 0, \forall k \quad (18b) \\
& p_k - p_{\max} \leq 0, \forall k \quad (18c) \\
& \delta_k/2 - p_k \leq 0, \forall k \quad (18d)
\end{aligned}$$

式(18a)及其约束条件均是关于 p_k 的凸函数, 可结合对数障碍法和牛顿法来解决该问题. 利用对数障碍函数为式(18a)设置障碍^[19], 其表达式为 $I(x) = -1/v \ln(-x)$, 其中 v 为正实数. 将约束条件作为自变量代入 $I(x)$ 并与式(18a)相加, 该问题进一步转化为如下无约束凸优化问题:

$$\begin{aligned}
\min_{p_k} \sum_{k=1}^K & \alpha_k n_k q_k (|u_k h_k|^2 p_k + |u_k|^2 \sigma^2) - \\
& \sum_{k=1}^K \alpha_k n_k q_k u_k^* h_k \sqrt{p_k} - \\
& \sum_{k=1}^K \alpha_k n_k q_k u_k h_k^* \sqrt{p_k} + \sum_{k=1}^K \alpha_k n_k q_k + \sum_{k=1}^K I(\varepsilon_k^i - D_k) + \\
& \sum_{k=1}^K I(p_k - p_{\max}) + \sum_{k=1}^K I(\delta_k/2 - p_k) \quad (19)
\end{aligned}$$

使用基于牛顿法的对数障碍方法^[19]求解无约束凸优化问题[式(19)]. 该算法在给定式(19)可行域内任意起始点及相应的参数条件下, 经过多次迭代得到满足精度要求的次优解.

算法参数如下: v 为 m/ξ , 其中 m 为式(18a)约束条件的数目, ξ 为对数障碍方法精度; η 为牛顿法精度要求; $\mathbf{P} = [p_k^*], k \in \{1, 2, \dots, K\}$ 表示发送功率的解向量; 令 F 表示式(19)的目标函数, 则 ∇F 表示

F 的梯度, $\nabla^2 F$ 表示 F 的 Hessian 矩阵. 算法的步骤如下.

1) 初始分配. 在式(19)可行域内随机分配一个解向量的起始点.

2) 下降过程. 计算起始点下降方向的 $\Delta \mathbf{P} = -\nabla^2 F^{-1} \nabla F$ 以及 $\lambda^2 = \nabla F^T \nabla^2 F^{-1} \nabla F$, 通过回溯直线搜索确定下降步长 t , 更新 $\mathbf{P}_i = \mathbf{P} + t \Delta \mathbf{P}$.

3) 重复步骤 2) 直到 $\lambda^2/2 \leq \eta$, 输出优化结果 \mathbf{P} .

1.2 节中其他 2 种情况的优化问题形式与式(17a)类似, 不同之处在于当仅考虑用户-IRS 和 IRS-BS 链路时, ε_k^i 通过式(6)定义; 当用户-IRS 和 IRS-BS 链路叠加在用户-BS 链路上时, ε_k^i 通过式(7)定义且用户-BS 链路信道增益视为常数. 为确保约束式(18b)是 p_k 的凸函数, 2 种情况下的约束式(18d)都替换为 $\delta_k - p_k \leq 0, \forall k$. 2 种情况下的优化问题类似, 可使用上述基于牛顿法的对数障碍方法求解, 这里将其省略.

2.3 用户重传次数的优化

在其他变量固定的条件下优化用户 k 的重传次数 n_k , 定义参量 $C_k = \alpha_k (\ln q_k - q_k E_k + 1)$ 和 $G_k = \ln \varepsilon_{\max} / \ln \varepsilon_k^i$. 优化问题表述如下:

$$\max_{n_k} \sum_{k=1}^K C_k n_k \quad (20a)$$

$$\text{s. t. } G_k - n_k \leq 0, \forall k \quad (20b)$$

$$(8d), (8f) \quad (20c)$$

该问题是纯整数线性规划问题, 可通过分支定界法和单纯形法解决. 为了与单纯形法的标准形式匹配, 应将优化变量从整数变量松弛化为连续变量. 具体地, 将约束式(8f)松弛化为 $0 \leq n_k \leq N$. 同时引入辅助变量 φ_k 和 ψ_k , 以标准化松弛优化问题的形式:

$$\max_{n_k} \sum_{k=1}^K C_k n_k \quad (21a)$$

$$\text{s. t. } G_k - n_k + \varphi_k = 0, \forall k \in \{1, 2, \dots, K\} \quad (21b)$$

$$n_k + \psi_k = N, \forall k \in \{1, 2, \dots, K\} \quad (21c)$$

$$n_k, \varphi_k, \psi_k \geq 0, \forall k \in \{1, 2, \dots, K\} \quad (21d)$$

$$(8d) \quad (21e)$$

其中 $k \in \{1, 2, \dots, K\}$.

为方便表述, 使用 $\mathbf{n} = [n_k^*], k \in \{1, 2, \dots, K\}$ 表示解向量. 式(21a)可通过基于单纯形法的分支定界法^[20]求解. 该算法在分支节点利用单纯形法求解松弛化问题(21)的最优解, 并通过比较结果对其进行定界和剪支, 逐步使得所有优化变量均为整数,

从而得到最优解.

算法的具体步骤如下.

1) 初始分配. 利用单纯形法直接求解式(21a), 获取初始解 \mathbf{n} 与初始目标函数值 Z^* , 令 $k=1$.

2) 如果 \mathbf{n} 的每一维分量均为整数, 则执行步骤 5); 否则执行步骤 3).

3) 分支定界. 将约束条件 $n_k \leq \lfloor n_k^* \rfloor$ 和 $n_k \geq \lfloor n_k^* \rfloor + 1$ 分别添加至式(21a), 得到 2 个分支问题. 利用单纯形法分别求解 2 个问题, 得到解 \mathbf{n}_1 和 \mathbf{n}_2 以及目标函数值 Z_1^*, Z_2^* . 如果 $Z_1^* \geq Z_2^*$ 或者 \mathbf{n}_2 不可行, 则将约束条件 $n_k \leq \lfloor n_k^* \rfloor$ 添加至式(21a)并用 \mathbf{n}_1 更新 \mathbf{n} ; 如果 $Z_1^* \leq Z_2^*$ 或者 \mathbf{n}_1 不可行, 则将约束条件 $n_k \geq \lfloor n_k^* \rfloor + 1$ 添加至式(21a)并用 \mathbf{n}_2 更新 \mathbf{n} . $k = k + 1$.

4) 重复执行步骤 2) 和 3), 直到 $k=K$.

5) 输出最优解 \mathbf{n} .

2.4 IRS 对角相移矩阵的优化

在固定其他变量的前提下对 $\boldsymbol{\Theta}_k$ 进行优化. 将 h_k 代入 E_k 并删除 $\boldsymbol{\Theta}_k$ 的无关项后, 相移矩阵的优化问题可以表示为

$$\min_{\boldsymbol{\Theta}_k} \sum_{k=1}^K \alpha_k n_k q_k g_k \quad (22a)$$

$$\text{s. t. } (8e) \quad (22b)$$

首先定义

$$\boldsymbol{\Theta}_k = [\theta_{1,k}, \theta_{2,k}, \dots, \theta_{M,k}]^H = [e^{j\phi_1}, e^{j\phi_2}, \dots, e^{j\phi_M}]^H$$

并考虑等式 $\mathbf{h}\boldsymbol{\Theta}_k\mathbf{b} = \boldsymbol{\Theta}_k^H \text{diag}(\mathbf{h})\mathbf{b}$, 之后, 通过引入变量 $\bar{\mathbf{h}}_k = \text{diag}(\mathbf{h}_{\text{ra}})\mathbf{h}_{\text{kr}}$, 推导得到 g_k 的简化形式:

$$\bar{g}_k = p_k |u_k|^2 \|\bar{\mathbf{h}}_k\|^2 \|\boldsymbol{\Theta}_k^H\|^2 - \sqrt{p_k} \{ u_k^* \boldsymbol{\Theta}_k^H \bar{\mathbf{h}}_k + u_k (\boldsymbol{\Theta}_k^H \bar{\mathbf{h}}_k)^* \}$$

显然, 由于 $|u_{i,k}| = 1$ 可以得到 $\|\boldsymbol{\Theta}_k\|^2 = M$. 将 \bar{g}_k 代入问题(22a)并去掉常数项, 优化问题简化为

$$\max_{\boldsymbol{\Theta}_k} \sum_{k=1}^K 2\text{Re} \{ u_k^* \boldsymbol{\Theta}_k^H \bar{\mathbf{h}}_k \} \quad (23a)$$

$$\text{s. t. } (8e) \quad (23b)$$

观察后发现, 当 $u_k^* \boldsymbol{\Theta}_k^H \bar{\mathbf{h}}_k$ 的相位均为 0 时, 目标函数可实现最大化. 因此, $\boldsymbol{\Theta}_k$ 的全局最优解闭式表达式为

$$\boldsymbol{\Theta}_k^{\text{opt}} = [e^{j[\arg(\bar{h}_{1,k} u_k^*)]}, \dots, e^{j[\arg(\bar{h}_{M,k} u_k^*)]}]^T \quad (24)$$

其中 $\bar{h}_{i,k}$ 为 $\bar{\mathbf{h}}_k$ 的第 i 个分量. 最终得到式(22a)的最优解 $\boldsymbol{\Theta}_k^{\text{opt}} = \text{diag}(\boldsymbol{\Theta}_k^{\text{opt}})$.

2.5 算法复杂度分析

辅助变量和对角相移矩阵的优化均可直接求得

闭式解, 因而算法的复杂度主要取决于发射功率和重传次数的优化.

发射功率子问题的求解使用的是基于牛顿法的对数障碍法. 考虑基于回溯直线搜索的牛顿法作为内层算法, 其计算复杂度为 $O(K^3)$, 迭代次数不多于

$$L_1 = (20 - 8\phi) [F(\mathbf{P}^{(0)}) - F(\mathbf{P}^{(*)})] / [\phi\psi(1 - 2\phi)^2 + \ln(1/\eta)]$$

其中: ϕ 为可以接受的 F 的减少量占基于线性外推预测减少量的比值, ψ 为步长缩小因子, $\mathbf{P}^{(0)}$ 为迭代起点, $\mathbf{P}^{(*)}$ 为最优解. 所使用的对数障碍方法直接令参数 $v = m/\xi$, 因此不需要外层迭代过程, 求解发射功率子问题的总复杂度为 $O(L_1 K^3)$. 重传次数子问题求解的复杂度在于分支定界法的使用. 在最差情况下, 该子问题的算法复杂度与变量维度呈指数关系, 即 $O(2^K)$, 其中 K 为变量维度. 基于以上分析, 算法的总复杂度为 $O(L_1 L_2 K^3 + L_2 2^K)$, 其中 L_2 为算法的最大迭代次数.

3 仿真结果

为了验证所提出的加权和速率最大化方法的性能, 下面给出仿真结果. 假设 BS 和 IRS 分别位于坐标 $(0, 0, 10)$ 和 $(50, 50, 15)$ 处, 度量单位为 m, 同时 $K=4$ 个用户均匀分布在高度为 0 的 $[-75, 75] \times [100, 100] \text{ m}^2$ 的范围内. 在仿真实验中, 分别设置 IRS-BS 链路、用户-IRS 链路和用户-BS 链路的路径损耗指数为 $\beta_{\text{ra}} = 2.2$, $\beta_{\text{ur}} = 2.8$ 和 $\beta_{\text{ua}} = 3.5$. 除非另有声明, 其他参数设置为 $\sigma^2 = -80 \text{ dBm}$, $L_0 = -30 \text{ dB}$, $P_{\text{max}} = 30 \text{ dBm}$, $M = 100$, $N = 400$ 并且 $\epsilon_{\text{max}} \sim U(10^{-7}, 10^{-6})$.

除去笔者提出的既有 IRS 辅助又有重要性感知资源分配机制的方案, 将其他 3 种方案作为对比. 其中“无重要性感知分配”表示在分配用户的重传次数时不考虑数据的重要性. 为了便于进行性能对比, 将归一化后的加权和速率 (NMSR, normalized weighted sum rate) 作为仿真图的纵坐标.

图 2 所示为不同方案下的归一化加权和速率与发射功率的关系. 首先, 可以观察到所有方案得到的 NWSR 均随着 BS 最大功率的增加而增加. 此外, 可以看出, “有 IRS, 有重要性感知分配”的表现远优于其他方案, 而“无 IRS, 无重要性感知分配^[21]”的表现最差. 这是因为在给出的设计方案中, 部署 IRS 会使信号的传播环境变得高度可控, 并且重要性感

知分配机制能够确保数据的重要性越高,被分配到的重传资源越多.

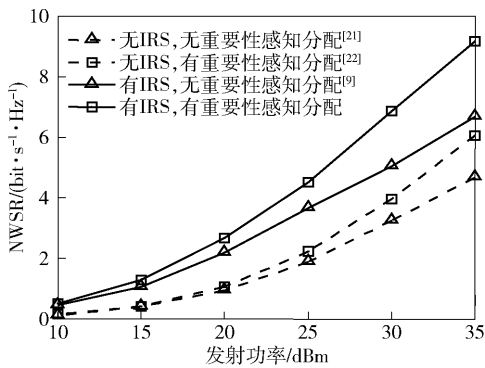


图2 不同发射功率时的归一化加权和速率对比

图3所示为归一化加权和速率随IRS反射单元数 M 变化的曲线.可以注意到,当 $M=20$ 时,只部署IRS^[9]和只采用重要性感知资源分配机制^[22]所获得的归一化加权和速率几乎相等.然而随着IRS反射单元数目的增加,IRS速率提高的作用变得愈加显著,表明部署IRS是一种非常有前景的可提高无线通信系统数据聚合能力的方法.

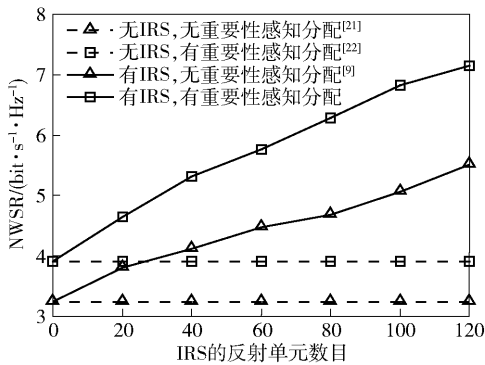


图3 不同IRS反射单元数时的归一化加权和速率对比

图4示出了IRS的位置对归一化加权和速率的影响.结果表明,当IRS的横纵坐标接近20或70

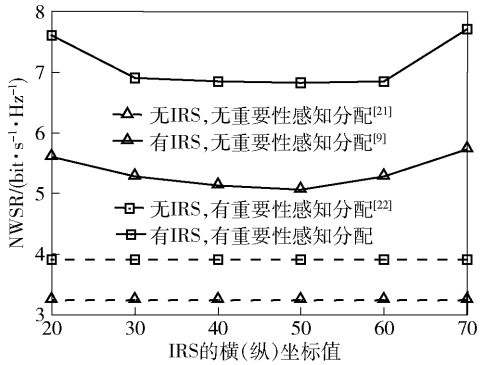


图4 不同IRS位置时的归一化加权和速率对比

时,IRS辅助通信方案具有显著的性能改善.该结果与预想的结果相吻合,这是因为基于以上的场景参量,当IRS的位置在向这2个方向移动时,它将分别接近BS和用户,其反射单元可以被充分用于反射接收端所需的信号或接收发送端处的发射信号.

4 结束语

在智能反射面辅助的边缘智能系统中,分布式数据对全局模型的训练具有差异性贡献.针对6G应用中分布式智能体的模型汇聚问题,提出了一种重要性感知的学习驱动资源管理算法.在IRS辅助的无线通信系统中综合考虑了信道不可靠性、用户发送功率及反射单元的相移等约束,构建非凸混合整数规划问题,以最大化数据汇聚的上行加权和速率.通过将其转化为等价加权均方误差最小化问题,结合凸优化、分支界定等方法与交替优化算法,解得资源分配方案.仿真结果表明,在不同的用户发射功率、IRS反射单元数目及IRS位置条件下,所提出的资源管理算法达到的效果均优于基准对比方案,说明该算法能够有效汇聚分布式智能体本地数据,并保障数据汇聚对用户数据的重要性感知.

参考文献:

[1] 张平,牛凯,田辉,等. 6G移动通信技术展望[J]. 通信学报, 2019, 40(1): 141-148.
Zhang Ping, Niu Kai, Tian Hui, et al. Technology prospect of 6G mobile communications[J]. Journal on Communications, 2019, 40(1): 141-148.

[2] 田辉,范绍帅,吕昕晨,等. 面向5G需求的移动边缘计算[J]. 北京邮电大学学报, 2017, 40(2): 1-10.
Tian Hui, Fan Shaoshuai, Lü Xinchun, et al. Mobile edge computing for 5G requirements[J]. Journal of Beijing University of Posts and Telecommunications, 2017, 40(2): 1-10.

[3] Yang Qiang, Liu Yang, Chen Tianjian, et al. Federated machine learning: concept and applications[J]. ACM Transactions on Intelligent Systems and Technology (TIST), 2019, 10(2): 1-19.

[4] 易芝玲,王森,韩双锋,等. 从5G到6G的思考:需求、挑战与技术发展趋势[J]. 北京邮电大学学报, 2020, 43(2): 1-9.
Yi Zhiling, Wang Sen, Han Shuangfeng, et al. From 5G to 6G: requirements, challenges and technical trends[J]. Journal of Beijing University of Posts and Telecommunications, 2020, 43(2): 1-9.

- [5] 中国移动研究院. 2030 + 愿景与需求报告(V1)[EB/OL]. 2019(2019-11-15)[2020-08-24]. http://cmri.chinamobile.com/wp-content/uploads/2019/11/2030_愿景与需求报告.pdf.
- [6] 梁应敞, 谭俊杰, Dusit Niyato. 智能无线通信技术研究概况[J]. 通信学报, 2020, 41(7): 1-17.
Liang Yingchang, Tan Junjie, Dusit N. Overview on intelligent wireless communication technology[J]. Journal on Communications, 2020, 41(7): 1-17.
- [7] Guo Jing, Durrani S, Zhou Xiangyun, et al. Massive machine type communication with data aggregation and resource scheduling[J]. IEEE Transactions on Communications, 2017, 65(9): 4012-4026.
- [8] Wu Qingqing, Zhang Rui. Towards smart and reconfigurable environment: intelligent reflecting surface aided wireless network[J]. IEEE Communications Magazine, 2020, 58(1): 106-112.
- [9] Jiang Tao, Shi Yuanming. Over-the-air computation via intelligent reflecting surfaces[C]//2019 IEEE Global Communications Conference (GLOBECOM). Waikoloa: IEEE Press, 2019: 1-6.
- [10] Zuo Jiakuo, Liu Yuanwei, Qin Zhijin, et al. Resource allocation in intelligent reflecting surface assisted NOMA systems[J]. IEEE Transactions on Communications, 2020, 68(11): 7170-7183.
- [11] Zhang Shuowen, Zhang Rui. Capacity characterization for intelligent reflecting surface aided MIMO communication[J]. IEEE Journal on Selected Areas in Communications, 2020, 38(8): 1823-1838.
- [12] Yang Yifei, Zheng Beixiong, Zhang Shuowen, et al. Intelligent reflecting surface meets OFDM: protocol design and rate maximization[J]. IEEE Transactions on Communications, 2020, 68(7): 4522-4535.
- [13] Yang Gang, Xu Xinyue, Liang Yingchang. Intelligent reflecting surface assisted non-orthogonal multiple access[C]//2020 IEEE Wireless Communications and Networking Conference (WCNC). Seoul: IEEE Press, 2020: 1-6.
- [14] Yu D, Park S H, Simeone O, et al. Optimizing over-the-air computation in IRS-aided C-RAN systems[C]//2020 IEEE 21st International Workshop on Signal Processing Advances in Wireless Communications (SPAWC). Atlanta: IEEE Press, 2020: 1-6.
- [15] She Changyang, Yang Chenyang, Quek T. Uplink transmission design with massive machine type devices in tactile internet[C]//2016 IEEE Globecom Workshops (GC Wkshps). Washington DC: IEEE Press, 2016: 1-6.
- [16] Boulougeorgos A, Alexiou A. Performance analysis of reconfigurable intelligent surface-assisted wireless systems and comparison with relaying[J]. IEEE Access, 2020, 8: 94463-94483.
- [17] Shi Qingjiang, Razaviyayn M, Luo Zhiquan, et al. An iteratively weighted MMSE approach to distributed sum-utility maximization for a MIMO interfering broadcast channel[J]. IEEE Transactions on Signal Processing, 2011, 59(9): 4331-4340.
- [18] Li Zhengfeng, Hua Meng, Wang Qingxia, et al. Weighted sum-rate maximization for multi-IRS aided cooperative transmission[J]. IEEE Wireless Communications Letters, 2020, 9(10): 1620-1624.
- [19] Boyd S, Vandenberghe L. Convex optimization[M]. Cambridge: Cambridge University Press, 2004: 437-551.
- [20] Jung C, Kim H, Lee T. A branch and bound algorithm for cyclic scheduling of timed petri nets[J]. IEEE Transactions on Automation Science and Engineering, 2015, 12(1): 309-323.
- [21] Chen Mingzhe, Yang Z, Saad W, et al. Performance optimization of federated learning over wireless networks[C]//2019 IEEE Global Communications Conference (GLOBECOM). Atlanta: IEEE Press, 2019: 1-6.
- [22] Choi H J, Lee K J, Song C, et al. Weighted sum rate maximization for multi-user multi-relay MIMO systems with direct links[C]//2013 IEEE 77th Vehicular Technology Conference (VTC Spring). Dresden: IEEE Press, 2013: 1-6.