面向超大规模RIS辅助近场通感一体化系统的基于GNN的联合波束成形设计

Jiahao Chen，*IEEE*学生会员，Feng Wang，*IEEE*会员，Guojun Han，*IEEE*高级会员，Xin Wang，*IEEE*会士，以及Vincent K. N. Lau，*IEEE*会士

arXiv:2603.01379v1 [cs.IT] 2 Mar 2026

摘要—**本文研究一种由超大规模可重构智能表面（XL-RIS）辅助的近场通信感知一体化（ISAC）系统，其中，多天线基站（BS）同时向多个单天线通信用户（CU）发送单播数据，并对多个目标（TGT）进行感知。假设基站、通信用户和目标均 位于XL-RIS的近场区域。我们的目标是在满足每个目标的感知波束图增益约束、基站发射功率约束以及XL-RIS相移的单位模约束的条件下，最大化所有通信用户的加权和速率（WSR）。首先，我们提出一种基于分式规划（FP）的块坐标下降（BCD）算法，以求解此类非凸联合设计问题的局部最优解。其次，为应对XL-RIS近场信道中的高维空间相关性和可扩展性问题，我们提出一种定制的图神经网络（GNN）方案，用于生成通感一体化系统的基站发射波束成形变量和XL-RIS反射系数向量，其中将近场通感一体化系统建模为由XL-RIS/通信用户/目标节点组成的异构图。所提出的GNN方案能够有效学习近场信道状态信息（CSI）特征，并利用消息传递机制在图中直接相连的节点之间交换CSI。此外，每个XL-RIS/通信用户/目标节点都维护一个特征向量，用于映射到基站发射波束成形变量或XL-RIS反射系数向量。数值结果表明，与现有基线方法相比，所提出的基于GNN的波束成形设计方案在计算效率、可行性、鲁棒性和泛化能力方面表现更优。**

关键词—**近场、通感一体化（ISAC）、超大规模可重构智能表面（XL-RIS）、图神经网络（GNN）、消息传递、鲁棒性。**

I. 引言

SIXTH-GENERATION (6G)无线网络被设想为众多新兴应用的关键使能因素，这些应用需要通信感知一体化（通感一体化）。通信与感知资源可以在通感一体化系统中共享，从而使通信与雷达感知功能能够在同一硬件平台上共存，并共享相同的发射波形，从而从本质上提升能量、频谱和硬件效率。然而，通感一体化资源日益稀缺，很可能制约6G无线网络的容量 [2]–[4]。

因此，可重构智能表面（RIS）被视为满足6G无线网络需求的一种有前景的解决方案 [5], [6]。借助RIS，通感一体化有望显著提升感知与通信性能 [7]。此外，随着超大规模天线阵列的集成，以及毫米波（mmWave）和太赫兹（THz）等更高频段的应用，近场区域不断扩大，因此应对近场效应变得愈发重要 [8]。因此，实现此类近场通感一体化系统面临着重大挑战，包括维持实时感知和低时延通信服务。

A. 相关工作

将RIS集成到通感一体化系统中，因其能够通过重构无线传播环境，同时提升通信速率和感知精度而备受关注。通感一体化面临的一项关键挑战是联合波束成形设计，这通常涉及变量耦合的非凸优化问题。传统上，基于优化理论的算法已被广泛用于应对这一挑战，其中包括分式规划（FP）、连续凸近似（SCA）和块坐标下降（BCD）等技术。例如，文献 [9]–[11] 分别采用上述方法，最大化多个目标（TGT）的最小感知波束方向图，以及通信用户（CU）的加权和速率（WSR）。

然而，这些基于优化理论的方法在超大规模可重构智能表面辅助的近场通感一体化系统中存在严重局限：随着超大规模可重构智能表面单元数量增加，这类方法通常需要更长的运行时间，无法满足实时通信与感知需求。此外，近场区域复杂的耦合信道模型可能会加剧传统求解器的收敛困难。

为克服传统优化的高计算开销，基于深度学习（DL）的算法已

本文部分内容发表于8月10日至13 [1]在中国上海举行的IEEE/CIC中国通信国际会议（ICCC）。J. Chen、F. Wang和G. Han现任职于广东工业大学信息工程学院，地址：中国广州510006（电子邮箱：fengwang13@gdut.edu.cn）。X. Wang现任职于复旦大学未来信息技术学院电磁波信息科学教育部重点实验室，地址：中国上海200438（电子邮箱：xwang11@fudan.edu.cn）。V. K. N. Lau现任职于香港科技大学电子与计算机工程系，地址：中国香港（电子邮箱：eeknlau@ust.hk）。

成为解决信道估计 [13] 和资源分配 [14]等各种问题的替代方案。在不完美信道状态信息（CSI）条件下， [15]中的作者研究了一种由可移动天线赋能的、基于异构多智能体深度确定性策略梯度（DDPG）的多接收机通信系统。 [16]中的工作研究了基于学习的波束成形方案问题，该方案利用用户导频，在多用户 RIS 系统中最大化加权和速率，同时兼顾不同服务优先级，并基于新颖的超网络波束成形（HNB）框架，通过用户权重考虑公平性。[17] 中的作者针对由可再生能源供电的多接入边缘计算系统，研究了去中心化深度神经网络（DNN）任务划分与卸载控制优化问题。工作 [18]采用 DDPG 神经网络，联合设计基站的发射波束成形矩阵与可重构智能表面的相移矩阵。工作 [19] 利用深度神经网络解决了多用户移动边缘计算系统中的顺序任务卸载问题。尽管这些深度学习模型在若干场景中展现出良好性能，它们仍缺乏泛化能力与可扩展性。具体而言，这些深度学习模型在结构上受限于固定维度输入，这意味着若通感一体化系统拓扑发生变化，为特定数量通信用户或目标训练的模型必须从头重新训练。该局限性使其在通信用户或目标数量快速变化的动态通感一体化场景中效率低下。

为了解决传统深度学习因输入维度固定而导致的泛化能力和可扩展性问题，图神经网络（GNN）已被引入通感一体化系统。GNN能够将无线网络建模为图，并利用网络拓扑的置换不变性，使其无需重新训练便能很好地泛化到通信用户和目标数量各异的通感一体化系统。

本文提出将基于图神经网络（GNN）的优化方法用于超大规模可重构智能表面辅助近场通感一体化系统。GNN在利用无线网络的图拓扑方面具有优势。所提出的方法受到 [20]–[23]的启发。具体而言， [20]提出了一种基于可重构智能表面的多用户多输入单输出（MISO）通信系统，并利用GNN满足基站的发射功率约束。此外， [21]提出了基于GNN的夹持天线系统来学习发射波束成形，并表明基于GNN的方法能够以较低的推理复杂度实现较高的频谱效率。 [22]的作者将多用户多输入单输出网络建模为图，同时直接将信道状态信息映射为波束成形向量。最近， [23] 提出了一种适用于远场区域多小区通感一体化系统的协同波束成形方案。

B. 主要贡献

不同于现有的远场通感一体化研究，本文针对由超大规模可重构智能表面辅助的近场通感一体化系统，提出一种基于图神经网络学习的波束成形设计方案，其中基站和多个通信用户/目标均位于超大规模可重构智能表面的近场区域。我们的目标是在满足基站发射功率约束、感知波束图增益约束以及超大规模可重构智能表面相移的模约束的条件下，通过联合优化基站发射波束成形向量、感知协方差矩阵和超大规模可重构智能表面的反射系数，最大化可实现的加权和速率。与经典神经网络架构（例如深度神经网络/卷积神经网络）相比，所提出的基于图神经网络的解法在动态通感一体化系统中具有更强的泛化能力 [24]。

我们的主要贡献总结如下。

- 首先，我们提出一种基于分式规划的分块坐标下降算法，以获得非凸约束加权和速率最大化问题的局部最优解。基于闭式分式规划重构，可将加权和速率问题等价地转化为双凸问题。利用BCD方法，可进一步将该双凸问题分解为两个凸子问题，并按交替顺序高效优化基站的通感一体化波束成形设计变量和超大规模可重构智能表面的反射系数。

- 其次，我们为超大规模可重构智能表面辅助近场通感一体化系统提出一种新颖的基于图神经网络的波束成形设计框架，其中将通感一体化系统建模为异构图，并将超大规模可重构智能表面、通信用户和目标定义为不同类型的节点。基于本文建立的高保真近场信道模型，图中的所有节点均能有效捕捉近场区域内通信与感知之间的复杂耦合。通信用户/目标节点利用各自的近场信道状态信息计算表征特征向量，而超大规模可重构智能表面节点则通过处理全局信道状态信息构建表征特征向量，以满足同时服务通信和感知的需求。

- 第三，由近场信道状态信息生成的图中所有节点的表征特征向量被映射为用于下行通信/感知的基站发射波束成形变量以及超大规模可重构智能表面的反射系数。与深度神经网络模型不同，这种基于图的架构利用了图模型的置换不变性，因此能够很好地泛化到超大规模可重构智能表面近场区域内通信用户和目标数量可变的系统。

- 最后，大量仿真结果表明，所提出的设计算法在计算效率、可行性、鲁棒性和泛化能力方面均有效。特别是，与基于块坐标下降的算法相比，所提出的基于图神经网络的波束成形设计框架取得了更好的性能，同时显著降低了计算延迟，并展现出对近场场景中信道状态信息误差的鲁棒性。

C. 论文结构与符号说明

本文其余部分安排如下。第二节介绍超大规模可重构智能表面辅助的近场通感一体化系统模型及问题 formulation。第三节给出所提出的 BCD 方法。第四节介绍所提出的基于图神经网络的解法。第五节给出数值结果，以展示所提方案的性能。最后，我们在第六节总结全文。

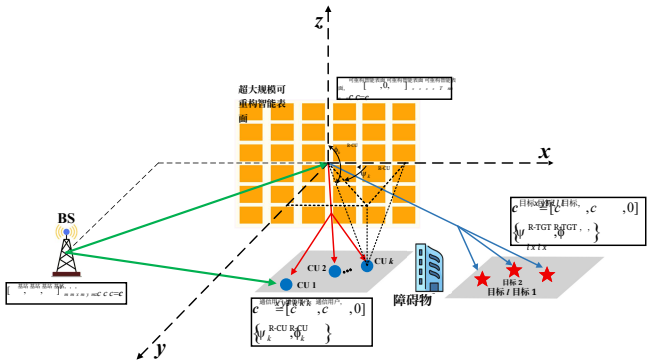

图1. XL-RIS辅助近场ISAC系统模型，其中基站/通信用户/目标位于超大规模可重构智能表面的近场区域。

本文使用的符号列举如下。$\mathbb{E}\{\cdot\}$ 表示统计期望。 $\mathcal{CN}(\mu,\ \sigma^2)$表示均值为 μ 、方差为 σ^2的圆对称复高斯（CSCG）分布。 $\boldsymbol{I}_N$ 和 $\mathbf{1}_N$ 分别表示大小为 $N \times N$ 的单位矩阵和大小为 $N \times 1$的单位向量。对于任意一般矩阵 $\boldsymbol{A}$, $[\boldsymbol{A}]_{i,\ j}$ 表示其第 i行、第 j列的元素； A^*、 A^T 和 A^H 分别表示$\boldsymbol{A}$的共轭、转置和共轭转置。对于任意向量 $\boldsymbol{a}$（本文中的所有向量均为列向量）， $\|\boldsymbol{a}\|$ 表示欧几里得范数， $[\boldsymbol{a}]_i$ 表示第 i个元素。 $|x|$表示复数 x的绝对值，而$(x)^+ = \max(x,\ 0)$。 $\Re\{\cdot\}$ 和 $\Im\{\cdot\}$ 分别表示复数量（包括矩阵、向量和复数）的实部和虚部。最后，符号 $\otimes$表示克罗内克积运算符。

II. 系统模型与问题 formulation

A. 系统模型

如图1所示，我们考虑一个由超大规模可重构智能表面辅助的近场通感一体化系统，其中多天线基站负责在下行信道中同时向一组由 $\mathcal{K} \triangleq \{1, 2, ..., K\}$个单天线通信用户组成的 K 发送单播数据，并感知一组感兴趣的 $\mathcal{L} \triangleq \{1, 2, ..., L\}$ 个指定目标 L。需要注意的是，由于超大规模可重构智能表面的尺寸较大，假设基站和通信用户/目标均位于超大规模可重构智能表面的近场区域。具体而言，基站配备了一个由 M 根天线组成的均匀线性阵列（ULA），而超大规模可重构智能表面配备了一个由 $N = N_x N_z$ 个反射~单元组成的均匀平面阵列（UPA），其中 $N_x = 2N_x + 1$ 和 $N_z = 2N_z + 1$ 分别表示超大规模可重构智能表面沿 x轴和 z轴的反射单元数量。对于基站和超大规模可重构智能表面，天线间距均假设为$d = \frac{\lambda}{2}$，其中 λ 是基站用于通感一体化的发射信号的载波波长。

请注意，在没有超大规模可重构智能表面时，近场与远场的边界通常由瑞利距离 [26], 即 $r_R = \frac{2D^2}{\lambda}$ 确定，其中 $D = Md$ 是基站发射天线孔径的直径。相比之下，在存在超大规模可重构智能表面的情况下，需要考虑经由超大规模可重构智能表面反射的基站到通信用户（或目标）的级联信道。所考虑的超大规模可重构智能表面的近场范围为 $r_h < {}^{2D^2}_{\text{可重构智能表面}\lambda}$，其中 $D_{\text{RIS}} = \sqrt{(N_x d)^2 + (N_z d)^2}$表示平面超大规模可重构智能表面孔径的有效直径，$r_h$ 表示基站与超大规模可重构智能表面之间距离和超大规模可重构智能表面与通信用户/目标之间距离 [27]的调和平均值。此外，我们假设系统工作于近场的菲涅耳区（$1.2D_{\text{RIS}} < r_h < {}^{2D^2}_{\text{可重构智能表面}\lambda}$）。

分别用 $s_k \in \mathbb{C}$ 和 $\boldsymbol{w}_k \in \mathbb{C}^{M\times 1}$ 表示每个通信用户 $k \in \mathcal{K}$ 的信息符号和发射波束成形向量。不失一般性，假设信息符号 $\{s_k\}_{k\in\mathcal{K}}$ 是零均值、独立同分布（i.i.d）的随机变量，且具有单位方差，即 $\mathbb{E}\{|s_k|^2\} = 1,\ \forall k \in \mathcal{K}$。基站的等效基带通感一体化信号 $\boldsymbol{x} \in \mathbb{C}^{M\times 1}$ 建模为 [9]

$$\boldsymbol{x} = \sum_{k=1}^{K} \boldsymbol{w}_k s_k + \boldsymbol{x}_0, \tag{1}$$

其中， $\boldsymbol{x}_0 \in \mathbb{C}^{M\times 1}$ 表示基站的专用感知符号。根据式 (1)，基站的平均发射功率表示为

$$\mathbb{E}[\|\boldsymbol{x}\|^2] = \text{tr}(\boldsymbol{W}^H\boldsymbol{W}) + \text{tr}(\boldsymbol{R}_0), \tag{2}$$

其中， $\boldsymbol{W} \triangleq [\boldsymbol{w}_1, ..., \boldsymbol{w}_K] \in \mathbb{C}^{M\times K}$ 表示基站的通信波束成形矩阵， $\boldsymbol{R}_0 \triangleq \mathbb{E}\{\boldsymbol{x}_0\boldsymbol{x}_0^H\}$ 表示基站的感知协方差矩阵。

我们考虑用于超大规模可重构智能表面辅助通感一体化系统的三维笛卡尔坐标系，其中超大规模可重构智能表面位于 xoz 平面，基站位于 yoz 平面，通信用户和目标均位于 xoy 平面。首先，我们分别将 $\boldsymbol{c}^{\text{RIS}}_{n_x\,n_z} = [c^{\text{RIS}}_{n_x}, 0, c^{\text{RIS}}_{n_z}]^T$ $\boldsymbol{c}^{\text{BS}}_m = [c^{\text{BS}}_{m,x}, c^{\text{BS}}_{m,y}, c^{\text{BS}}_{m,z}]^T$ 和表示为超大规模可重构智能表面的反射单元 (n_x, n_z) 和基站天线 m 的坐标，其中 $n_x \in \mathcal{N}_x \triangleq \{-\tilde{N}_x, -\tilde{N}_x + 1, ..., \tilde{N}_x\}$, $n_z \in \mathcal{N}_x \triangleq \{-\tilde{N}_z, -\tilde{N}_z+1, ..., \tilde{N}_z\}$，且 $m \in \mathcal{M} \triangleq \{1, 2, ..., M\}$。分别用 $\boldsymbol{c}^{\text{CU}}_k = [c^{\text{CU},x}_k, c^{\text{CU},y}_k, 0]^T$ 和 $\boldsymbol{c}^{\text{TGT}}_l = [c^{\text{TGT},x}_l, c^{\text{TGT},y}_l, 0]^T$ 表示通信用户 $k \in \mathcal{K}$ 和目标 $l \in \mathcal{L}$ 的坐标。

因此，基站天线m 到超大规模可重构智能表面单元（n_x, n_z）以及通信用户 $k \in \mathcal{K}$ 的欧几里得距离分别为

$$r^{\text{BS-CU}}_{m,k} = \left\|\boldsymbol{c}^{\text{BS}}_m - \boldsymbol{c}^{\text{CU}}_k\right\| \tag{3a}$$

$$r^{\text{BS-R}}_{m,n_x,n_z} = \left\|\boldsymbol{c}^{\text{BS}}_m - \boldsymbol{c}^{\text{RIS}}_{n_x,n_z}\right\|, \tag{3b}$$

其中 $m \in \mathcal{M}$，超大规模可重构智能表面单元的单元（n_x, n_z）到通信用户 $k \in \mathcal{K}$ 和目标 $l \in \mathcal{L}$ 的欧几里得距离分别为

$$r^{\text{R-CU}}_{n_x,n_z,k} = \left\|\boldsymbol{c}^{\text{RIS}}_{n_x,n_z} - \boldsymbol{c}^{\text{CU}}_k\right\| \tag{4a}$$

$$r^{\text{R-TGT}}_{n_x,n_z,l} = \left\|\boldsymbol{c}^{\text{RIS}}_{n_x,n_z} - \boldsymbol{c}^{\text{TGT}}_l\right\|. \tag{4b}$$

B. 超大规模可重构智能表面辅助通信模型

令 $\boldsymbol{G} \in \mathbb{C}^{N\times M}$ 表示从基站到超大规模可重构智能表面的近场信道矩阵，其定义为

$$\boldsymbol{G} = \beta^{\text{BS-R}} \begin{bmatrix} e^{-j\frac{2\pi}{\lambda}r^{\text{BS-R}}_{1,-\tilde{N}_x,-\tilde{N}_z}} & \cdots & e^{-j\frac{2\pi}{\lambda}r^{\text{BS-R}}_{M,-\tilde{N}_x,-\tilde{N}_z}} \\ \vdots & & \vdots \\ e^{-j\frac{2\pi}{\lambda}r^{\text{BS-R}}_{1,0,0}} & \cdots & e^{-j\frac{2\pi}{\lambda}r^{\text{BS-R}}_{M,0,0}} \\ \vdots & & \vdots \\ e^{-j\frac{2\pi}{\lambda}r^{\text{BS-R}}_{1,\tilde{N}_x,\tilde{N}_z}} & \cdots & e^{-j\frac{2\pi}{\lambda}r^{\text{BS-R}}_{M,\tilde{N}_x,\tilde{N}_z}} \end{bmatrix}, \tag{5}$$

其中，$\beta^{\text{BS-R}} = \rho_0(r_{1\,0\,0,}^{\text{BS-R}})^{-\alpha}$ 表示从基站到超大规模可重构智能表面的路径损耗系数。此外，令 ρ_0 和 α分别表示信号传播在参考距离一米处的路径损耗系数和路径损耗指数。

令 $\psi_k^{\text{R-CU}}$和 $\phi_k^{\text{R-CU}}$分别表示从超大规模可重构智能表面中心单元（0,0）到通信用户 $k \in \mathcal{K}$的方位角和俯仰角出发角（AoD）。相应地，超大规模可重构智能表面在出发角-距离对（$\psi_k^{\text{R-CU}}, \phi_k^{\text{R-CU}}, r_{0\,0\,k,}^{\text{R-CU}}$）下的阵列响应为 [29]

$$\boldsymbol{\alpha}_k^{\text{R-CU}}(\psi_k^{\text{R-CU}}, \phi_k^{\text{R-CU}}, r_{0,0,k}^{\text{R-CU}}) = \boldsymbol{\alpha}_{k,x}^{\text{R-CU}} \otimes \boldsymbol{\alpha}_{k,z}^{\text{R-CU}}, \tag{6}$$

对于每个 $n_x \in \mathcal{N}_x$ 和 $n_z \in \mathcal{N}_z$，有

$$[\boldsymbol{\alpha}_{k,x}^{\text{R-CU}}]_{n_x} = \exp\Bigg(-j\frac{2\pi}{\lambda}\Big(-n_x d\cos\psi_k^{\text{R-CU}}\sin\phi_k^{\text{R-CU}} + \frac{n_x^2 d^2(1-\cos^2\psi_k^{\text{R-CU}}\sin^2\phi_k^{\text{R-CU}})}{2r_{0,0,k}^{\text{R-CU}}}\Big)\Bigg) \tag{7a}$$

$$[\boldsymbol{\alpha}_{k,z}^{\text{R-CU}}]_{n_z} = \exp\Bigg(-j\frac{2\pi}{\lambda}\Big(-n_z d\cos\phi_k^{\text{R-CU}} + \frac{n_z^2 d^2\sin^2\phi_k^{\text{R-CU}}}{2r_{0,0,k}^{\text{R-CU}}}\Big)\Bigg). \tag{7b}$$

令 $\beta_k^{\text{R-CU}} = \rho_0(r_{0\,0\,k,}^{\text{R-CU}})^{-\alpha}$ 表示从超大规模可重构智能表面的单元（n_x, n_z）到通信用户 k的路径损耗系数。从基站天线 m到通信用户 k 的路径损耗系数记为$\beta_k^{\text{BS-CU}} = \rho_0(r_{1\,k}^{\text{BS-CU}})^{-\alpha}$。从超大规模可重构智能表面和基站到通信用户 $k \in \mathcal{K}$ 的信道向量分别建模为

$$\boldsymbol{h}_k^{\text{R-CU}} = \beta_k^{\text{R-CU}}\boldsymbol{\alpha}_k^{\text{R-CU}}(\psi_k^{\text{R-CU}}, \phi_k^{\text{R-CU}}, r_{0,0,k}^{\text{R-CU}}) \tag{8a}$$

$$\boldsymbol{h}_k^{\text{BS-CU}} = \beta_k^{\text{BS-CU}}\boldsymbol{\alpha}_k^{\text{BS-CU}}, \tag{8b}$$

其中 $\boldsymbol{\alpha}_k^{\text{BS-CU}} = [e^{-j\frac{2\pi}{\lambda}r_{1,k}^{\text{BS-CU}}}, e^{-j\frac{2\pi}{\lambda}r_{2,k}^{\text{BS-CU}}}, ..., e^{-j\frac{2\pi}{\lambda}r_{M,k}^{\text{BS-CU}}}]^T$表示从基站到通信用户 $k \in \mathcal{K}$的阵列导向向量。

令 $\boldsymbol{\Phi}$ 表示超大规模可重构智能表面反射矩阵，其中$\Phi_{n_x,n_z} = e^{j\phi_{n_x,n_z}}$ 表示超大规模可重构智能表面单元（n_x, n_z）的反射系数，$\phi_{n_x,n_z} \in [0, 2\pi]$ 表示超大规模可重构智能表面单元（n_x, n_z）的相移值，$\forall n_x \in \mathcal{N}_x$，$n_z \in \mathcal{N}_z$。为便于表示，我们将 $\boldsymbol{\theta} = \text{vec}(\boldsymbol{\Phi})$定义为超大规模可重构智能表面反射向量，它由 $\boldsymbol{\Phi}$的各列堆叠而成。

在所考虑的通感一体化系统中，每个通信用户 $k \in \mathcal{K}$通过直达链路以及由超大规模可重构智能表面辅助的级联链路接收来自基站的信号。因此，每个通信用户 $k \in \mathcal{K}$ 的接收信号建模为

$$\begin{aligned} y_k &= \big((\boldsymbol{h}_k^{\text{R-CU}})^H\text{diag}(\boldsymbol{\theta}^H)\boldsymbol{G} + (\boldsymbol{h}_k^{\text{BS-CU}})^H\big)\boldsymbol{x} + n_k \\ &= (\boldsymbol{G}^H\text{diag}(\boldsymbol{h}_k^{\text{R-CU}})\boldsymbol{\theta} + \boldsymbol{h}_k^{\text{BS-CU}})^H\boldsymbol{x} + n_k \\ &= \boldsymbol{h}_{\text{CU},k}^H\boldsymbol{x} + n_k, \end{aligned} \tag{9}$$

其中，$\boldsymbol{h}_{\text{CU},\,k} \triangleq \boldsymbol{G}^H\text{diag}(\boldsymbol{h}_k^{\text{R-CU}})\boldsymbol{\theta} + \boldsymbol{h}_k^{\text{BS-CU}}$称为从基站经超大规模可重构智能表面到通信用户的级联信道向量；$n_k \sim \mathcal{CN}(0,\ \sigma_k^2$表示通信用户处均值为零、方差为 σ_k^2的加性白高斯噪声（AWGN）。

在解码通信信号时，每个通信用户的接收端 $k \in \mathcal{K}$ 将所有感知信号 $\boldsymbol{x}_0$ 以及发往其他通信用户的通信信号视为干扰。然后，根据式 (9)，通信用户 k 的解码信干噪比 (SINR) 表示为

$$\gamma_k = \frac{|\boldsymbol{h}_{\text{CU},k}^H\boldsymbol{w}_k|^2}{\sum_{j=1,j\neq k}^K|\boldsymbol{h}_{\text{CU},k}^H\boldsymbol{w}_j|^2 + \boldsymbol{h}_{\text{CU},k}^H\boldsymbol{R}_0\boldsymbol{h}_{\text{CU},k} + \sigma_k^2}, \tag{10}$$

其中 $k \in \mathcal{K}$。

*C. XL-RIS*辅助感知模型

在超大规模可重构智能表面辅助的通感一体化系统中，通过调整其反射单元的相移值，超大规模可重构智能表面能够灵活地重构基站 → XL-RIS → 目标级联信道条件，从而提升通感一体化性能。

令 $\psi_l^{\text{R-TGT}}$和 $\phi_l^{\text{R-TGT}}$分别表示从XL-RIS中心反射单元(0，0)到目标 $l \in \mathcal{L}$的方位角和俯仰角出发角，并令 $r_{0\,0\,l}^{\text{R-TGT}}$,表示从XL-RIS中心反射单元(0，0)到目标 $l \in \mathcal{L}$的欧氏距离。对于每个具有出发角-距离对($\psi_{l\,x}^{\text{R-TGT}}$，$\phi_{l\,x}^{\text{R-TGT}}$，$r_{0\,0\,l}^{\text{R-TGT}}$,)的目标 $l \in \mathcal{L}$，XL-RIS的近场阵列响应向量$\boldsymbol{\alpha}_l^{\text{R-TGT}}$定义为

$$\boldsymbol{\alpha}_l^{\text{R-TGT}}(\psi_l^{\text{R-TGT}}, \phi_l^{\text{R-TGT}}, r_{0,0,l}^{\text{R-TGT}}) = \boldsymbol{\alpha}_{l,x}^{\text{R-TGT}} \otimes \boldsymbol{\alpha}_{l,z}^{\text{R-TGT}}, \tag{11}$$

其中，对于每个 $n_x \in \mathcal{N}_x$ 和 $n_z \in \mathcal{N}_z$，有

$$[\boldsymbol{\alpha}_{l,x}^{\text{R-TGT}}]_{n_x} = \exp\Bigg(-j\frac{2\pi}{\lambda}\Big(-n_x d\cos\psi_l^{\text{R-TGT}}\sin\phi_l^{\text{R-TGT}} + \frac{n_x^2 d^2(1-\cos^2\psi_l^{\text{R-TGT}}\sin^2\phi_l^{\text{R-TGT}})}{2r_{0,0,l}^{\text{R-TGT}}}\Big)\Bigg) \tag{12a}$$

$$[\boldsymbol{\alpha}_{l,z}^{\text{R-TGT}}]_{n_z} = \exp\Bigg(-j\frac{2\pi}{\lambda}\Big(-n_z d\cos\phi_l^{\text{R-TGT}} + \frac{n_z^2 d^2\sin^2\phi_l^{\text{R-TGT}}}{2r_{0,0,l}^{\text{R-TGT}}}\Big)\Bigg). \tag{12b}$$

记 $\beta_l^{\text{RIS-TGT}}$为信号从超大规模可重构智能表面中心单元 (0,0) 传播至目标 $l \in \mathcal{L}$的路径损耗系数。从超大规模可重构智能表面到目标 $l \in \mathcal{L}$ 的信道向量为

$$\boldsymbol{h}_l^{\text{R-TGT}} = \beta_l^{\text{R-TGT}}\boldsymbol{\alpha}_l^{\text{R-TGT}}(\psi_l^{\text{R-TGT}}, \phi_l^{\text{R-TGT}}, r_{0,0,l}^{\text{R-TGT}}). \tag{13}$$

注意，基站发射信号 $\boldsymbol{x}$中的通信信号 $\sum_{k=1}^K\boldsymbol{w}_k s_k$ 和感知信号 $\boldsymbol{x}_0$ 均可通过基站 → 超大规模可重构智能表面 →目标级联信道照射多个 L 目标。因此，目标 $l \in \mathcal{L}$ 的感知波束图增益 ρ_l 表示为

$$\rho_l = \boldsymbol{h}_{\text{TGT},l}^H\big(\boldsymbol{W}\boldsymbol{W}^H + \boldsymbol{R}_0\big)\boldsymbol{h}_{\text{TGT},l}, \tag{14}$$

其中，$\boldsymbol{h}_{\text{TGT},l} \triangleq \boldsymbol{G}^H\text{diag}(\boldsymbol{h}_l^{\text{R-TGT}})\boldsymbol{\theta}$ 表示目标 $l \in \mathcal{L}$的基站 → 超大规模可重构智能表面→ 目标级联信道向量。

D. 问题 *formulation*

在所有 L目标的最小感知波束图增益要求以及基站发射功率约束下，我们旨在通过联合优化基站通信波束成形矩阵 $\boldsymbol{W}$ 和

感知协方差矩阵 $\boldsymbol{R}_0$，以及超大规模可重构智能表面的反射系数向量 $\boldsymbol{\theta}$。在数学上，联合近场通感一体化波束成形设计问题可描述为

$$
\begin{aligned}
(\text{P1}):\ &\max_{\boldsymbol{W},\boldsymbol{R}_0,\boldsymbol{\theta}} \ \sum_{k=1}^{K}\tau_k\log\left(1+\gamma_k\right) && \text{(15a)}\\
\text{s.t.}\ &\ \text{tr}(\boldsymbol{W}^H\boldsymbol{W})+\text{tr}(\boldsymbol{R}_0)\le P_0 && \text{(15b)}\\
&\ |\Phi_{n_x,n_z}|=1,\ \forall n_x\in\mathcal{N}_x, n_z\in\mathcal{N}_z && \text{(15c)}\\
&\ \rho_l\ge\rho_{th},\forall l\in\mathcal{L}, && \text{(15d)}
\end{aligned}
$$

其中，$\tau_k\in(0,1]$表示通信用户 k 下行可达数据速率的优先级权重，P_0 表示基站发射功率预算，ρ_{th} 表示所有目标的感知波束图增益阈值。

需要注意的是，基站发射设计变量（$\boldsymbol{W}$，$\boldsymbol{R}_0$）与超大规模可重构智能表面的反射系数向量 $\boldsymbol{\theta}$ 高度耦合。因此，（P1）是一个非凸优化问题。作为折中，我们在第三节采用经典的BCD方法，以较低复杂度求得（P1）的局部最优解。此外，在第四节中，我们通过利用图结构化超大规模可重构智能表面辅助近场通感一体化数据训练深度学习模型，开发了用于求解（P1）的先进图神经网络方案，在复杂度可控的情况下实现了优越的性能。

III. 基于分式规划的（P1）分块坐标下降解法

本节中，我们提出一种基于分式规划的分块坐标下降算法，用于求解联合近场通感一体化设计问题（P1）。

A. 闭式解分式规划重构

基于分式规划（FP）的思想 [10], [31], 即 $\log(1+\gamma_k)=\max_{\lambda_k>0}(\log(1+\lambda_k)-\lambda_k+(1+\lambda_k)\frac{\gamma_k}{1+\gamma_k})$，加权速率最大化问题（P1）可重写为

$$
\begin{aligned}
(\text{P1.1})\ &\max_{\boldsymbol{W},\boldsymbol{R}_0,\boldsymbol{\theta},\boldsymbol{\lambda}} \ \sum_{k=1}^{K}\tau_k\Big(\log(1+\lambda_k)-\lambda_k+\frac{(1+\lambda_k)\gamma_k}{1+\gamma_k}\Big)\\
&\text{满足约束 (15b), (15c),(15d)}\\
&\ \lambda_k\ge 0,\forall k\in\mathcal{K},
\end{aligned}
$$

其中 $\boldsymbol{\lambda}=[\lambda_1,...,\lambda_K]^T$。注意，给定向量 $\boldsymbol{\lambda}$ 时，最大化问题（P1.1）的目标函数等价于最大化比率函数 $\frac{\sum_{k=1}^{K}(1+\lambda_k)\frac{\gamma_k}{1+\gamma_k}}{}$，其中

$$
\frac{(1+\lambda_k)\gamma_k}{1+\gamma_k}=\frac{|\sqrt{1+\lambda_k}\boldsymbol{h}_{\text{CU},k}\boldsymbol{w}_k|^2}{\boldsymbol{h}_{\text{CU},k}(\boldsymbol{W}\boldsymbol{W}^H+\boldsymbol{R}_0)\boldsymbol{h}_{\text{CU},k}+\sigma_k^2}. \quad (16)
$$

此外，通过引入辅助变量 $v=A(x)B(x)$，可得

$$
\max_x\frac{|A(x)|^2}{B(x)}=\max_{x,v}(vA^*(x)+v^*A(x)-|\beta|^2B(x)). \quad (17)
$$

因此，基于(16)和(17)，问题(P1.1)被等价地重新表述为一个双凸问题

$$
\begin{aligned}
(\text{P1.2}):\ &\min_{\boldsymbol{\lambda},\boldsymbol{v},\boldsymbol{W},\boldsymbol{R}_0,\boldsymbol{\theta}} \ -f(\boldsymbol{\lambda},\boldsymbol{v},\boldsymbol{W},\boldsymbol{R}_0,\boldsymbol{\theta}) && \text{(18a)}\\
\text{s.t.}\ &\ \lambda_k\ge 0,\forall k=1,...,K && \text{(18b)}\\
&\ \text{(15b), (15c), (15d),} && \text{(18c)}
\end{aligned}
$$

其中 $\boldsymbol{v}=[v_1,...,v_K]^T$，且函数 f 定义为

$$
\begin{aligned}
f(\boldsymbol{\lambda},\boldsymbol{v},\boldsymbol{W},\boldsymbol{R}_0,\boldsymbol{\theta})&=\sum_{k=1}^{K}\tau_k(\log(1+\lambda_k)-\lambda_k)\\
&+\sum_{k=1}^{K}\sqrt{\tau_k(1+\lambda_k)}(v_k\boldsymbol{w}_k^H\boldsymbol{h}_{\text{CU},k}+v_k^*\boldsymbol{h}_{\text{CU},k}^H\boldsymbol{w}_k)\\
&-\sum_{k=1}^{K}|v_k|^2\left(\boldsymbol{h}_{\text{CU},k}^H(\boldsymbol{W}\boldsymbol{W}^H+\boldsymbol{R}_0)\boldsymbol{h}_{\text{CU},k}+\sigma_k^2\right). \quad (19)
\end{aligned}
$$

注意，f 分别关于变量块$\boldsymbol{\lambda}$、$\boldsymbol{v}$、$(\boldsymbol{W},\boldsymbol{R}_0)$ 和 $\boldsymbol{\theta}_0$为凹函数。因此，接下来我们采用BCD方法来获得（P1.2）的局部最优解。

B. 优化$(\boldsymbol{\lambda},\boldsymbol{v})$

将上一次迭代的时序优化结果记为 $\bar{\boldsymbol{\lambda}},\bar{\boldsymbol{v}},\bar{\boldsymbol{W}},\bar{\boldsymbol{R}}_0,\bar{\boldsymbol{\theta}}$。基于 [10],，$(\boldsymbol{\lambda},\boldsymbol{v})$ 的闭式解为

$$
\lambda_k=\frac{\bar{\chi}_k^2+\bar{\chi}_k\sqrt{\bar{\chi}_k^2+4}}{2} \quad (20a)
$$

$$
v_k=\frac{\sqrt{\tau_k(1+\bar{\lambda}_k)}\bar{\boldsymbol{h}}_{\text{CU},k}^H\bar{\boldsymbol{w}}_k}{\bar{\boldsymbol{h}}_{\text{CU},k}^H(\bar{\boldsymbol{W}}\bar{\boldsymbol{W}}^H+\bar{\boldsymbol{R}}_0)\bar{\boldsymbol{h}}_{\text{CU},k}+\sigma_k^2}, \quad (20b)
$$

其中，$\bar{\chi}_k=\frac{1}{\sqrt{\tau_k}}\Re\left\{\bar{v}_k^*\bar{\boldsymbol{h}}^H{}_{\text{通信用户 }k}\bar{\boldsymbol{w}}_k\right\}$，且 $\bar{\boldsymbol{h}}_{\text{CU},k}=\boldsymbol{G}^H\quad\boldsymbol{h}_k^{\text{R-CU}}\ \bar{\boldsymbol{\theta}}+\boldsymbol{h}_k^{\text{BS-cu}}=$ diag( ) 表示上一次迭代中基站到通信用户 k 的等效信道。

C. 传输设计优化$(\boldsymbol{W},\boldsymbol{R}_0)$

给定 $\bar{\boldsymbol{\lambda}},\bar{\boldsymbol{v}},\bar{\boldsymbol{\theta}}$ 后，接下来针对 K 个通信用户和 L 个目标优化基站发射设计变量 $(\boldsymbol{W},\boldsymbol{R}_0)$。具体而言，从$f(\boldsymbol{\lambda},\boldsymbol{v},\boldsymbol{W},\boldsymbol{R}_0,\boldsymbol{\theta})$中去除与 $\boldsymbol{W}$ 和 $\boldsymbol{R}_0$ 无关的常数项后，$(\boldsymbol{W},\boldsymbol{R}_0)$ 的优化可表示为以下最小化问题

$$
\begin{aligned}
&(\hat{\boldsymbol{W}},\hat{\boldsymbol{R}}_0)=\arg\min_{\boldsymbol{W},\boldsymbol{R}_0} g(\boldsymbol{W},\boldsymbol{R}_0) && \text{(21a)}\\
&\text{s.t. tr}(\boldsymbol{W}^H\boldsymbol{W})+\text{tr}(\boldsymbol{R}_0)\le P_0 && \text{(21b)}\\
&\ \bar{\boldsymbol{h}}_{\text{TGT},l}^H(\boldsymbol{W}\boldsymbol{W}^H+\boldsymbol{R}_0)\bar{\boldsymbol{h}}_{\text{TGT},l}\ge\rho_{th},\forall l\in\mathcal{L}, && \text{(21c)}
\end{aligned}
$$

其中 $\bar{\boldsymbol{h}}_{\text{TGT},\ l}\triangleq\boldsymbol{G}^H\text{diag}(\boldsymbol{h}_l^{\text{R-TGT}})\,\bar{\boldsymbol{\theta}}$，且函数 g为

$$
\begin{aligned}
g(\boldsymbol{W},\boldsymbol{R}_0)=&\sum_{k=1}^{K}|\bar{v}_k|^2\bar{\boldsymbol{h}}_{\text{CU},k}^H(\boldsymbol{W}\boldsymbol{W}^H+\boldsymbol{R}_0)\bar{\boldsymbol{h}}_{\text{CU},k}\\
&-\sum_{k=1}^{K}2\sqrt{\tau_k(1+\bar{\lambda}_k)}\Re\{\bar{v}_k^*\bar{\boldsymbol{h}}_{\text{CU},k}^H\boldsymbol{w}_k\}. \quad (22)
\end{aligned}
$$

需要注意的是，由于（21c）中的约束具有非凸性，问题（21）是一个非凸优化问题。因此，我们采用经典的连续凸近似（SCA）技术，对约束（21c）进行一阶线性化，得到

$$
\begin{aligned}
&2\Re\{\boldsymbol{h}_{\text{TGT},l}^H\boldsymbol{W}\bar{\boldsymbol{W}}^H\bar{\boldsymbol{h}}_{\text{TGT},l}\}+\bar{\boldsymbol{h}}_{\text{TGT},l}^H\boldsymbol{R}_0\bar{\boldsymbol{h}}_{\text{TGT},l}^H\\
&\ge\rho_{\text{th}}+\bar{\boldsymbol{h}}_{\text{TGT},l}^H\bar{\boldsymbol{W}}\bar{\boldsymbol{W}}^H\bar{\boldsymbol{h}}_{\text{TGT},l},\forall l\in\mathcal{L}. \quad (23)
\end{aligned}
$$

这样，问题（21）可以近似为一个凸二次约束二次规划（QCQP），即

$$\min_{\boldsymbol{W},\boldsymbol{R}_0} g(\boldsymbol{W},\boldsymbol{R}_0)+g_{\text{prox1}}(\boldsymbol{W})+g_{\text{prox2}}(\boldsymbol{R}_0) \tag{24a}$$

$$\text{s.t. (21b), (23),} \tag{24b}$$

其中，g_{prox1} — — g_{prox2} = $\frac{C_2}{2}\|\boldsymbol{R}_0-\boldsymbol{R}_0\|_F^2$ $(\boldsymbol{W})$ $=\frac{C_1}{2}\sum_{k=1}^{K}\|\boldsymbol{w}_k-\boldsymbol{w}_k\|^2$ 和 $(\boldsymbol{R}_0)$ 分别表示变量 $\boldsymbol{W}$ 和 $\boldsymbol{R}_0$ 对应的近端正则化项，[32],$C_1>0$ 和 $C_2>0$ 表示近端正则化参数。请注意，这些二次项 g_{prox1} 和 g_{prox2}用于控制变量更新步长，以防止振荡。问题 (24) 是一个严格凸问题。因此，可以使用标准凸优化求解器（例如 CVX工具箱 [33]）高效求得 (24) 的最优解 ($\hat{}\boldsymbol{W}$ 和 $\hat{}$ $\boldsymbol{R}_0$)。

D. 超大规模可重构智能表面反射系数向量的优化 $\boldsymbol{\theta}$

现在，给定 $\boldsymbol{\lambda},\bar{\boldsymbol{v}},\boldsymbol{W},\boldsymbol{R}_0$，我们对超大规模可重构智能表面反射系数向量 $\boldsymbol{\theta}$进行优化。为方便记号，定义 $\boldsymbol{H}_{RT,l}=\text{diag}((\boldsymbol{h}_l^{\text{R-TGT}})^H)\boldsymbol{G}\in\mathbb{C}^{N\times M}$、 $\forall l\in\mathcal{L}$和 $\boldsymbol{H}_{RC,k}=\text{diag}((\boldsymbol{h}_k^{\text{R-CU}})^H)\boldsymbol{G}\in\mathbb{C}^{N\times M}$、 $\forall k\in\mathcal{K}$。去掉 $f(\boldsymbol{\lambda},\boldsymbol{v},\boldsymbol{W},\boldsymbol{R}_0,\boldsymbol{\theta})$ 中与 $\boldsymbol{\theta}$ 无关的常数项后，对$\boldsymbol{\theta}$ 的优化可表述为以下最小化问题:

$$\hat{\boldsymbol{\theta}}=\arg\min_{\boldsymbol{\theta}}\boldsymbol{\theta}^H\boldsymbol{B}\boldsymbol{\theta}-2\Re\{\boldsymbol{\theta}^H\boldsymbol{\eta}\} \tag{25a}$$

$$\text{s.t. } |\Phi_{n_x,n_z}|=1,\forall n_x\in\mathcal{N}_x,n_z\in\mathcal{N}_z \tag{25b}$$

$$\boldsymbol{\theta}^H\boldsymbol{A}_l\boldsymbol{\theta}\geq\rho_{th},\forall l\in\mathcal{L}, \tag{25c}$$

其中， $\boldsymbol{A}_l\succeq 0$、 $\boldsymbol{B}\succeq 0$和 $\boldsymbol{\eta}$ 分别表示为

$$\boldsymbol{A}_l=\boldsymbol{H}_{RT,l}\boldsymbol{Q}\boldsymbol{H}_{RT,l}^H,\forall l\in\mathcal{L}$$

$$\boldsymbol{B}=\sum_{k=1}^{K}|\bar{v}_k|^2\boldsymbol{H}_{RC,k}\boldsymbol{Q}\boldsymbol{H}_{RC,k}^H$$

$$\boldsymbol{\eta}=\sum_{k=1}^{K}\left(\sqrt{\tau_k(1+\bar{\lambda}_k)}\bar{v}_k^*\boldsymbol{H}_{RC,k}\bar{\boldsymbol{w}}_k-|\bar{v}_k|^2\boldsymbol{H}_{RC,k}\boldsymbol{Q}\boldsymbol{h}_k^{\text{R-CU}}\right)$$

其中 $\boldsymbol{Q}=\bar{\boldsymbol{W}}\bar{\boldsymbol{W}}^H+\bar{\boldsymbol{R}}_0$。

注意，(25b) 中对超大规模可重构智能表面相移施加的单位模约束为 $\boldsymbol{\theta}$定义了一个非凸集合，并且(25c) 左侧每个凸二次函数的超水平集也不是凸集合。因此，问题 (25) 是一个非凸优化问题，难以高效地获得其全局解。

尽管如此，由于单位模约束$|\Phi_{n_x,\ n_z}|=1,\ \forall n_x\in\mathcal{N}_x$, $n_z\in\mathcal{N}_z$，可以证明，问题 (25) 的可行变量$\boldsymbol{\theta}$ 位于一个黎曼流形上。接下来，我们采用一种基于惩罚的黎曼流形优化 算法[34]来高效求解问题 (25)。

令 $\mathcal{M}_R$ 表示包含问题 (25) 的可行 $\boldsymbol{\theta}$ 的黎曼流形。于是有

$$\mathcal{M}_R\triangleq\{\boldsymbol{\theta}\in\mathbb{C}^N:\boldsymbol{\theta}\odot\boldsymbol{\theta}^*=\mathbf{1}_N\}, \tag{26}$$

其中， $\odot$ 表示哈达玛积。基于黎曼流形优化框架，感知波束图增益约束 (25c) 被转化为目标函数中的二次惩罚项。因此，问题 (25) 被重新表述为

$$\hat{\boldsymbol{\theta}}=\arg\min_{\boldsymbol{\theta}\in\mathcal{M}_R} f_R(\boldsymbol{\theta}), \tag{27}$$

其中，目标函数定义为

$$f_R(\boldsymbol{\theta})=\boldsymbol{\theta}^H\boldsymbol{B}\boldsymbol{\theta}-2\Re\{\boldsymbol{\theta}^H\boldsymbol{\eta}\}+f_{\text{pen}}(\boldsymbol{\theta}) \tag{28}$$

其中， $f_{\text{pen}}(\boldsymbol{\theta})$ = $\frac{C}{2}\sum_{l=1}^{L}((\rho_{th}-\boldsymbol{\theta}^H\boldsymbol{A}_l\boldsymbol{\theta})^+)^2$ 为二次惩罚项， $C>0$ 表示预设的惩罚因子。

对于问题 (27)，我们采用黎曼共轭梯度（RCG）算法 [35]–[37], ，利用流形 $\mathcal{M}_R$ 的几何特性，通过在切空间上进行梯度下降并执行回缩操作，迭代更新超大规模可重构智能表面反射系数向量 $\boldsymbol{\theta}$ 。具体而言，RCG算法在每次迭代中包含以下三个关键步骤。

- 步骤 *1*—求取黎曼梯度： $f_R(\boldsymbol{\theta})$关于 $\boldsymbol{\theta}$的黎曼梯度记为 $\text{grad}f_R(\boldsymbol{\theta})$，其定义为将欧几里得梯度 $\nabla f_R(\boldsymbol{\theta})$正交投影到复圆上。随后，每次迭代中的黎曼梯度 $\text{grad}f_R(\boldsymbol{\theta})$按如下方式计算:

$$\text{grad}f_R(\boldsymbol{\theta})=\nabla f_R(\boldsymbol{\theta})-\Re\{\nabla f_R(\boldsymbol{\theta})\odot\boldsymbol{\theta}^*\}\odot\boldsymbol{\theta}, \tag{29}$$

其中，欧几里得梯度为 $\nabla f_R(\boldsymbol{\theta})$ = $\boldsymbol{B}\boldsymbol{\theta}-\boldsymbol{\eta}-C\sum_{l=1}^{L}\rho_{th}-\boldsymbol{\theta}^H\boldsymbol{A}_l\boldsymbol{\theta}+\boldsymbol{A}_l\boldsymbol{\theta}$ ( )。

- 步骤 *2*—分别确定搜索步长 τ 和上一次迭代的搜索方向。在每次迭代中，确定与 $\text{grad}f_R(\boldsymbol{\theta})$ 共轭的切向量作为搜索方向 $\boldsymbol{d}$。相应地，可得

$$\boldsymbol{d}=-\text{grad}f_R(\boldsymbol{\theta})+C_0(\bar{\boldsymbol{d}}-\Re\{\boldsymbol{d}\odot\boldsymbol{\theta}^*\}\odot\boldsymbol{\theta}), \tag{30}$$

其中， C_0 表示梯度更新参数。

- 步骤 *3*——回缩：注意，切向量需要投影回复圆流形。相应地，在一次迭代中，超大规模可重构智能表面反射系数向量 $\boldsymbol{\theta}$ 更新为

$$[\boldsymbol{\theta}]_n=\frac{[\boldsymbol{\theta}]_n+p[\boldsymbol{d}]_n}{|[\boldsymbol{\theta}]_n+p[\boldsymbol{d}]_n|},\ n=1,...,N, \tag{31}$$

其中， $p>0$ 表示 Armijo-Goldstein步长。

E. 所提算法与复杂度分析

算法1总结了完整的所提BCD流程。令 $\epsilon>0$ 为误差容限。优化变量按照 $\cdots\boldsymbol{\lambda},\boldsymbol{v},\boldsymbol{\theta},\boldsymbol{v},(\boldsymbol{W},\boldsymbol{R}_0)\ \boldsymbol{\lambda}\cdots$的顺序循环更新，直至目标函数收敛。下面讨论所提BCD的计算复杂度。

- 更新 $(\boldsymbol{\lambda},\boldsymbol{v})$: 用于更新 $\boldsymbol{\lambda}$ 和 $\boldsymbol{v}$ 的(20a)和(20b)中的闭式解分别如下所示，计算复杂度约为 $\mathcal{O}(KNM)$。

- 更新$(\boldsymbol{W},\boldsymbol{R}_0)$: 优化 $(\boldsymbol{W},\boldsymbol{R}_0)$ 的问题 (24) 是一个凸二次约束二次规划。若采用标准方法求解

算法1针对 (P1) 提出的基于块坐标下降的算法 1：**初始化**：初始化满足约束的 $(\boldsymbol{W}^{(0)}, \boldsymbol{R}_0^{(0)}, \boldsymbol{\theta}^{(0)})$ 和辅助变量 $(\boldsymbol{\lambda}^{(0)}, \boldsymbol{v}^{(0)})$，并设置迭代索引 $t = 0$。

2: **重复**

3: 设定 $t \leftarrow t + 1$.

4 l $\boldsymbol{\lambda}$ $\boldsymbol{v}$：步骤：

5 $\boldsymbol{\lambda}^{(t)}$ $\boldsymbol{v}^{(t)}$

更新辅助变量并：分别根据 (20a) 和 (20b) 中的闭式解更新和。 6: 步骤 *2*：更新超大规模可重构智能表面系数 $\boldsymbol{\theta}$ 7: 构造惩罚目标函数 $f_{\mathrm{R}}(\boldsymbol{\theta})$。 8: 使用 RCG算法更新 $\boldsymbol{\theta}^{(t)}$ 。 9: 步骤 *3*：更新发射波束成形 $(\boldsymbol{W}, \boldsymbol{R}_0)$ 10: 为 $(\boldsymbol{W}, \boldsymbol{R}_0)$ 构造凸子问题。 11: 基于 CVX工具箱求解 (24)，以更新 $\boldsymbol{W}^{(t)}$ 和 $\boldsymbol{R}_0^{(t)}$。 12: **直到**两次迭代之间的目标值之差小于容差水平 ϵ，或达到最大迭代次数 I_{max} 。

对于 CVX工具箱等凸求解器，复杂度约为 $\mathcal{O}(KM^3)$。

- 更新 $\boldsymbol{\theta}$：更新$\boldsymbol{\theta}$ 的计算复杂度主要由RCG算法决定，约为 $\mathcal{O}(I_{RCG}(K^2N^2 + LN^2))$，其中 I_{RCG} 为RCG算法所需的迭代次数。

因此，所提出的用于求解(P1)的BCD方法的总体复杂度约为 $\mathcal{O}(I_{\text{out}}(KNM + KM^2 + I_{RCG}(K^2N^2 + LN^2)))$，其中 I_{out} 表示迭代次数。

IV. 用于求解(P1)的基于GNN的解法

本节介绍用于表征所提出的XL-RIS辅助近场通感一体化系统的图神经网络模型，然后提出一种用于求解(P1)的基于GNN的解法，通过交换和更新嵌入在图神经网络模型中的特征信息，生成联合ISAC波束成形策略。

*A. GNN*基础

作为一类基于信息扩散机制的深度学习模型，图神经网络模型能够有效地从基于图的数据中提取关键特征。无向图由GNN单元集和边集组成，其中每个单元对应一个节点 [38]。图神经网络的输出基于单元状态生成。具体而言，图神经网络遵循邻域聚合方案，通过聚合并拼接其邻居节点的特征来计算节点特征向量 [39]。通常，GNN架构由三个功能模块组成：初始层、多个级联的节点更新层以及读出层。

考虑图 $\mathcal{G} = (\mathcal{V}_{\mathrm{g}}, \mathcal{E}_{\mathrm{g}})$，其中 $\mathcal{V}_{\mathrm{g}}$ 和 $\mathcal{E}_g$ 分别表示节点集（对应于超大规模可重构智能表面、通信用户和目标）以及刻画它们相互作用的边集（例如，信号/干扰信道链路）。通常，节点 $v \in \mathcal{V}_{\mathrm{g}}$ 以特征 $\boldsymbol{u}_v^{(0)}$初始化。按照

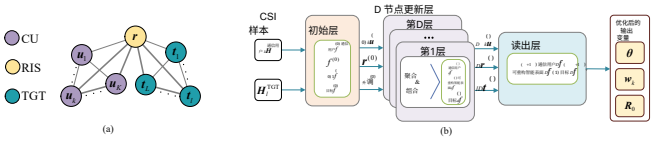

图2. (a) 超大规模可重构智能表面辅助近场通感一体化系统的图模型；(b) 所提出的图神经网络结构。

消息传递策略，节点表示通过聚合其邻居的表示进行迭代更新。经过 d_{g} 轮消息传递后，预计每个节点的感受野将扩展至其 d_{g}跳邻域。用 $\boldsymbol{u}_{\mathrm{g},v}^{(d_{\mathrm{g}})}$ 表示 GNN 第 d_{g} 层节点 v 的特征。特征向量更新规则为

$$\boldsymbol{u}_{\mathrm{g},v}^{(d_{\mathrm{g}})} = f_{\mathrm{comb}}^{(d_{\mathrm{g}})}\left(\boldsymbol{u}_{\mathrm{g},v}^{(d_{\mathrm{g}}-1)}, f_{\mathrm{agg}}^{(d_{\mathrm{g}})}\left(\{\boldsymbol{u}_{\mathrm{g},v'}^{(d_{\mathrm{g}}-1)}\}_{v' \in \mathcal{N}(v)}\right)\right), \quad (32)$$

其中，$\mathcal{N}(v)$表示 v的邻居节点集合，$f^{(d_g)\mathrm{agg}}$和 $f_{(d_g)\,\mathrm{comb}}$ 分别表示消息传递第 d_g轮中的聚合函数和组合函数。为简洁起见，在下文中我们将超大规模可重构智能表面节点简称为可重构智能表面节点。

B. 超大规模可重构智能表面辅助近场通感一体化的图模型

图2(a)展示了针对所研究的超大规模可重构智能表面辅助通感一体化系统建立的无权无向图模型（包括一个可重构智能表面节点、 K 个通信用户节点和 L 个目标节点）。令 $\boldsymbol{r}$、$\boldsymbol{u}_k$和 $\boldsymbol{t}_l$ 分别表示可重构智能表面、通信用户 k和目标 l的节点特征向量。需要注意的是，可重构智能表面节点特征向量 $\boldsymbol{r}$ 与 K 个通信用户节点和 L个目标节点相关联，以获取提供通信与感知服务所需的全部信息；通信用户节点与目标节点之间不存在边。由于干扰的存在，通信用户节点之间以及目标节点之间均存在连接边。因此，图表示中总共有 $K + L + \binom{K}{2} + \binom{L}{2} = {}^{K}(K+1)+L(L+1)\ 2$ 条边。

C. 所提出的图神经网络结构

在本小节中，我们针对超大规模可重构智能表面辅助的通感一体化系统提出了一种图神经网络结构，如图2(b)所示。该结构基于近场通感一体化的图模型，由一个初始层、若干个 D 更新层和一个读出层组成。基站发射波束成形变量（$\{\boldsymbol{w}_k\}_{k=1}^K$，$\boldsymbol{R}_0$）和超大规模可重构智能表面反射系数向量 $\boldsymbol{\theta}$ 均被视为所提出图神经网络结构的读出层输出。

1）初始层：图3展示了所提出的图神经网络初始层结构。分别用 $\boldsymbol{r}^{(0)}$、$\boldsymbol{u}_k^{(0)}$ 和 $\boldsymbol{t}_l^{(0)}$ 表示基站、通信用户 $k \in \mathcal{K}$ 和目标 $l \in \mathcal{L}$的初始节点特征向量。对于初始层，其输入是可重构智能表面辅助通感一体化时，基站到通信用户/目标的信道状态信息，即:

$$\boldsymbol{H}_k^{\mathrm{CU}} \triangleq \left[\boldsymbol{G}^H \mathrm{diag}(\boldsymbol{h}_k^{\text{R-CU}}), \boldsymbol{h}_k^{\text{BS-CU}}\right] \in \mathbb{C}^{M \times (N+1)} \quad (33a)$$

$$\boldsymbol{h}_{k,m}^{\mathrm{CU}} = (\boldsymbol{H}_k^{\mathrm{CU}}(m,:))^T \in \mathbb{C}^{(N+1)\times 1} \quad (33b)$$

$$\boldsymbol{H}_l^{\mathrm{TGT}} \triangleq \boldsymbol{G}^H \mathrm{diag}(\boldsymbol{h}_l^{\text{R-TGT}}) \in \mathbb{C}^{M \times N} \quad (33c)$$

$$\boldsymbol{h}_{l,m}^{\mathrm{TGT}} = (\boldsymbol{H}_l^{\mathrm{TGT}}(m,:))^T \in \mathbb{C}^{N\times 1}, \quad (33d)$$

其中 $k \in \mathcal{K}$、$m \in \mathcal{M}$ 和 $l \in \mathcal{L}$。

为捕捉近场信道状态信息中的复杂非线性相关性，函数 $f_{(0)0}$：$\mathbb{R}^{2(N+1)\times 1} \mapsto \mathbb{R}^{q/2\times 1}$ 和 $f_1^{(0)}$：$\mathbb{R}^{2N\times 1} \mapsto \mathbb{R}^{q/2\times 1}$ 被实现为两个层的全连接神经网络（FCNN）。具体而言，这些函数处理信道状态信息 $\{\boldsymbol{h}_{k,m}^{\mathrm{CU}}, \boldsymbol{h}_{l,m}^{\mathrm{TGT}}\}$，分别提取特征对（$k$，$m$）和（$l$，$m$）的特征。

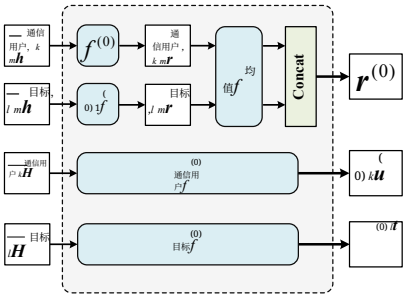

图3。初始层的结构。

将 ReLU$(x) = (x)^+$ 记为线性整流单元（ReLU）激活函数。从基站天线$m \in \mathcal{M}$ 到通信用户 $k \in \mathcal{K}$ 的特征向量表示为

$$\begin{aligned}\boldsymbol{r}_{k,m}^{\mathrm{CU}} &= f_0^{(0)}(\bar{\boldsymbol{h}}_{k,m}^{\mathrm{CU}}) \\ &= \boldsymbol{W}_{0,2}^{(0)}\left(\mathrm{ReLU}\left(\boldsymbol{W}_{0,1}^{(0)}\bar{\boldsymbol{h}}_{k,m}^{\mathrm{CU}} + \boldsymbol{b}_{0,1}^{(0)}\right)\right) + \boldsymbol{b}_{0,2}^{(0)}, \end{aligned} \quad (34)$$

其中，$\bar{\boldsymbol{h}}_{k,m}^{\mathrm{CU}}$、$_m = [(\Re\{\boldsymbol{h}_{k,m}^{\mathrm{CU}}\})^T$、$(\Im\{\boldsymbol{h}_{k,m}^{\mathrm{CU}}\})^T]^T \in \mathbb{R}^{2(N+1)\times 1}$；$\boldsymbol{W}_{(0)0}$、$_1 \in \mathbb{R}^{q\times 2(N+1)}$ 和 $\boldsymbol{W}_{(0)0}$、$_2 \in \mathbb{R}^{q/2\times q}$ 为 $f_{(0)0}$ 的权重矩阵；$\boldsymbol{b}_0^{(0)}$、$_1 \in \mathbb{R}^{q\times 1}$ 和 $\boldsymbol{b}_0^{(0)}$、$_2 \in \mathbb{R}^{q/2\times 1}$ 表示 $f_0^{(0)}$ 的偏置向量。来自基站天线$m \in \mathcal{M}$ 至目标 $l \in L$ 的特征向量表示为

$$\begin{aligned}\boldsymbol{r}_{l,m}^{\mathrm{TGT}} &= f_1^{(0)}(\bar{\boldsymbol{h}}_{l,m}^{\mathrm{TGT}}) \\ &= \boldsymbol{W}_{1,2}^{(0)}\left(\mathrm{ReLU}\left(\boldsymbol{W}_{1,1}^{(0)}\bar{\boldsymbol{h}}_{l,m}^{\mathrm{TGT}} + \boldsymbol{b}_{1,1}^{(0)}\right)\right) + \boldsymbol{b}_{1,2}^{(0)}, \end{aligned} \quad (35)$$

其中，$\bar{\boldsymbol{h}}_{l,m}^{\mathrm{TGT}}$、$_m = [(\Re\{\boldsymbol{h}_{l,m}^{\mathrm{TGT}}\})^T$、$(\Im\{\boldsymbol{h}_{l,m}^{\mathrm{TGT}}\})^T]^T \in \mathbb{R}^{2N\times 1}$；$\boldsymbol{W}_{(0)1}$、$_1 \in \mathbb{R}^{q\times 2N}$ 和 $\boldsymbol{W}_{(0)1}$、$_2 \in \mathbb{R}^{q/2\times q}$ 表示 $f_{(0)1}$ 的权重矩阵；$\boldsymbol{b}_1^{(0)}$、$_1 \in \mathbb{R}^{q\times 1}$、$\boldsymbol{b}_1^{(0)}$、$_2 \in \mathbb{R}^{q/2\times 1}$ 表示 $f_1^{(0)}$ 的偏置向量。

首先，利用得到的 $\{\boldsymbol{r}_{k,m}^{\mathrm{CU}}, \boldsymbol{r}_{l,m}^{\mathrm{TGT}}\}$，特征信息向量 $\boldsymbol{r}^{(0)}$ 通信用户 和 $\boldsymbol{r}^{(0)}$ 目标 分别表示为

$$\boldsymbol{r}_{\mathrm{CU}}^{(0)} = f_{\mathrm{mean}}(\{\boldsymbol{r}_{k,m}^{\mathrm{CU}}\}) = \frac{1}{KM}\sum_{k=1}^{K}\sum_{m=1}^{M}\boldsymbol{r}_{k,m}^{\mathrm{CU}} \quad (36a)$$

$$\boldsymbol{r}_{\mathrm{TGT}}^{(0)} = f_{\mathrm{mean}}(\{\boldsymbol{r}_{l,m}^{\mathrm{TGT}}\}) = \frac{1}{LM}\sum_{l=1}^{L}\sum_{m=1}^{M}\boldsymbol{r}_{l,m}^{\mathrm{TGT}}, \quad (36b)$$

其中，f_{mean} 表示算术平均函数，用于公平地获取信道状态信息，并保留图神经网络模型的置换不变性。

然后，通过拼接 $\boldsymbol{r}^{(0)}$ 通信用户 和 $\boldsymbol{r}^{(0)}$ 目标，得到 RIS节点的初始特征向量 $\boldsymbol{r}^{(0)} \in \mathbb{R}^{q\times 1}$，即：

$$\boldsymbol{r}^{(0)} = [(\boldsymbol{r}_{\mathrm{CU}}^{(0)})^T, (\boldsymbol{r}_{\mathrm{TGT}}^{(0)})^T]^T \in \mathbb{R}^{q\times 1}. \quad (37)$$

接下来，由通信用户对应的全连接神经网络 $f^{(0)}$ 通信用户 生成初始特征向量 $\boldsymbol{u}_k^{(0)} \in \mathbb{R}^{q\times 1}$，即：$\mathbb{R}^{2M(N+1)\times 1} \mapsto \mathbb{R}^{q\times 1}$

$$\begin{aligned}\boldsymbol{u}_k^{(0)} &= f_{\mathrm{CU}}^{(0)}(\bar{\boldsymbol{H}}_k^{\mathrm{CU}}) \\ &= \boldsymbol{W}_{\mathrm{CU},2}^{(0)}\left(\mathrm{ReLU}\left(\boldsymbol{W}_{\mathrm{CU},1}^{(0)}\bar{\boldsymbol{H}}_k^{\mathrm{CU}} + \boldsymbol{b}_{\mathrm{CU},1}^{(0)}\right)\right) + \boldsymbol{b}_{\mathrm{CU},2}^{(0)}, \end{aligned} \quad (38)$$

其中，$\bar{\boldsymbol{H}}_k^{\mathrm{CU}} = [\Re\{\boldsymbol{H}_k^{\mathrm{CU}}\}^T \quad \Im\{\boldsymbol{H}_k^{\mathrm{CU}}\}^T]^T \in \mathbb{R}^{2M(N+1)\times 1}$，$\boldsymbol{W}^{0}$ vec( ),vec( ) ,() 通信用户 $_1 \in \mathbb{R}^{2q\times 2M(N+1)}$ 和 () 通信用户 $_2 \in \mathbb{R}^{q\times 2q}$ 为权重矩阵，$\boldsymbol{b}^{(0)}$ 通信用户 $_1 \in \mathbb{R}^{2q\times 1}$ 和 $\boldsymbol{b}^{(0)}$ 通信用户 $_2 \in \mathbb{R}^{q\times 1}$ 表示 $f^{(0)}$ 通信用户 的偏置向量。

类似地，TGT $l \in \mathcal{L}$ 的初始特征向量 $\boldsymbol{t}_l^{(0)} \in \mathbb{R}^{q\times 1}$ 由全连接神经网络 $f^{(0)}$ 目标 生成：$\mathbb{R}^{2MN\times 1} \mapsto \mathbb{R}^{q\times 1}$。因此，我们有

$$\begin{aligned}\boldsymbol{t}_l^{(0)} &= f_{\mathrm{TGT}}^{(0)}(\bar{\boldsymbol{H}}_l^{\mathrm{TGT}}) \\ &= \boldsymbol{W}_{\mathrm{TGT},2}^{(0)}\left(\mathrm{ReLU}\left(\boldsymbol{W}_{\mathrm{TGT},1}^{(0)}\bar{\boldsymbol{H}}_l^{\mathrm{TGT}} + \boldsymbol{b}_{\mathrm{TGT},1}^{(0)}\right)\right) + \boldsymbol{b}_{\mathrm{TGT},2}^{(0)}, \end{aligned} \quad (39)$$

其中，$\bar{\boldsymbol{H}}_l^{\mathrm{TGT}} = [\Re\{\boldsymbol{H}_l^{\mathrm{TGT}}\}^T \quad \Im\{\boldsymbol{H}_l^{\mathrm{TGT}}\}^T]^T \in \mathbb{R}^{2MN\times 1}$，$\boldsymbol{W}^{0}$ vec( )，vec( )；() 目标 $_1 \in \mathbb{R}^{2q\times 2MN}$ 和 () 目标 $_2 \in \mathbb{R}^{q\times 2q}$ 是权重矩阵，$\boldsymbol{b}^{(0)}$ 目标 $_1 \in \mathbb{R}^{2q\times 1}$ 和 $\boldsymbol{b}^{(0)}$ 目标 $_2 \in \mathbb{R}^{q\times 1}$ 表示 $f^{(0)}$ 目标 的偏置向量。

2）节点更新层：在图4所示的图神经网络模型的节点更新层中，需要在每个节点更新层中，通过聚合并结合邻居的信息，迭代更新每个节点的特征向量。将 $\boldsymbol{r}^{(d)} \in \mathbb{R}^{(d+1)q\times 1}$、$\boldsymbol{u}_k^{(d)} \in \mathbb{R}^{(d+1)q\times 1}$ 和 $\boldsymbol{t}_l^{(d)} \in \mathbb{R}^{(d+1)q\times 1}$ 分别表示在第 d 个节点更新层更新后的可重构智能表面、通信用户 $k \in \mathcal{K}$ 和目标 $l \in \mathcal{L}$ 的特征向量，其中 $d = 1, \ldots\ldots, D$。我们有

$$\boldsymbol{r}^{(d)} = [(f_{\mathrm{RIS}}^{(d)}(\boldsymbol{r}^{(d-1)}, \boldsymbol{\varphi}_{\mathrm{CU}}^{(d)}, \boldsymbol{\varphi}_{\mathrm{TGT}}^{(d)}))^T, (\boldsymbol{r}^{(d-1)})^T]^T, \quad (40)$$

其中 $\boldsymbol{\varphi}^{(d)}$ 通信用户 $= \frac{1}{K}\sum_{k=1}^{K}\boldsymbol{u}_k^{(d-1)}$、$\boldsymbol{\varphi}^{(d)}$ 目标 $= \frac{1}{L}\sum_{l=1}^{L}\boldsymbol{t}_l^{(d-1)}$ 表示逐元素算术平均运算，且 $f^{(d)}$ 可重构智能表面：$\mathbb{R}^{dq\times dq\times dq} \mapsto \mathbb{R}^{q\times 1}$ 是 $\boldsymbol{r}^{(d)}$ 在第 d 个节点更新层的全连接神经网络生成函数。相应地，我们有

$$\begin{aligned} f_{\mathrm{RIS}}^{(d)}(\boldsymbol{r}^{(d-1)}, \boldsymbol{\varphi}_{\mathrm{CU}}^{(d)}, \boldsymbol{\varphi}_{\mathrm{TGT}}^{(d)}) = \boldsymbol{W}_{\mathrm{RIS},2}^{(d)}\Big(\mathrm{ReLU}\Big(\boldsymbol{W}_{\mathrm{RIS},1}^{(d)}\bar{\boldsymbol{r}}^{(d-1)} \\ + \boldsymbol{b}_{\mathrm{RIS},1}^{(d)}\Big)\Big) + \boldsymbol{b}_{\mathrm{RIS},2}^{(d)}, \end{aligned} \quad (41)$$

其中 $\bar{\boldsymbol{r}}^{(d-1)} = [(\boldsymbol{r}^{(d-1)})^T, (\boldsymbol{\varphi}^{(d)}$ 通信用户 $)^T, (\boldsymbol{\varphi}^{(d)}$ 目标$)^T]^T \in \mathbb{R}^{3dq\times 1}$；$\boldsymbol{W}_{(d)}$ 可重构智能表面 $_1 \in \mathbb{R}^{q\times 3dq}$ 和 $\boldsymbol{W}_{(d)}$ 可重构智能表面 $_2 \in \mathbb{R}^{q\times q}$ 是权重矩阵；$\boldsymbol{b}^{(d)}$ 可重构智能表面 $_1 \in \mathbb{R}^{q\times 1}$ 和 $\boldsymbol{b}^{(d)}$ 可重构智能表面 $_2 \in \mathbb{R}^{q\times 1}$ 表示 $f^{(d)}$ 可重构智能表面 的偏置向量。

记 $f^{(d)}$ 通信用户：$\mathbb{R}^{dq\times dq\times dq} \mapsto \mathbb{R}^{q\times 1}$ 以及 $f_{(d)}$ 目标：$\mathbb{R}^{dq\times dq\times dq} \mapsto \mathbb{R}^{q\times 1}$ 分别表示用于生成第 d 层通信用户 $k \in \mathcal{K}$ 和目标 $l \in \mathcal{L}$ 的 $\boldsymbol{u}_k^{(d)}$ 和 $\boldsymbol{t}_l^{(d)}$ 的全连接神经网络，其中 $d = 1, \ldots, D$。由此可得

$$\boldsymbol{u}_k^{(d)} = [(f_{\mathrm{CU}}^{(d)}(\boldsymbol{u}_k^{(d-1)}, \boldsymbol{\varphi}_{\mathrm{CU},k}^{(d)}, \boldsymbol{r}^{(d-1)}))^T, (\boldsymbol{u}_k^{(d-1)})^T]^T \quad (42a)$$

$$\boldsymbol{t}_l^{(d)} = [(f_{\mathrm{TGT}}^{(d)}(\boldsymbol{t}_l^{(d-1)}, \boldsymbol{\varphi}_{\mathrm{TGT},l}^{(d)}, \boldsymbol{r}^{(d-1)}))^T, (\boldsymbol{t}_l^{(d-1)})^T]^T, \quad (42b)$$

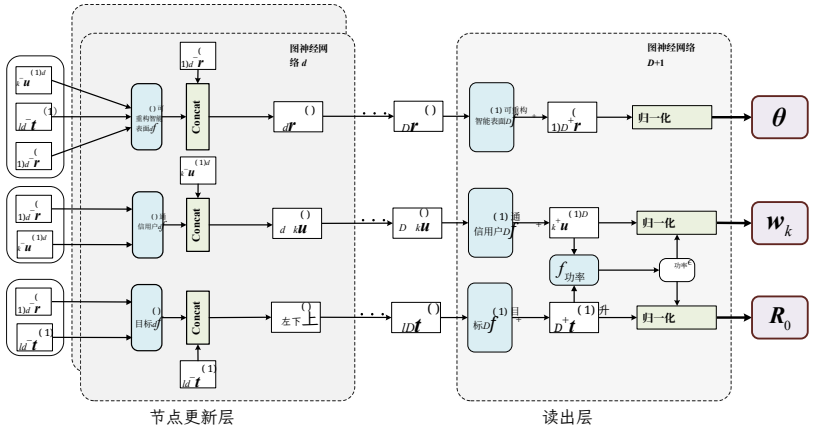

图4. 第 d个节点更新层的结构，后接一个读出层。

其中 $k \in \mathcal{K}$、 $l \in L$ 和 $d = 1$、.....、 D。函数 $f_{(d)\text{通信用户}}$ 和 $f^{(d)}_{\text{目标}}$ 定义如下:

$$f_{\text{CU}}^{(d)}(\boldsymbol{u}_k^{(d-1)}, \boldsymbol{\varphi}_{\text{CU},k}^{(d)}, \boldsymbol{r}^{(d-1)}) = \boldsymbol{W}_{\text{CU},2}^{(d)} \left(\text{ReLU} \left(\boldsymbol{W}_{\text{CU},1}^{(d)} \bar{\boldsymbol{u}}_k^{(d-1)} + \boldsymbol{b}_{\text{CU},1}^{(d)} \right) \right) + \boldsymbol{b}_{\text{CU},2}^{(d)} \quad (43a)$$

$$f_{\text{TGT}}^{(d)}(\boldsymbol{t}_l^{(d-1)}, \boldsymbol{\varphi}_{\text{TGT},l}^{(d)}, \boldsymbol{r}^{(d-1)}) = \boldsymbol{W}_{\text{TGT},2}^{(d)} \left(\text{ReLU} \left(\boldsymbol{W}_{\text{TGT},1}^{(d)} \bar{\boldsymbol{t}}_l^{(d-1)} + \boldsymbol{b}_{\text{CU},1}^{(d)} \right) \right) + \boldsymbol{b}_{\text{CU},2}^{(d)}, \quad (43b)$$

其中 $\bar{\boldsymbol{u}}_k^{(d-1)}$ 和 $\bar{\boldsymbol{t}}_l^{(d-1)}$ 是

$$\bar{\boldsymbol{u}}_k^{(d-1)} = [(\boldsymbol{u}_k^{(d-1)})^T, (\boldsymbol{\varphi}_{\text{CU},k}^{(d)})^T, (\boldsymbol{r}^{(d-1)})^T]^T \quad (44a)$$

$$\bar{\boldsymbol{t}}_l^{(d-1)} = [(\boldsymbol{t}_l^{(d-1)})^T, (\boldsymbol{\varphi}_{\text{TGT},l}^{(d)})^T, (\boldsymbol{r}^{(d-1)})^T]^T, \quad (44b)$$

并且 $\boldsymbol{W}_{(d)\text{通信用户}\,1} \in \mathbb{R}^{q\times 3dq}$和 $\boldsymbol{W}_{(d)\text{通信用户}\,2} \in \mathbb{R}^{q\times q}$是 $f_{(d)}$ 通信用户的权重矩阵； $\boldsymbol{W}_{(d)\text{目标}\,1} \in \mathbb{R}^{q\times 3dq}$和 $\boldsymbol{W}_{(d)\text{目标}\,2} \in \mathbb{R}^{q\times q}$表示 $f^{(d)}$目标的权重矩阵； $\boldsymbol{b}^{(d)}$通信用户 $_1 \in \mathbb{R}^{q\times 1}$和 $\boldsymbol{b}^{(d)}$通信用户 $_2 \in \mathbb{R}^{q\times 1}$表示 $f_{(d)}$ 通信用户的偏置向量； $\boldsymbol{b}^{(d)}$目标 $_1 \in \mathbb{R}^{q\times 1}$和 $\boldsymbol{b}^{(d)}$目标 $_2 \in \mathbb{R}^{q\times 1}$表示 $f_{(d)}$ 目标的偏置向量。

此外，我们有 $\boldsymbol{\varphi}^{(d)}_{\text{通信用户}\,k} = f_{\max}(\{\boldsymbol{u}_j^{(d-1)}\}_{j\neq k})$ 和 $\boldsymbol{\varphi}^{(d)}_{\text{目标}\,l} = f_{\max}(\{\boldsymbol{t}_j^{(d-1)}\}_{j\neq l})$，其中 $f_{\max}$ 表示逐元素最大池化函数。该函数在经验上表现良好，这与干扰主要由最强用户主导这一事实相符。因此，我们有

$$[\boldsymbol{\varphi}_{\text{CU},k}^{(d)}]_i = \max\{[\boldsymbol{u}_j^{(d-1)}]_i \mid j \in \mathcal{K} \setminus \{k\}\} \quad (45a)$$

$$[\boldsymbol{\varphi}_{\text{TGT},l}^{(d)}]_i = \max\{[\boldsymbol{t}_j^{(d-1)}]_i \mid j \in \mathcal{L} \setminus \{l\}\}, \quad (45b)$$

其中 $i = 1,..., dq$。

经过若干个 D 节点更新层后，我们得到图神经网络节点的最终特征向量 $\{\boldsymbol{r}^{(D)}, \boldsymbol{u}_k^{(D)}, \boldsymbol{t}_l^{(D)}\}$。

3) 读出层：图4展示了所提出的图神经网络模型的读出层。作为对节点最终特征向量进行线性化与归一化后的图神经网络读出层输出，基站通感一体化发射波束成形设计变量（$\{\boldsymbol{w}_k\}_{k=1}^K$， $\boldsymbol{R}_0$）以及超大规模可重构智能表面反射系数向量 $\boldsymbol{\theta}$ 的实部和虚部最终得以生成。

为便于记号表示，第（$D+1$）层用于表示读出层。

对于可重构智能表面节点，我们首先使用全连接神经网络 $f^{(D+1)}_{\text{可重构智能表面}}\,\mathbb{R}^{(D+1)q\times 1} \mapsto \mathbb{R}^{2N\times 1}$ 对 $\boldsymbol{r}^{(D)} \in \mathbb{R}^{2N\times 1}$进行线性化。因此，我们有

$$\boldsymbol{r}^{(D+1)} = f_{\text{RIS}}^{(D+1)}(\boldsymbol{r}^{(D)}) = \boldsymbol{W}_{\text{RIS},1}^{(D+1)} \boldsymbol{r}^{(D)} + \boldsymbol{b}_{\text{RIS},1}^{(D+1)}, \quad (46)$$

其中 $\boldsymbol{W}^{(D+1)}_{\text{可重构智能表面}\,1} \in \mathbb{R}^{2N\times(D+1)q}$和 $\boldsymbol{b}^{(D+1)}_{\text{可重构智能表面}\,1} \in \mathbb{R}^{2N\times 1}$分别表示 $f^{(D+1)}_{\text{可重构智能表面}}$的权重矩阵和偏置向量。

接下来，采用归一化操作来保证满足模值为一约束 (15c)，从而得到超大规模可重构智能表面反射系数向量 $\boldsymbol{\theta}$，即，

$$[\boldsymbol{\theta}]_n = \frac{[\boldsymbol{r}^{(D+1)}]_n}{\bar{r}_n} + j\frac{[\boldsymbol{r}^{(D+1)}]_{N+n}}{\bar{r}_n}, \; n = 1, ..., N, \quad (47)$$

其中 $\bar{r}_n = \sqrt{([\boldsymbol{r}^{(D+1)}]_n)^2 + ([\boldsymbol{r}^{(D+1)}]_{N+n})^2}$。给定 $\boldsymbol{\theta}$ 后，我们即可得到超大规模可重构智能表面反射系数矩阵 $\boldsymbol{\Phi}$。

为了在严格满足约束 (15b) 的同时，自适应地平衡通信与感知之间的基站发射功率分配，我们首先引入可学习的功率分配因子 $\epsilon_{\text{power}} \in (0, 1)$，并用函数 f_{power}：$\mathbb{R}^{(D+1)q\times(D+1)q} \mapsto \mathbb{R}^{2M\times 1}$ 表示。于是有

$$\epsilon_{\text{power}} = f_{\text{power}}(\boldsymbol{u}_k^{(D+1)}, \boldsymbol{t}^{(D+1)}) \quad (48a)$$

$$= \text{Sigmoid}\left(\boldsymbol{W}_{\text{power}}^T \boldsymbol{\varphi}_{\text{power}} + b_{\text{power}} \right), \quad (48b)$$

其中 $\boldsymbol{\varphi}_{\text{power}} = \frac{1}{K+1}\left(\sum_{k\in\mathcal{K}} \boldsymbol{u}_k^{(D+1)} + \boldsymbol{t}^{(D+1)} \right) \in \mathbb{R}^{2M\times 1}$; $\text{Sigmoid}(x) = \frac{1}{1+e^{-x}}$表示 Sigmoid 激活函数; $\boldsymbol{W}_{\text{power}} \in \mathbb{R}^{2M\times 1}$和 $b_{\text{power}} \in \mathbb{R}$ 是 f_{power} 中的两个功率分配参数。通信用户 $k \in \mathcal{K}$ 和目标 $l \in \mathcal{L}$ 在读出层的特征向量 $\boldsymbol{u}_k^{(D+1)} \in \mathbb{R}^{2M\times 1}$ 和 $\boldsymbol{t}^{(D+1)} \in \mathbb{R}^{2M\times 1}$ 由下式给出

$$\boldsymbol{u}_k^{(D+1)} = f_{\text{CU}}^{(D+1)}(\boldsymbol{u}_k^{(D)}) = \boldsymbol{W}_{\text{CU},1}^{(D+1)} \boldsymbol{u}_k^{(D)} + \boldsymbol{b}_{\text{CU},1}^{(D+1)} \quad (49a)$$

$$\boldsymbol{t}^{(D+1)} = f_{\text{TGT}}^{(D+1)}\left(\frac{1}{L}\sum_{l=1}^{L} \boldsymbol{t}_l^{(D)}\right) = \boldsymbol{W}_{\text{TGT},1}^{(D+1)}\left(\frac{1}{L}\sum_{l=1}^{L} \boldsymbol{t}_l^{(D)}\right) + \boldsymbol{b}_{\text{TGT},1}^{(D+1)}, \quad (49b)$$

其中 $\boldsymbol{W}^{(D+1)}{}_{\text{通信用户 }1} \in \mathbb{R}^{2M\times(D+1)q}$ 和 $\boldsymbol{b}^{(D+1)}{}_{\text{通信用户 }1} \in \mathbb{R}^{2M\times 1}$ 表示线性化函数 $f^{(D+1)}{}_{\text{通信用户}}$： $\mathbb{R}^{(D+1)q\times 1} \mapsto \mathbb{R}^{2M\times 1}$ 的权重矩阵和偏置向量。类似地，对于感知 L 目标，包含 L 个目标信息的特征向量 $\boldsymbol{t}^{(D+1)} \in \mathbb{R}^{2M\times 1}$ 由线性函数 $f^{(D+1)}{}_{\text{目标}}$： $\mathbb{R}^{(D+1)q\times 1} \mapsto \mathbb{R}^{2M\times 1}$ 生成，其中 $\boldsymbol{W}_{(D+1)\text{目标}}{}_{1} \in \mathbb{R}^{2M\times(D+1)q}$ 和 $\boldsymbol{b}^{(D+1)}{}_{\text{目标}}{}_{1} \in \mathbb{R}^{2M\times(D+1)q}$。

因此，每个通信用户 $k \in \mathcal{K}$ 对应的基站发射波束成形向量 $\boldsymbol{w}_k$ 可表示为

$$[\boldsymbol{w}_k]_m = \alpha_0^{\text{CU}}([\boldsymbol{u}_k^{(D+1)}]_m + j[\boldsymbol{u}_k^{(D+1)}]_{M+m}), \tag{50}$$

其中，$m \in \mathcal{M}$，且 $\alpha_0^{\text{CU}} = \frac{\sqrt{\epsilon_{\text{power}} P_0}}{\sqrt{\sum_{k=1}^{K} \left\|\boldsymbol{u}_k^{(D+1)}\right\|^2}}$ 表示功率缩放因子，$m \in \mathcal{M}$。有了 $\boldsymbol{w}_k$ 之后，我们便可以构造基站通信波束成形矩阵 $\boldsymbol{W}$。

为获得基站感知协方差矩阵 $\boldsymbol{R}_0$，我们有

$$[\boldsymbol{R}_0]_{m,m} = \alpha_0^{\text{TGT}} \left(([\boldsymbol{t}^{(D+1)}]_m)^2 + ([\boldsymbol{t}^{(D+1)}]_{M+m})^2\right), \tag{51}$$

其中，$m \in \mathcal{M}$，且 $\alpha_0^{\text{TGT}} = \frac{(1-\epsilon_{\text{power}})\, P_0}{\text{tr}(\boldsymbol{R}_0)}$ 表示功率缩放因子。请注意，在（50）和（51）中，归一化确保 $\text{tr}(\boldsymbol{W}^H\boldsymbol{W}) = \epsilon_{\text{power}} P_0$ 且 $\text{tr}(\boldsymbol{R}_0) = (1-\epsilon_{\text{power}})P_0$，从而满足基站发射功率约束（15b）。

*D. GNN*训练过程与分析

将 K 个通信用户的加权和速率的负值与针对 L 个目标的感知波束图惩罚项之和视为损失函数 f_{loss}。损失函数表示为

$$f_{loss}(\boldsymbol{W}, \boldsymbol{R}_0, \boldsymbol{\theta}) = -\sum_{k=1}^{K} \tau_k \log_2(1+\gamma_k) + \beta \sum_{l=1}^{L} (\rho_{th} - \rho_l)^+,$$

其中，$\beta > 0$ 表示惩罚项 $\sum_{l=1}^{L} (\rho_{th} - \rho_l)^+$ 的参数。在 GNN 训练过程中，我们的目标是最小化损失函数 f_{loss}，从而在满足式（15d）中的感知约束的同时，最大化所有通信用户可实现的加权和速率。

随后，采用该损失函数的无监督训练流程如算法2所示，其中 E、B 和 B_{size} 分别表示训练数据集 $\mathcal{D}$ 中的训练轮次数、批次数和批量大小；ω 和 Θ_{GNN} 分别表示学习率和所提出的图神经网络中的参数。

所提出的基于图神经网络的方法的计算复杂度分析如下，其主要由特征初始化、节点更新和变量读出决定。

- 特征初始化：信道矩阵 $\boldsymbol{H}_{\text{通信用户}}$ $\mathbb{C}^{M\times N+1}$ $\forall k \in \mathcal{K}$ $\boldsymbol{H}_l \in \mathbb{C}^{M\times N}$ $\forall l \in \mathcal{L}$ $^{k} \in$ ()、以及目标、被映射到维度为 q 的特征空间中，映射由全连接神经网络完成。其复杂度为 $\mathcal{O}((K+L)MNq)$。
- 节点更新：在 D 层中的每一层，聚合和更新操作都涉及特征维度为 q 的矩阵乘法。更新所有节点的复杂度为 $\mathcal{O}(D(K+L)q^2)$。
- 变量读出：读出层中的变换将特征映射回优化变量，其复杂度为 $\mathcal{O}(K(M+N)q)$。

算法2 基于图神经网络的（P1）无监督训练流程 要求：训练数据集 $\mathcal{D}$ ，包含信道状态信息样本$\{\boldsymbol{H}_k^{\text{CU}}, \boldsymbol{H}_l^{\text{TGT}}\}$；批量大小 B；训练轮次数 E；学习率 ω。确保：优化后的图神经网络参数 Θ_{GNN}（权重和偏置），以获得最优的 $\boldsymbol{\theta}$、$(\boldsymbol{W}, \boldsymbol{R}_0)$ 1：随机初始化图神经网络参数 Θ_{GNN}。2：对于训练轮次 $e = 1$，...，E，执行 3：对于批次 $b = 1$，...，B，执行 4：步骤1：在初始层和 D 节点更新层中进行初始化和更新 5：将一批 B_{size} 信道状态信息样本输入图神经网络，得到初始特征 $\boldsymbol{r}^{(0)}$ $\boldsymbol{u}_k^{(0)}$ $\boldsymbol{t}_l^{(0)}$，并且：6 $t^{(D)}$ 通过 D节点更新层，获得节点特征 $u_k^{(D)}$ 和 7：步骤2：在读出层中恢复变量 8：通过（47）恢复超大规模可重构智能表面的反射系数 $\boldsymbol{\theta}$，并进行单位模归一化。9：通过（48）计算功率分配因子 ϵ_{power}。10：通过（50）恢复 $\boldsymbol{w}_k$，并进行功率缩放。11：通过（51）恢复感知协方差矩阵 $\boldsymbol{R}_0$，并进行功率缩放。12：步骤3：损失计算 13：计算每个通信用户 $k \in \mathcal{K}$ 的信干噪比 γ_k 以及每个目标 $l \in \mathcal{L}$的感知增益 ρ_l，并计算损失函数 f_{loss}。14：步骤4：反向传播 15：计算 f_{loss}的梯度 $\nabla_{\Theta_{\text{GNN}}} f_{loss}$。16：使用 Adam 优化器更新图神经网络参数 Θ_{GNN}：$\Theta_{\text{GNN}} \leftarrow \Theta_{\text{GNN}} - \omega \nabla_{\Theta_{\text{GNN}}} f_{loss}$。17：结束循环 18：结束循环 19：返回训练后的图神经网络模型参数 Θ_{GNN}。

,

V. 数值结果

本节给出数值结果，以评估所提出的图神经网络模型的性能。我们基于多个指标介绍了所提出图神经网络的评估方法，涵盖四个方面：计算效率、可行性、鲁棒性和泛化能力。

A. 仿真设置

1）仿真场景：XL-RIS → 通信用户、基站 → XL- RIS、基站 → 通信用户以及 XL-RIS → 目标信道的路径损耗指数 α 分别设为 2.5、2.2、3.5 和 2.5。除非另有说明，我们设定 $(M, K, L) = (9, 4, 2)$，基站的发射功率预算和路径损耗系数分别设为 $P_0 = 1$W 和 $\rho_0 = \frac{\lambda}{4\pi}$。XL- RIS 单元数量设为 $N \in \{21^2, 23^2, 25^2, 27^2, 29^2, 31^2\}$，其中 $N_x = N_z$。基站发射信号的载波频率设为 $f_c = 28$ GHz（即波长为 $\lambda = 1.07$ cm）。通信用户 k 的感知波束图增益阈值和接收机噪声功率分别设为 $\rho_{th} = 10^4$ 和 $\sigma_k^2 = 1 \times 10^{-9}$。$\tau_k$ 设为 1。我们采用以米为单位的坐标设置，其中基站和 XL-RIS 的中心分别位于

(−4 m，2 m，0 m) 和 (0 m，0 m，0 m)。每个通信用户 $k \in \mathcal{K}$ 都随机分布在一个圆形区域 $\mathcal{C}_{\mathrm{CU}}$ 内，该区域以 (2 m，2 m，0 m) 为圆心，半径为 $R_{\mathrm{CU}} = 1\,\mathrm{m}$；每个目标 $l \in \mathcal{L}$ 都随机分布在一个圆形区域 $\mathcal{C}_{\mathrm{TGT}}$ 内，该区域以 (4 m，2 m，0 m) 为圆心，半径为 $R_{\mathrm{TGT}} = 1\,\mathrm{m}$。

2）实现细节：所提出的基于图神经网络的优化框架采用 Python 3.8.18 和配备 CUDA 11.7 的 PyTorch 1.13.1 实现，而所提出的 BCD 方法则针对 $(\boldsymbol{W},\ \boldsymbol{R}_0)$ 使用 CVX工具箱求解，并在 MATLAB R2024b 中使用 Manopt求解器求解 $\boldsymbol{\theta}$ 。在神经网络训练过程中，采用自适应矩估计（Adam）优化器，学习率设为 $\omega = 10^{-3}$。训练轮次、批次和批量大小分别设为 $E = 2000$、$B = 4$ 和 $B_{\mathrm{size}} = 128$。可学习的功率分配因子 ϵ_{power} 初始化为 0。7。所有数值仿真均在配备一块 NVIDIA RTX 3090图形处理器（24 GB 内存）的服务器上进行。

3）训练数据集：用于图神经网络训练过程的数据集 $\mathcal{D}$ 由无标签的信道状态信息样本构成，并依据几何关系（即 K 通信用户和 L 目标的位置）随机生成，以确保对多样化物理场景和信道实现的全面覆盖。

B. 所提出的图神经网络结构

图神经网络模型的参数设置为 $D \in \{3, 4\}$、$q = 128$ 和 $\beta = 200$。前两个参数旨在增强特征提取能力，而较大的正则化参数则确保满足约束 (15d)。此外，为评估所提出的图神经网络模型的鲁棒性，在训练过程中引入 $\boldsymbol{h}_k^{\text{R-CU}}$ 和 $\boldsymbol{h}_k^{\text{BS-CU}}$ 的不完美信道状态信息，并设置不完美参数 $\sigma_e^2 \in \{0.001, 0.01\}$ （$\sigma_e^2 = 0$ 表示完美信道状态信息）；计算和速率时则使用完美信道状态信息。

为了比较性能，我们考虑以下两种用于近场通感一体化系统设计的基准方案。

- **基于深度神经网络的设计方案：** 所提出的深度神经网络模型的层数和特征维度参数分别设置为 $D \in \{3, 4\}$ 和 $q = 128$，深度神经网络损失函数中的正则化参数设置为 $\beta = 200$。与图神经网络类似，该深度神经网络由一个初始层、D 个节点更新层和一个读出层组成，并通过读出层生成 $\{\boldsymbol{w}_k\}_{k=1}^K$、$\boldsymbol{R}_0$ 和 $\boldsymbol{\theta}$ 。
- **基于BCD的设计方案：** 对于 (P1) 的基于块坐标下降算法，参数 $(C_1,\ C_2,\ C)$ 设置为 (50，50，30)。最后，所提出的算法1中的容差水平设为$\epsilon = 10^{-6}$ 。最大迭代次数 I_{max} 设为30。

我们首先在图5中展示节点更新层数量 D 对加权和速率的影响，并比较所提出的图神经网络模型与深度神经网络及基于块坐标下降的基准方案在不同 N下的平均运行时间。如图所示，传统的基于块坐标下降的算法会产生显著的计算延迟。相比之下，基于学习的方法（图神经网络和深度神经网络）表现出卓越的

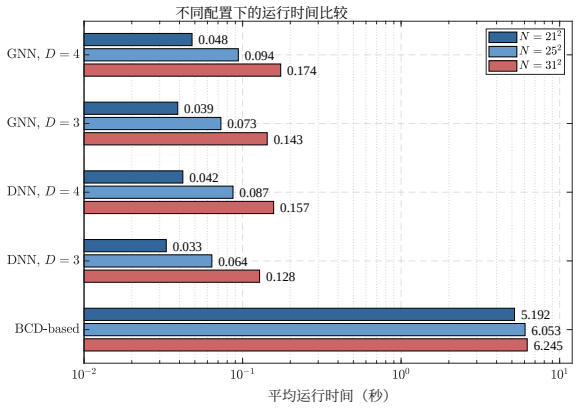

图5. 不同配置下的运行时间比较（单位：秒）

速度，凸显了其在实时通感一体化应用中的潜力。与深度神经网络相比，图神经网络的延迟略有增加，这是由于节点更新层中的消息传递机制所致；然而，该机制对于有效捕获通感一体化系统的空间拓扑至关重要。

表I 超大规模可重构智能表面反射单元数量下约束（16d）的满足率 N

(K, L) =(4,2)	$N = 21^2$	$N = 25^2$	$N = 31^2$
图神经网络，$D = 3, \sigma_e^2 = 0$	99.9%	99.9%	99.9%
图神经网络，$D = 3, \sigma_e^2 = 0.001$	99.5%	99.6%	99.7%
图神经网络，$D = 3,\ \sigma_e^2 = 0.01$	99.2%	99.3%	99.5%
图神经网络，$D = 4, \sigma_e^2 = 0.001$	98.9%	99.1%	99.1%
图神经网络，$D = 4, \sigma_e^2 = 0.01$	98.4%	98.7%	98.9%

表I展示了感知性能（即，在不同的 σ_e^2 and D 取值下，约束 (15d) 的满足率），这体现了图神经网络在通感一体化系统中的鲁棒性，即约束的满足率随 σ_e^2 取值的变化仅有轻微波动。此外，三层图神经网络的感知性能优于四层图神经网络。

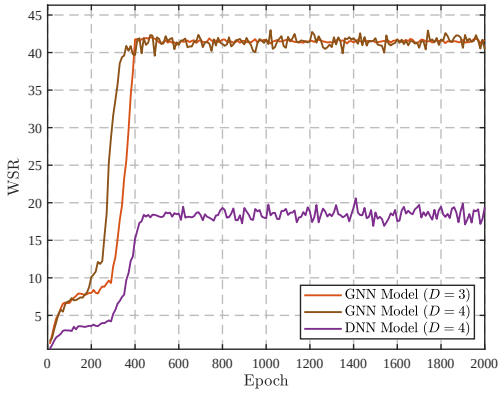

图 6. 在 $N = 21^2$ 条件下，所提出的图神经网络模型与深度神经网络在通感一体化系统中的收敛行为。

图 6 展示了所提出的图神经网络模型在采用不同数量的节点更新层时的收敛行为，D。可以观察到，采用 $D = 3$ 的图神经网络模型

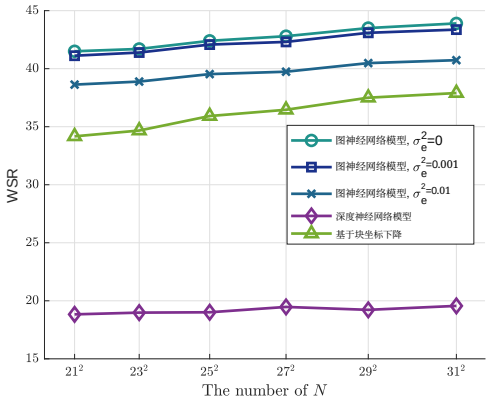

图7. WSR随 N数量的变化。

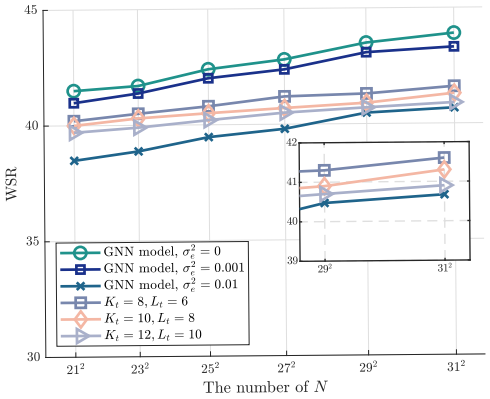

图9. 使用（K， L）$=(4,\ 2)$训练的所提出的图神经网络模型的泛化能力。

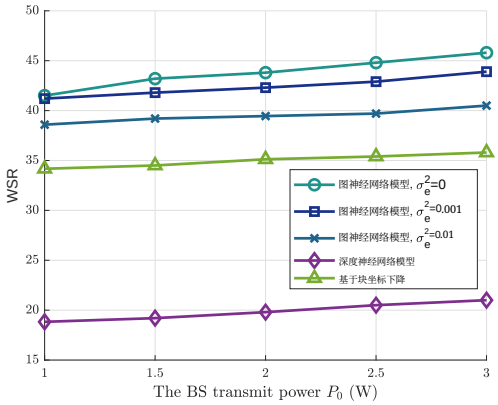

Fig. 8. WSR随基站发射功率 P_0 的变化（$N = 21^2$条件下）。

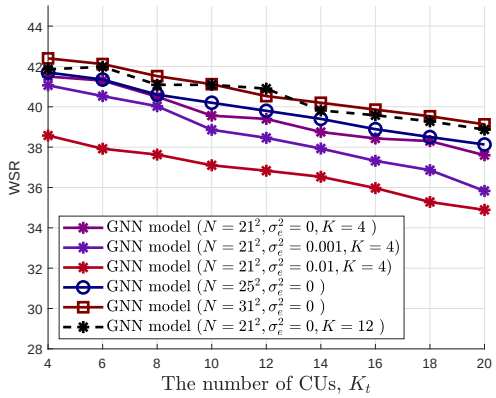

Fig. 10. 使用 K训练的所提出的图神经网络模型中，加权和速率随 K_t 数量的变化。

收敛后相比采用 $D = 4$ 的情况，能够获得相近且更稳定的加权和速率，这表明对于近场通感一体化中的聚合与组合， $D = 3$已足够，无需 $D = 4$。因此，与训练期间因图神经网络固有的过平滑而出现较高方差的四层图神经网络相比，三层图神经网络在特征提取能力和训练稳定性之间实现了平衡。因此，后续近场通感一体化仿真采用 $D = 3$ 。

图7展示了不同方案的通信性能对比。与基于块坐标下降的算法相比，所提出的图神经网络性能良好。深度神经网络的性能不如图神经网络和基于块坐标下降的算法，这是因为其在捕捉超大规模可重构智能表面、通信用户和目标之间复杂的拓扑依赖关系方面存在固有局限。与图神经网络不同，传统深度神经网络模型将信道状态信息视为无结构向量，因此无法充分利用高复杂度近场信道中的空间相关性，难以提取信道状态信息的特征，从而限制了其在近场通感一体化中的性能。此外，所提出的图神经网络在参数$\sigma_e^2 \in \{0.001, 0.01\}$不完美时仍表现出良好的通信性能鲁棒性，即不同$\sigma_e^2$取值下，WSR仅发生轻微变化。此外，图8展示了 P_0条件下的WSR性能。

由于图神经网络的置换不变性，我们接下来研究所提出的图神经网络模型在较小规模（K, L）$=(4,2)$下训练后的泛化能力，即在通信用户和目标数量分别大于 K 和 L（即 K_t 和L_t）时评估其性能。正如在图9中所预期的那样，所提出的基于图神经网络的设计方案在服务于不同通感一体化系统时展现出显著的灵活性，同时保持了良好的通信性能（而深度神经网络则需要重新训练）。从另一个角度，我们考虑以 $K \in \{4, 12\}$训练的图神经网络模型的泛化能力。图10展示了该图神经网络模型在 K_t取不同值时的通信性能。加权和速率随K_t的增大而下降，但仍保持良好的通信性能。对于以 $K = 12$训练的图神经网络模型，可以观察到关于加权和速率下降程度的一个关键洞见。具体而言，与以 $K = 4$训练的模型相比，以 $K = 12$训练的模型在 $K_t > 12$时加权和速率的下降明显更慢。这表明，选择通信用户数量适中的训练集能使图神经网络学习到更复杂的干扰管理模式，从而增强其鲁棒性，并减轻其泛化到另一近场通感一体化时的性能损失。

VI. 结论

本文研究了一个联合波束成形设计问题，旨在

最大化超大规模可重构智能表面辅助近场通感一体化系统的加权和速率，同时满足基站发射功率和感知波束图增益约束，以及超大规模可重构智能表面相移的模约束。我们利用分式规划重构和逐次凸近似方法，开发了一种基于块坐标下降的算法，以获得近似最优解。此外，为应对通信用户/目标移动性导致的动态拓扑和通感一体化中复杂耦合的近场信道模型，并克服传统深度学习方法的可扩展性问题，我们提出了一种用于近场通感一体化的基于图神经网络的联合波束成形设计框架。我们将近场通感一体化系统建模为由超大规模可重构智能表面/通信用户/目标节点组成的异构图，以有效利用近场信道状态信息。该框架采用消息传递机制，使直接连接的节点之间能够有效交换信息，并为每个超大规模可重构智能表面/通信用户/目标节点关联一个特征向量，该向量可有效映射为基站发射波束成形变量或超大规模可重构智能表面反射系数向量。数值结果表明，与现有基准方案相比，所提出的基于图神经网络的方案在效率、可行性、鲁棒性和泛化能力方面具有优势。

参考文献

[1] J. Chen、F. Wang和X. Wang，“面向可重构智能表面辅助近场通感一体化系统的基于图神经网络的波束成形设计”，载于*IEEE/CIC*国际通信大会论文集，中国上海，2025年8月，第1–6页。[2] S. Lu等，“通感一体化：最新进展与十个开放性挑战”，*IEEE*物联网期刊，第11卷，第11期，第19094–19120页，2024年6月。[3] N. Jabeen等，“通感一体化中的定位：综述”，*IEEE*物联网期刊，第12卷，第22期，第46526–46552页，2025年11月。[4] M. Nabati、T. Mahmoodi、S. Pal和S. Sarkar，“6G中原生感知的机遇与挑战：研究与标准化综述”，*IEEE*物联网期刊，第12卷，第24期，第52042–52066页，2025年12月。[5] W. Tang等，“基于可重构智能表面的无线通信：路径损耗建模与实验测量”，*IEEE*无线通信汇刊，第20卷，第1期，第421–439页，2021年1月。[6] D. Wang等，“面向6G系统的RIS赋能的通感一体化”，载于*IEEE*无线通信与网络会议（*WCNC*）论文集，2024年4月，第1–6页。[7] Q. Wu、S. Zhang、B. Zheng、C. You和R. Zhang，“智能反射面辅助无线通信：教程”，*IEEE*通信汇刊，第69卷，第5期，第3313–3351页，2021年5月。[8] F. Liu、Y. Cui、C. Masouros、J. Xu、T. X. Han、Y. C. Eldar等，“通感一体化：迈向面向6G及未来的双功能无线网络”，*IEEE*选定领域通信期刊，第40卷，第6期，第1728–1767页，2022年。[9] C. Liao、F. Wang和V. K. N. Lau，“杂波环境下IRS辅助通感一体化系统的优化后的设计”，*IEEE*通信汇刊，第71卷，第8期，第4721–4734页，2023年8月。[10] H. Guo等，“可重构智能表面辅助无线网络的加权和速率最大化”，*IEEE*无线通信汇刊，第70卷，第12期，第8313–8330页，2022年12月。[11] Y. Lin、F. Wang、X. Zhang、G. Han和V. K. N. Lau，“混合RIS辅助通感一体化系统的联合模式选择与波束成形设计”，*IEEE*无线通信快报，2025，第14卷，第6期，第1718–1722页，6月。[12] Z. Wang、X. Mu和Y. Liu，“近场通感一体化”，*IEEE*通信快报，第27卷，第8期，第2048–2052页，2023年8月。[13] T. Jiang、H. V. Cheng和W. Yu，“基于隐式信道估计的智能反射面反射与波束成形学习”，*IEEE*选定领域通信期刊，第39卷，第7期，第1931–1945页，2021年7月。[14] Z. Chang、H. Deng、L. You、G. Min、S. Garg和G. Kaddoum，“多无人机网络的轨迹设计与资源分配：深度强化学习方法”，*IEEE*网络科学与工程汇刊，第10卷，第5期，第2940–2951页，2023年9月/10月。

[15] C. Weng、Y. Chen、L. Zhu和Y. Wang，“可移动天线系统中基于学习的联合波束成形与天线移动设计”，IEEE无线通信快报，第13卷，第8期，第2120–2124页，2024年8月。[16] M. S. Abouamer和P. Mitran，“用于在可重构智能表面系统中学习自适应波束成形方案的超网络框架”，IEEE通信汇刊，第73卷，第12期，第13471–13485页，2025年12月。[17] F. Wang、S. Cai和V. K. N. Lau，“具有能量收集设备的移动边缘计算系统中去中心化深度神经网络任务划分与卸载控制”，IEEE信号处理选题期刊，第17卷，第1期，第173–188页，2023年1月。[18] C. Huang、R. Mo和C. Yuen，“利用深度强化学习的可重构智能表面辅助多用户MISO系统”，IEEE选定领域通信期刊，第38卷，第8期，第1839–1850页，2020年8月。[19] F. Wang、S. Cai和V. K. Lau，“多用户移动边缘计算系统中分布式深度神经网络计算的顺序卸载”，IEEE物联网期刊，第10卷，第20期，第18315–18329页，2023年10月。[20] S. Lyu、L. Peng和S. Y. Chang，“利用图神经网络研究大规模可重构智能表面辅助无线通信”，IEEE消费电子汇刊，2024年1月。[21] J. Guo、Y. Liu和A. Nallanathan，“用于学习夹持天线系统（PASS）中波束成形的图神经网络”，IEEE无线通信快报，第14卷，第12期，第3962–3966页，2025年12月。[22] Y. Li、Y. Lu、B. Ai、O. A. Dobre、Z. Ding和D. Niyato，“MU-MISO网络中面向和速率最大化的基于图神经网络的波束成形”，IEEE无线通信汇刊，第23卷，第8期，第9251–9264页，2024年8月。[23] X. Liu和C. Fischione，“利用图神经网络的多小区通感一体化协同波束成形”，IEEE无线通信汇刊，第25卷，第5876–5889页，2026年。[24] Y. Shen、J. Zhang、S. H. Song和K. B. Letaief，“面向无线通信的图神经网络：从理论到实践”，IEEE无线通信汇刊，第22卷，第5期，第3554–3569页，2023年5月。[25] B.-J. Chen、R. Y. Chang、F.-T. Chien和H. V. Poor，“面向混合中继与可重构智能表面辅助多用户系统的基于图神经网络的联合波束成形”，IEEE无线通信快报，第12卷，第10期，第1811–1815页，2023年10月。[26] K. T. Selvan和R. Janaswamy，“夫琅禾费距离与菲涅尔距离：口径天线的统一推导”，IEEE天线与传播杂志，第59卷，第4期，第12–15页，2017年8月。[27] M. Cui、Z. Wu、Y. Lu、X. Wei和L. Dai，“面向6G的近场MIMO通信：基础、挑战、潜力与未来方向”，IEEE通信杂志，第61卷，第1期，第40–46页，2023年。[28] E. Björnson等，“阵列与可重构智能表面近场波束成形入门”，载于第55届阿西洛马信号、系统与计算机会议论文集，2021年10月，第105–112页。[29] Y. Liu、Z. Wang、J. Xu、C. Ouyang、X. Mu和R. Schober，“近场通信：教程综述”，IEEE通信学会开放期刊，第4卷，第1999–2049页，2023年。[30] D. P. Bertsekas，《非线性规划》。美国马萨诸塞州剑桥：麻省理工学院出版社，1999年。[31] K. Shen和W. Yu，“通信系统的分式规划——第一部分：功率控制与波束成形”，IEEE信号处理汇刊，第66卷，第10期，第2616–2630页，2018年5月。[32] G. Scutari、F. Facchinei和L. Lampariello，“约束非凸优化的并行与分布式方法——第一部分：理论”，IEEE信号处理汇刊，第65卷，第8期，第1929–1944页，2017年4月。[33] S. Boyd和L. Vandenberghe，《凸优化》。英国剑桥：剑桥大学出版社，2004年。[34] J. Nocedal和S. J. Wright，《数值优化》，第2版。美国纽约州纽约：施普林格出版社，2006年。[35] N. Boumal、B. Mishra、P.-A. Absil和R. Sepulchre，“Manopt：用于流形优化的MATLAB工具箱”，机器学习研究期刊，第15卷，第1期，第1455–1459页，2014年。[36] P. Petersen、S. Axler和K. A. Ribet，《黎曼几何》，第171卷。美国纽约州纽约：施普林格出版社，2006年。[37] P.-A. Absil、R. Mahony和R. Sepulchre，《矩阵流形上的优化算法》。美国新泽西州普林斯顿：普林斯顿大学出版社，2009年。[38] F. Scarselli、M. Gori、A. C. Tsoi、M. Hagenbuchner和G. Monfardini，“图神经网络模型”，IEEE神经网络汇刊，第20卷，第1期，第61–80页，2009年1月。[39] K. Xu、W. Hu、J. Leskovec和S. Jegelka，“图神经网络有多强大？”，载于国际学习表征会议论文集，2019年。