基于算法展开的 RIS辅助无蜂窝网络的分布式优化

Wangyang Xu、Jiancheng An，*IEEE*会员，Hongbin Li，*IEEE*会士，Lu Gan和Chau Yuen，*IEEE*会士

arXiv:2301.02360v1 [eess.SP] 6 Jan 2023

摘要

用户中心无蜂窝网络凭借其有效消除小区间干扰的能力，已成为提升下一代无线网络容量的一项颇具吸引力的技术。然而，随着部署的基站（BS）数量增加，无小区网络不可避免地会带来更高的硬件成本和回传开销。此外，高频频段中的严重信道衰落也是限制无小区网络实际应用的另一项关键问题。为应对上述挑战，我们将无小区系统与另一项新兴技术——可重构智能表面（RIS）相结合。RIS能够通过智能重塑无线传播环境，以较低的硬件成本实现较高的频谱效率和能量效率。为此，我们针对RIS辅助无小区系统，通过联合优化基站预编码矩阵和RIS反射系数向量，构建了加权和速率（WSR）最大化问题。随后，我们将复杂的WSR问题转化为易于处理的优化问题，并提出一种分布式合作交替方向乘子法（ADMM），以充分利用并行计算资源。受基于模型的算法展开概念启发，我们将求解器展开为一种基于学习的深度分布式ADMM（D^2-ADMM）网络框架。为了提升D^2-ADMM在分布式基站中的效率，我们提出了一种信令开销较低的单向信息交换策略。除了利用领域知识外，D^2-ADMM还通过数据驱动的端到端训练，自适应地学习超参数和难以处理的RIS设计问题中的非凸求解器。最后，数值结果表明，所提出的D^2-ADMM实现了

W. Xu和L. Gan任职于中国四川成都611731电子科技大学信息与通信工程学院（电子邮箱：wangyangxu@std.uestc.edu.cn；ganlu@uestc.edu.cn）。H. Li任职于美国新泽西州霍博肯07030史蒂文斯理工学院电气与计算机工程系（电子邮箱：hli@stevens.edu）。J. An和C. Yuen任职于新加坡科技设计大学工程产品开发（EPD）支柱，新加坡487372（电子邮箱：jiancheng an@sutd.edu.sg；yuenchau@sutd.edu.sg）。

与分布式非合作算法相比，容量提升约210%；与集中式算法相比，容量提升近96%。

索引词

无小区系统、可重构智能表面、分布式协作设计、算法展开。

I. 引言

随着万物互联时代的到来，下一代无线通信系统预计将面临更高容量、更密集连接和更广覆盖的需求 [1]–[4]。传统通信网络采用蜂窝拓扑，并基于以小区为中心的原则发展出小区网络和蜂窝大规模多输入多输出（MIMO）等有效通信范式 [5], [6]。具体而言，单个基站（BS）为同一小区内的所有用户提供服务，同时在不同小区之间采用适当的资源复用策略。因此，位于小区边缘的用户更容易受到其他相邻小区上行/下行信号的干扰，从而产生常见的小区间干扰 [7]问题。

研究表明，在某些典型场景中，通过适当缩小小区尺寸，小区网络的能量效率可以优于蜂窝大规模多输入多输出 [8], [9]。然而，随着小区密度增加，小区间干扰也会随之加剧，并成为限制蜂窝网络容量的主要瓶颈 [10]。尽管蜂窝大规模多输入多输出不受小区间干扰的影响，但如果在单个基站上集中配置大量天线，阻挡造成的阴影衰落就会成为限制性能的因素。因此，在某些恶劣环境中，蜂窝大规模多输入多输出的覆盖范围和网络容量可能会显著下降 [11]。

与上述以小区为中心的网络形成鲜明对比的是，一种称为 无蜂窝大规模多输入多输出网络 的以用户为中心的网络范式，近期作为一种潜在且前沿的替代方案，受到了广泛关注 [7], [12], [13]。在无蜂窝大规模多输入多输出网络中，大量天线以分布式形式部署在众多基站上 [14]。这些基站在同一时频域内为相对少量的用户提供服务。由于无蜂窝大规模多输入多输出消除了小区边缘，因此不会像现有蜂窝网络那样造成小区间干扰。尽管无蜂窝大规模多输入多输出具有许多显著优势，

但其在未来通信系统更高频段中的应用仍需克服与严重传输衰减和覆盖盲区相关的问题 [15], [16]。此外，部署大量基站也会带来难以承受的硬件成本和能耗。幸运的是，一种颇具前景的技术——可重构智能表面（RIS）——近期已被引入各种通信场景，可显著提升系统吞吐量和频谱/能量效率 [17]–[20]。具体而言，RIS 是一块配备了许多低成本无源单元的金属面板。这些无源单元的相移可以调整，从而实现对无线环境的智能操控，并提升通信服务质量（QoS） [21]。鉴于 RIS 和无蜂窝系统的优势，开发面向未来无线通信的 RIS 辅助无蜂窝方案值得探索。

A. 已有研究

下行预编码对于充分发挥无蜂窝网络的潜力至关重要。目前，现有的无小区系统预编码方案大致可分为非协作 [7], [22], [23] 和协作 [13], [24]–[26]两类。非协作预编码假设每个基站只能利用通过上行信道估计获取的本地信道状态信息（CSI），而基站之间不进行任何CSI交换。沿着这一思路，一些相对简单的策略已被用于预编码，例如最大比传输（MRT） [7],、局部迫零（ZF） [22], 和局部最小均方误差（MMSE） [23] 设计。协作预编码包括集中式和分布式协作方案，它们在所有基站之间进行联合预编码，与非协作方案相比可获得更好的系统性能。具体而言，在集中式方案中，基站通过特定的回传链路将本地CSI上传至集中式处理单元（CPU），据此联合设计所有基站的预编码矩阵，然后再将其分发。现有关于集中式预编码的大多数研究都专注于为CPU开发预编码算法，例如集中式迫零预编码 [24], [25] 和集中式最小均方误差预编码 [13]。分布式协作预编码将计算负载分摊至多个基站，从而减轻CPU的计算负担 [27], [28]。每个基站在本地执行预编码，并根据不同基站之间的交叉项信息交换进行更新，以实现接近集中式设计最优性能的效果。

与此同时，考虑到各种实际约束和应用背景，RIS反射系数设计近年来受到了广泛关注，例如 [29]–[32],。然而——

关于RIS辅助无小区网络的研究仍处于起步阶段 [33]–[37]。具体而言， [34] 的作者采用基于本地CSI的共轭波束成形方法设计预编码向量，并随机调整RIS反射系数向量，以展示无小区系统的性能增益。假设基站将本地CSI发送至中央处理器， [35], [36] 的作者采用交替优化算法，联合设计基站预编码和RIS反射系数向量。需要指出的是，上述工作要么基于非协作方案，无需进行CSI交换，但性能较差；要么基于集中式方案，以增加系统复杂度为代价换取更好的性能。尽管近期 [37] 提出了一种RIS辅助无小区系统的分布式协作优化方法，但该方法必须在不同基站上执行多轮迭代，未能充分利用无蜂窝系统的分布式并行计算能力。

此外，现有大多数关于RIS辅助无小区系统的研究都致力于开发迭代优化算法，这些算法基于从底层物理过程推导出的复杂模型，或通过人工设计构建模型 [38], [39]。相反，深度学习（DL）方法尝试直接从训练数据中自动推断模型信息和网络参数 [19], [40]。因此，深度学习非常适用于环境复杂、难以显式构建系统模型的场景 [41]。此外，大多数神经网络的层数远少于典型迭代算法所需的迭代次数，因此深度学习方法能够实现更快的推理速度。然而，神经网络通常以“黑箱”方式训练，可解释性较差，且缺乏有助于泛化的必要领域知识。因此，结合传统迭代算法与原始数据驱动的深度学习已成为新的研究热潮。近年来，一种颇具吸引力的概念——算法展开 ——被提出，它将基于迭代的算法展开为基于学习的神经网络结构[42]–[51]。这种展开过程不仅能够融入领域知识，还能从输入数据中学习复杂的映射函数和超参数。具体而言，传统迭代算法中的每个步骤都被展开为神经网络的一层或一个模块。不同的网络层或模块串联起来，形成一个整体的神经网络框架，从而更高效地求解原始问题。算法展开方法已在许多应用领域展现出优势，例如计算成像 [48], [49], 、语音处理 [50],和遥感 [51]。

表I 所提 D^2-交替方向乘子法与现有 RIS 辅助无小区系统研究的对比

特征		所提方法	[34]	[35]	[36]	[37]
优化目标		WSR	ASR	EE	WSR	WSR
基站预编码设计		DL	局部最大比传输	IA	PDS	ADMM
RIS无源波束成形设计		DL	随机	IA	PDS	MM
集中式设计		×	×	✓	✓	×
分布式设计	非合作	×	✓	×	×	×
	合作	✓	×	×	×	✓
收敛速度		Fast	N/A	中等	中等	Slow

WSR：加权和速率；ASR：平均和速率；EE：能量效率；IA：内近似；PDS：原始-对偶次梯度；MM：主化-最小化；

B. 主要贡献

针对RIS辅助无小区系统，我们设计了一种基于交替方向乘子法（ADMM）的完全分布式联合基站预编码与RIS反射系数优化方案。此外，我们将所提出的求解器展开为基于学习的神经网络，以实现更好的收敛性和系统性能。具体而言，本文相较于现有工作的主要贡献见表I，并进一步概括如下：

- 我们提出了一种分布式 RIS 辅助无小区系统，其中部署了多个高能效 RIS，以辅助一组分布式基站向多个用户设备（UE）进行下行通信。我们开发了一种分布式合作基站预编码与 RIS 反射系数设计方案，以充分利用分布式计算资源。

- 此外，我们提出一种基于交替方向乘子法的分布式设计，通过迭代更新相关的辅助变量、基站预编码、RIS反射系数向量和乘子。所提出的设计考虑了在并行地为各基站分别设计RIS反射系数时的一致性问题。

- 我们将所提出的分布式ADMM设计展开为一种基于学习的深度分布式ADMM（D^2-ADMM）神经网络结构，该结构由多个级联的神经网络块组成。每个神经网络块均通过展开所提出的分布式ADMM设计中的单次迭代构建。此外，我们还提出了一种有效的单向信息交换

策略，以较低的信息交换开销实现我们的算法。除了根据领域知识获取确定性的变量更新策略外，D^2-ADMM还通过数据驱动端到端训练，自适应地学习RIS设计问题的超参数和非凸求解器。此外，得益于深度学习强大的推理能力，D^2-ADMM仅需少量神经网络块即可实现收敛。

- 最后，我们详细介绍所提出算法的训练与实现。数值结果表明，与多种传统算法相比，所提出的算法收敛更快、计算复杂度更低，且性能更优。

C. 章节结构与符号说明

本文其余部分安排如下。第二节介绍系统模型，并建立RIS辅助无小区系统中的联合预编码与RIS反射设计问题。第三节中，我们通过最大化加权和速率，提出一种基于分布式ADMM的设计。第四节介绍一种D^2-ADMM神经网络结构和一种单向信息交换策略，用于设计基站预编码和RIS反射系数。第五节给出数值结果。最后，我们在第六节总结全文。

符号说明：本文中，标量用斜体字母表示。向量和矩阵分别用粗体小写字母和粗体大写字母表示。上标$(\cdot)^T$ 和$(\cdot)^H$分别表示转置和共轭转置操作。 $|\cdot|$ 表示实数的绝对值。 $\|\cdot\|$ 表示向量或矩阵的二范数。Re $\{x\}$ 和Im $\{x\}$ 分别表示复数 x的实部和虚部。diag $(\cdot)$表示对角化操作。均值为 v、方差为 σ 的圆对称复高斯分布（CSCG）记为 $\sim \mathcal{CN}(v, \sigma)$。$\log_2(\cdot)$ 表示对数函数。 $\mathbb{C}$ 表示复数集合。 $\mathbb{S}$ 表示对称正定矩阵集合。

II. 系统模型与问题表述

本节首先介绍RIS辅助无小区系统的系统模型。为了设计基站预编码与RIS反射系数向量，构建了一个实际的加权和速率（WSR）最大化问题。

A. 系统模型

本文考虑如图1所示的下行链路RIS辅助无蜂窝系统，其中，多个基站和RIS采用分布式部署，以合作方式为所有用户设备提供服务。基站、RIS和用户设备的集合分别定义为 $\mathcal{B}=\{1,2,\cdots B\}$、 $\mathcal{R}=\{1,2,\cdots R\}$和 $\mathcal{K}=\{1,2,\cdots K\}$。每个基站和用户设备的天线数分别为 N_t 和1。每个RIS均配备一个矩形超表面，该超表面包含 N 个无源反射单元。

如图1所示，每个可重构智能表面在基站与用户设备之间构建一个由基站-RIS信道和RIS-用户设备信道组成的虚拟信道，以辅助下行链路通信。本文将第 b个基站与第 r个可重构智能表面之间的基站-RIS信道表示为$\mathbf{G}_{b,r}\in\mathbb{C}^{N\times N_t}$。第 r个可重构智能表面与第 k个用户设备之间的RIS-用户设备信道表示为$\mathbf{v}_{r,k}^{H}\in\mathbb{C}^{1\times N}$。此外，第 b个基站与第 k个用户设备之间的直达信道表示为$\mathbf{h}_{b,k}^{H}\in\mathbb{C}^{1\times N_t}$。我们考虑所提出的系统工作在毫米波频段，其中 $\mathbf{G}_{b,r}$、$\mathbf{v}_{r,k}$和$\mathbf{h}_{b,k}$ 均由Saleh-Valenzuela模型 [52], 描述，其表达式为

$$\begin{aligned}\mathbf{G}_{b,r}&=\sqrt{\frac{N_tN}{L_{\mathbf{G}}}}\sum_{l=1}^{L_{\mathbf{G}}}\beta_{b,r,l}\mathbf{a}_P\left(\psi_{b,r,l},\varsigma_{b,r,l}\right)\mathbf{a}_L^H\left(\chi_{b,r,l}\right),\\ \mathbf{v}_{r,k}&=\sqrt{\frac{N}{L_{\mathbf{v}}}}\sum_{l=1}^{L_{\mathbf{v}}}\beta_{r,k,l}\mathbf{a}_P\left(\psi_{r,k,l},\varsigma_{r,k,l}\right),\\ \mathbf{h}_{b,k}&=\sqrt{\frac{N_t}{L_{\mathbf{h}}}}\sum_{l=1}^{L_{\mathbf{h}}}\beta_{b,k,l}\mathbf{a}_L\left(\psi_{b,k,l}\right)\end{aligned}\tag{1}$$

分别表示，其中 $L_{\mathbf{G}}$、 $L_{\mathbf{v}}$ 和 $L_{\mathbf{h}}$ 分别表示 $\mathbf{G}_{b,r}$、$\mathbf{v}_{r,k}$ 和 $\mathbf{h}_{b,k}$ 的多径数。$\psi_{*,*,l}$（$\varsigma_{*,*,l}$）和 $\chi_{*,*,l}$ 分别表示到达角（AoAs）的方位角（仰角）以及出发角（AoDs）的方位角，其中 $*$ 分别表示基站、可重构智能表面单元和用户设备的索引。$\beta_{b,r,l}\sim\mathcal{CN}(0,PL_b,_r,_l)$、$\beta_{r,k,l}\sim\mathcal{CN}(0,PL_r,_k,_l)$ 和 $\beta_{b,k,l}\sim\mathcal{CN}(0,PL_b,_k,_l)$ 表示相应的复数路径增益，其中 PL 表示路径损耗。此外，$\mathbf{a}_L(\varsigma)$ 和 $\mathbf{a}(\psi,\varsigma)$ 分别表示均匀线性阵列（ULA）和均匀平面阵列（UPA）的阵列响应向量，其定义如下

$$\mathbf{a}_L(\psi)=\frac{1}{\sqrt{N_L}}[1,\cdots,e^{j\pi n_l\sin\psi},\cdots,e^{j\pi(N_L-1)\sin\psi}]^T,\tag{2}$$

$$\mathbf{a}_P(\psi,\varsigma)=\frac{1}{\sqrt{N_xN_y}}\left[1,\cdots,e^{j\pi(n_x\sin\psi\sin\varsigma+n_y\cos\varsigma)},\cdots,e^{j\pi((N_x-1)\sin\psi\sin\varsigma+(N_y-1)\cos\varsigma)}\right]^T,\tag{3}$$

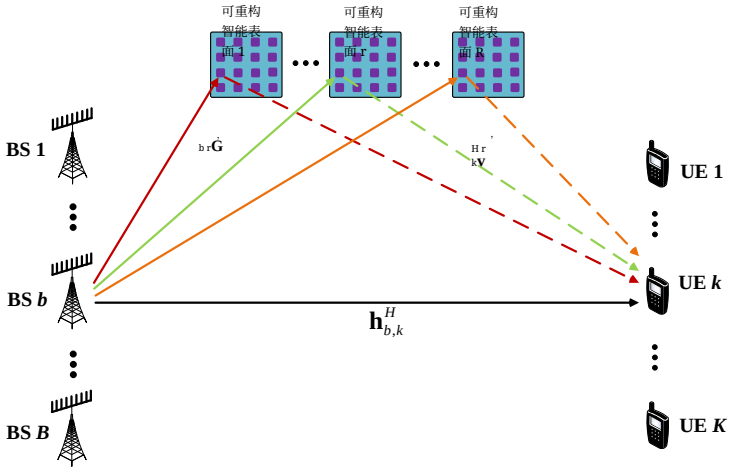

图1。下行链路RIS辅助无蜂窝系统。

分别表示，其中 N_L 和 n_l 分别表示均匀线性阵列的天线总数和天线索引；N_x、N_y、n_x 和 n_y 分别表示均匀平面阵列的水平天线数、垂直天线数、水平天线索引和垂直天线索引。

在下行传输中，第 b 个基站发射的符号 $\mathbf{x}_b \in \mathbb{C}^{N_t \times 1}$ 定义为

$$\mathbf{x}_b = \sum_{k=1}^{K} \mathbf{w}_{b,k} s_k, \ b \in \mathcal{B}, \tag{4}$$

其中，s_k 是第 k 个用户设备的发射符号。因此，我们有 $\mathbf{s} = [s_1, s_2, \cdots, s_K]^T \in \mathbb{C}^{K \times 1}$ 表示发射符号向量，且满足 $\mathbb{E}[\mathbf{s}\mathbf{s}^H] = \mathbf{I}_K$；$\mathbf{w}_{b,k} \in \mathbb{C}^{N_t \times 1}$ 表示第 b 个基站为第 k 个用户设备设置的预编码向量。

在每个用户设备处，对应于一个基站的接收信号分量包含两部分：一部分是从基站直接传播到用户设备的信号，另一部分是多个由 R RIS 反射的信号副本叠加而成。因此，第 k 个用户设备处对应于第 b 个基站的接收信号分量可表示为

$$\begin{aligned} y_{b,k} &= \left(\mathbf{h}_{b,k}^H + \sum_{r=1}^{R} \mathbf{v}_{r,k}^H \mathbf{\Theta}_r^H \mathbf{G}_{b,r} \right) \sum_{k=1}^{K} \mathbf{w}_{b,k} s_k \\ &= \left(\mathbf{h}_{b,k}^H + \boldsymbol{\theta}^H \mathbf{V}_k^H \mathbf{G}_b \right) \mathbf{x}_b \\ &= \hat{\mathbf{h}}_{b,k}^H \mathbf{x}_b, \end{aligned} \tag{5}$$

其中 $\mathbf{\Theta}_r = \mathrm{diag}([e^{j\varphi_{r,1}}, e^{j\varphi_{r,2}}, \cdots, e^{j\varphi_{r,N}}]^T) \in \mathbb{C}^{N \times N}$ 是 r个可重构智能表面的反射系数矩阵；$\varphi_{r,n}$ 是由 n个可重构智能表面的第 r个单元施加的相移；$\boldsymbol{\theta} \triangleq e^{\left(j[\varphi_{1,1},\cdots,\varphi_{1,N},\varphi_{2,1},\cdots,\varphi_{R,N}]^T\right)} \in \mathbb{C}^{NR \times 1}$ 表示 R个可重构智能表面的相移向量；$\mathbf{V}_k \triangleq \mathrm{diag}([\mathbf{v}_{1,k}^T, \mathbf{v}_{2,k}^T,$

$\cdots, \mathbf{v}_{R,k}^T]) \in \mathbb{C}^{NR\times NR}$表示从 R个可重构智能表面到第 k个用户设备的等效信道；$\mathbf{G}_b = [\mathbf{G}_{b,1}^T, \mathbf{G}_{b,2}^T, \cdots, \mathbf{G}_{b,R}^T]^T \in \mathbb{C}^{NR\times N_t}$表示从第 b个基站到 R个可重构智能表面的等效信道；$\hat{\mathbf{h}}_{b,k}$是从第 b个基站到第 k个用户设备的复合信道，其中包含一个直射信道和 NR个反射信道。

我们假设所有基站均已同步，以确保在同一时频资源块中为所有用户设备提供联合服务。因此，第 k个用户设备接收到的信号是所有基站发射信号的叠加，可表示为

$$\begin{aligned} y_k &= \sum_{b=1}^{B} y_{b,k} + z_k \\ &= \sum_{b=1}^{B}\sum_{j=1}^{K} \hat{\mathbf{h}}_{b,k}^H \mathbf{w}_{b,j} s_j + z_k \\ &= \underbrace{\sum_{b=1}^{B} \hat{\mathbf{h}}_{b,k}^H \mathbf{w}_{b,k} s_k}_{\text{Desired signal}} + \underbrace{\sum_{b=1}^{B}\sum_{j=1,j\neq k}^{K} \hat{\mathbf{h}}_{b,k}^H \mathbf{w}_{b,j} s_j}_{\text{Interference of other UEs}} + z_k, \end{aligned} \tag{6}$$

其中，$z_k \sim \mathcal{CN}(0, \delta_k^2)$表示加性白高斯噪声（AWGN）。不失一般性，我们假设所有用户设备具有相同的噪声功率，即 $\delta_k^2 = \delta^2, \forall k \in \mathcal{K}$。

B. 问题表述

根据式（6）所示的信号模型，第 k个用户设备的信干噪比（SINR）ζ_k 可写为

$$\zeta_k = \frac{\left|\sum_{b=1}^{B} \hat{\mathbf{h}}_{b,k}^H \mathbf{w}_{b,k}\right|^2}{\sum_{j=1,j\neq k}^{K} \left|\sum_{b=1}^{B} \hat{\mathbf{h}}_{b,k}^H \mathbf{w}_{b,j}\right|^2 + \delta^2}. \tag{7}$$

评估　　可重构智能表面辅助无小区系统的性能时，加权和速率（WSR）定义为

$$\mathrm{WSR} = \sum_{k=1}^{K} \omega_k \log_2(1+\zeta_k), \tag{8}$$

其中，$\omega_k > 0$ 是第 k个用户设备的权重，用于表示不同用户设备的优先级。

本文致力于通过设计基站预编码 $\mathbf{W} = \{\mathbf{w}_{b,k} | \forall b \in \mathcal{B}, \forall k \in \mathcal{K}\}$ 以及 RIS反射系数向量 $\boldsymbol{\theta}$，使 RIS辅助无小区系统的加权和速率最大化。数学上，该优化问题可表示为

$$\mathcal{P}0: \max_{\boldsymbol{\theta},\mathbf{W}} \ \mathrm{WSR} = \sum_{k=1}^{K} \omega_k \log_2(1+\zeta_k) \tag{9a}$$

$$s.t. \ \sum_{k=1}^{K} \|\mathbf{w}_{b,k}\|^2 \le P_{b,\max}, \ \forall b \in \mathcal{B}, \tag{9b}$$

$$|\theta_{r,b}| = 1, \ \forall r \in \mathcal{R}, \ \forall n \in \mathcal{N}, \tag{9c}$$

其中，(9a)为加权和速率目标函数；(9b)为基站的功率约束，其中$P_{b,\max}$表示第 b个基站的最大发射功率预算。约束(9c)表示本文中每个RIS的反射系数幅度保持不变。

备注 *1*： 尽管集中式算法能够获得 $\mathcal{P}0$ [36]的最优解，但它需要收集所有基站的本地信道状态信息，以便在中央处理器上进行联合优化。这不可避免地会增加信道状态信息反馈和控制信令开销，同时也会加重中央处理器的计算复杂度。因此，我们旨在通过将计算负载分散到各分布式基站，开发一种分布式算法来求解 $\mathcal{P}0$ 。

因此， $\mathcal{P}0$ 的分布式优化问题可改写为

$$\mathcal{P}1: \max_{\boldsymbol{\theta},\mathbf{W}} \ \mathrm{WSR} = \sum_{k=1}^{K} \omega_k \log_2(1+\zeta_k) \tag{10a}$$

$$s.t. \ (9b), \ (9c),$$

$$\boldsymbol{\theta}_b = \boldsymbol{\theta}_{\bar{b}}, \forall b \in \mathcal{B}, \forall \bar{b} \in \mathcal{F}_b, \tag{10b}$$

其中，(10b)为一致性约束，表示相邻基站处优化的 $\boldsymbol{\theta}_b$ 应保持一致。 $\mathcal{F}_b$ 表示能够与第 b 个基站交换信息的相邻基站索引集。具体而言，第 b个基站在设计RIS反射系数时，需要利用相邻基站的信息。随后，它将本地信息发送给相邻基站，直至所有基站上的RIS反射系数达成一致。

注释 *2*： 这里我们强调，在分布式系统中，优化$\mathbf{W}_b$ 和 $\boldsymbol{\theta}_b$ 存在明显差异。具体而言，不同基站对应的下行预编码矩阵$\mathbf{W}_b$ 各不相同。相比之下，不同基站优化得到的 $\boldsymbol{\theta}_b$ 对应同一个可重构智能表面，因此需要将其适当地融合为一个反射系数向量，这称为一致性

分布式系统中的问题。尽管集中式算法不涉及共识问题，但考虑到基站的分布式部署以及有限的回传容量，分布式优化策略更加有效且实用。

III. 基于ADMM的分布式优化

本节提出一种基于分布式ADMM的设计，以有效优化实际RIS辅助无小区系统中的预编码器和反射相移。具体而言，我们首先将非凸 $\mathcal{P}1$ 转化为易于处理的形式 $\mathcal{P}2$。然后，提出一种分布式ADMM设计来求解 $\mathcal{P}2$。

A. $\mathcal{P}1$的一种易处理形式

观察式（10a）可知，由于优化变量$\mathbf{W}$ 和 $\boldsymbol{\theta}$ 之间的耦合以及一致性约束（10b），$\mathcal{P}1$ 是一个非凸优化问题。因此，我们通过应用拉格朗日对偶变换和二次变换，将 $\mathcal{P}1$转化为一个易于处理的问题；这两种变换分别总结于引理1和引理2中。

引理 *1*（拉格朗日对偶变换）：给定一个对数比值和问题，表示为 [53]

$$\max_{\mathbf{x}} \ \sum_{d=1}^{D} \omega_d \log_2 \left(1+\frac{Q_d(\mathbf{x})}{F_d(\mathbf{x})}\right) \tag{11a}$$

$$s.t. \ \ \mathbf{x} \in \chi, \tag{11b}$$

其中， ω_d 是非负权重； Q_d（$\mathbf{x}$）是满足 Q_d（$\mathbf{x}$） ≥ 0的非负函数；F_d（$\mathbf{x}$）是满足 F_d（$\mathbf{x}$） > 0的正函数；$\mathbf{x}$ 是优化变量， χ 表示一个非空约束集。将比值从对数内部移至外部后，（11a）可改写为

$$\min_{\mathbf{x},\boldsymbol{\gamma}} \ \sum_{d=1}^{D} \omega_d \left(\gamma_d - \log_2(1+\gamma_d) - \frac{(1+\gamma_d)Q_d(\mathbf{x})}{Q_d(\mathbf{x})+F_d(\mathbf{x})}\right) \tag{12a}$$

$$s.t. \ \ \mathbf{x} \in \chi, \gamma_d \leq \frac{Q_d(\mathbf{x})}{F_d(\mathbf{x})}, \tag{12b}$$

其中， $\boldsymbol{\gamma} = [\gamma_1, \gamma_2, \cdots \gamma_D]^T$是辅助变量向量。

引理 *2*（二次变换）：给定一个适用于多维和复数情形的函数和比值问题，其表达式为 [54]

$$\min_{\mathbf{x}} \ \sum_{d=1}^{D} \bar{f}_d \left(Q_d \left(\mathbf{x} \right) F_d^{-1} \left(\mathbf{x} \right) Q_d^H \left(\mathbf{x} \right) \right) \tag{13a}$$

$$s.t. \ \ \mathbf{x} \in \chi, \tag{13b}$$

其中，函数 $Q_d(\mathbf{x}): \mathbb{C}^{d_1} \to \mathbb{C}^{d_2}$, $F_d(\mathbf{x}) \mathbb{C}^{d_1} \to \mathbb{S}^{d_2 \times d_2}$, $\mathbf{x}$，以及约束 $\chi \subseteq \mathbb{C}^{d_1}$。令 $\bar{f}_d(\cdot)$ 表示单调非递减函数，则问题 (13) 可变换为

$$\min_{\mathbf{x}, \boldsymbol{\eta}} \ \sum_{d=1}^{D} \bar{f}_d \left(2\mathrm{Re} \left\{ \eta_d Q_d \left(\mathbf{x} \right) \right\} - \eta_d^2 F_d \left(\mathbf{x} \right) \right) \tag{14a}$$

$$s.t. \ \ \mathbf{x} \in \chi, \eta_d \in \mathbb{C}^{d_1}, \tag{14b}$$

其中，$\boldsymbol{\eta} = [\eta_1, \eta_2, \cdots \eta_D]^T$ 表示辅助变量向量。

因此，利用拉格朗日对偶变换，$\mathcal{P}1$ 可改写为

$$\mathcal{LP}1: \min_{\boldsymbol{\theta}, \mathbf{W}, \boldsymbol{\gamma}} \ f_1 \left(\boldsymbol{\theta}, \mathbf{W}, \boldsymbol{\gamma} \right) \tag{15a}$$

$$s.t. \ \ (9b), (9c), (10b),$$

其中，$f_1(\boldsymbol{\theta}, \mathbf{W}, \boldsymbol{\gamma})$ 是通过引理 1 得到的新目标函数，具体见式 (16)。此外，$\boldsymbol{\gamma} = [\gamma_1, \gamma_2, \cdots \gamma_K]^T$ 表示辅助变量向量。

$$f_1 \left(\boldsymbol{\theta}, \mathbf{W}, \boldsymbol{\gamma} \right) = \sum_{k=1}^{K} \omega_k \left(\gamma_k - \log_2 \left(1 + \gamma_k \right) - \frac{\left(1 + \gamma_k \right) \left| \sum_{b=1}^{B} \hat{\mathbf{h}}_{b,k}^H \mathbf{w}_{b,k} \right|^2}{\sum_{k=1}^{K} \left| \sum_{b=1}^{B} \hat{\mathbf{h}}_{b,k}^H \mathbf{w}_{b,k} \right|^2 + \delta^2} \right). \tag{16}$$

然后，我们利用引理 2 中给出的二次变换，将 $\mathcal{LP}1$ 中分式的分子和分母解耦，以进一步简化优化问题。因此，$\mathcal{LP}1$ 可变换为

$$\mathcal{LP}2: \min_{\boldsymbol{\theta}, \mathbf{W}, \boldsymbol{\gamma}, \boldsymbol{\eta}} \ f_2 \left(\boldsymbol{\theta}, \mathbf{W}, \boldsymbol{\gamma}, \boldsymbol{\eta} \right) \tag{17a}$$

$$s.t. \ \ (9b), (9c), (10b),$$

其中 $f_2(\boldsymbol{\theta}, \mathbf{W}, \boldsymbol{\gamma}, \boldsymbol{\eta})$ 由式 (18) 给出；$\boldsymbol{\eta} = [\eta_1, \eta_2, \cdots \eta_K]^T$ 表示辅助变量向量。

$$\begin{aligned} f_2 \left(\theta, \mathbf{W}, \gamma, \eta \right) = & \sum_{k=1}^{K} \left(|\eta_k|^2 \sum_{j=1}^{K} \left| \sum_{b=1}^{B} \hat{\mathbf{h}}_{b,j}^H \mathbf{w}_{b,k} \right|^2 + |\eta_k|^2 \delta^2 + \omega_k \gamma_k \right. \\ & \left. - 2\sqrt{\left(1 + \gamma_k \right) \omega_k} \sum_{b=1}^{B} \mathrm{Re} \left\{ \eta_k \hat{\mathbf{h}}_{b,k}^H \mathbf{w}_{b,k} \right\} - \omega_k \log_2 \left(1 + \gamma_k \right) \right). \end{aligned} \tag{18}$$

Ne接下来，我们将问题 $\mathcal{LP}2$ 改写为其增广拉格朗日形式，表示为

$$\mathcal{L}\left(\boldsymbol{\theta},\mathbf{W},\boldsymbol{\gamma},\boldsymbol{\eta},\boldsymbol{\lambda}\right)=f_2\left(\boldsymbol{\theta},\mathbf{W},\boldsymbol{\gamma},\boldsymbol{\eta}\right)+\underbrace{\sum_{b=1}^{B}\mu_b\left(\sum_{k=1}^{K}\left\|\mathbf{w}_{b,k}\right\|^2-P_{b,\max}\right)}_{\text{Power constraint}}$$
$$+\underbrace{\sum_{b=1}^{B}\mathbb{I}\left(\boldsymbol{\theta}_b\right)}_{\text{Feasible constraint}}+\underbrace{\sum_{b=1}^{B}\frac{\rho_b}{2}\left\|\boldsymbol{\theta}_b-\boldsymbol{\theta}_{\bar{b}}+\frac{\boldsymbol{\lambda}_b}{\rho_b}\right\|^2}_{\text{Consensus constraint}}. \tag{19}$$

其中，$\boldsymbol{\lambda}=\left\{\boldsymbol{\lambda}_b\in\mathbb{C}^{N\times 1}|\forall b\in B\right\}$ 是拉格朗日乘子，且 $\rho_b>0$。$\mathbb{I}\left(\cdot\right)$ 表示一个可行函数，使得对于 $|\theta_b|=1$，$\mathbb{I}\left(\boldsymbol{\theta}_b\right)=0$；对于 $|\theta_b|\neq 1$，$\mathbb{I}\left(\boldsymbol{\theta}_b\right)=\infty$。因此，$\mathcal{P}1$ 的最终可处理形式为

$$\mathcal{P}2:\min_{\boldsymbol{\theta},\mathbf{W},\boldsymbol{\gamma},\boldsymbol{\eta},\boldsymbol{\lambda}}\mathcal{L}\left(\boldsymbol{\theta},\mathbf{W},\boldsymbol{\gamma},\boldsymbol{\eta},\boldsymbol{\lambda}\right) \tag{20}$$

B. 基于交替方向乘子法的分布式设计

为求解问题 $\mathcal{P}2$，我们提出了一种基于交替方向乘子法的分布式设计 [55], [56]。该设计通过迭代，在每个基站处设计本地的基站预编码与RIS反射系数向量。具体而言，第 i 次迭代中第 b个基站的操作可表示为

$$\boldsymbol{\gamma}^i=\arg\ \min_{\boldsymbol{\gamma}}f_1\left(\boldsymbol{\theta}^{i-1},\mathbf{W}^{i-1},\boldsymbol{\gamma}\right), \tag{21a}$$
$$\boldsymbol{\eta}^i=\arg\ \min_{\boldsymbol{\eta}}\mathcal{L}\left(\boldsymbol{\theta}^{i-1},\mathbf{W}^{i-1},\boldsymbol{\gamma}^i,\boldsymbol{\eta},\boldsymbol{\lambda}^{i-1}\right), \tag{21b}$$
$$\mathbf{W}_b^i=\arg\ \min_{\mathbf{W}_b}\mathcal{L}\left(\boldsymbol{\theta}^{i-1},\bar{\mathbf{W}}_b^{i-1},\mathbf{W}_b,\boldsymbol{\gamma}^i,\boldsymbol{\eta}^i,\boldsymbol{\lambda}^{i-1}\right), \tag{21c}$$
$$\boldsymbol{\theta}_b^i=\arg\ \min_{\boldsymbol{\theta}_b}\mathcal{L}\left(\bar{\boldsymbol{\theta}}_b^{i-1},\boldsymbol{\theta}_b,\bar{\mathbf{W}}_b^{i-1},\mathbf{W}_b^i,\boldsymbol{\gamma}^i,\boldsymbol{\eta}^i,\boldsymbol{\lambda}^{i-1}\right), \tag{21d}$$
$$\boldsymbol{\lambda}_b^i=\boldsymbol{\lambda}_b^{i-1}+\rho_b\left(\boldsymbol{\theta}_b^i-\boldsymbol{\theta}_{\bar{b}}^i\right), \tag{21e}$$

其中，$\mathbf{W}_b=\left\{\mathbf{w}_{b,k}|\forall k\in\mathcal{K}\right\}$ 表示第 b个基站的本地预编码；$\bar{\mathbf{W}}_b=\mathbf{W}\backslash\mathbf{W}_b$ 和 $\bar{\boldsymbol{\theta}}_b=\boldsymbol{\theta}\backslash\boldsymbol{\theta}_b$ 分别表示除第 b个基站外其他基站的下行预编码和RIS反射系数向量；由式（21）可知，$\boldsymbol{\gamma}$、$\boldsymbol{\eta}$、$\mathbf{W}_b$、$\boldsymbol{\theta}_b$和 $\boldsymbol{\lambda}_b$ 依次在本地更新。

接下来，我们依次给出问题 (21a)-(21d) 的解。注意，$\mathcal{P}2$ 是 $\mathcal{LP}1$的等价问题，这意味着 $\mathcal{LP}1$ 的最优 γ 与 $\mathcal{P}2$的最优解相同。此外，为求得最优 γ，求解 $\mathcal{LP}1$ 比求解 $\mathcal{P}2$ 更容易。因此，我们求解 $\mathcal{LP}1$ 以获得最优 γ。

1）(21a) 的求解器：对于问题 (21a)，当$\boldsymbol{\theta}$ 和$\mathbf{W}$固定时，$f_1(\boldsymbol{\theta},\ \mathbf{W}\ \boldsymbol{\gamma})$ 是关于 $\boldsymbol{\gamma}$的凸函数。因此，可以通过令 $\frac{\partial (f_1(\boldsymbol{\gamma}))}{\partial \gamma_k} = 0$来获得最优 γ_k 。因此，我们有

$$\gamma_k^{\dagger} = \frac{\left|\sum_{b=1}^{B} \hat{\mathbf{h}}_{b,k}^H \mathbf{w}_{b,k}\right|^2}{\sum_{j=1,j\neq k}^{K} \left|\sum_{b=1}^{B} \hat{\mathbf{h}}_{b,k}^H \mathbf{w}_{b,j}\right|^2 + \delta^2} = \frac{|\varpi_{k,k} + \vartheta_{k,k}|^2}{\sum_{j=1,j\neq k}^{K} |\varpi_{k,j} + \vartheta_{k,j}|^2 + \delta^2}, \tag{22}$$

其中 $\varpi_{k,\ j} = \sum_{b=1}^{B} \mathbf{h}_{b,\ k}^H \mathbf{w}_{b,\ j}$ 以及 $\vartheta_{k,\ j} = \sum_{b=1}^{B} \boldsymbol{\theta}^H \mathbf{V}_k^H \mathbf{G}_b \mathbf{w}_{b,\ j}$ 是两个定义的交叉项信息，其中包含所有基站的信息。请注意，$\{\varpi_{k,j}|\forall k,j \in \mathcal{K}\}$ 和 $\{\vartheta_{k,j}|\forall k,j \in \mathcal{K}\}$ 随后会在不同基站之间交换，以实现协同设计的目标。

2) (21b) 的求解器：对于问题 (21b)，我们注意到，式 (19) 中只有 $f_2(\boldsymbol{\theta},\ \mathbf{W}\ \boldsymbol{\gamma},\ \boldsymbol{\eta})$ 依赖于 $\boldsymbol{\eta}$。因此，问题 (21b) 可改写为

$$\begin{aligned}\boldsymbol{\eta} = \arg\ \min_{\boldsymbol{\eta}} \sum_{k=1}^{K} \Bigg(& |\eta_k|^2 \left(\sum_{j=1}^{K} \left| \sum_{b=1}^{B} \hat{\mathbf{h}}_{b,j}^H \mathbf{w}_{b,k} \right|^2 + \delta^2 \right) \\ & - \sqrt{(1+\gamma_k)\,\omega_k} \left(\sum_{b=1}^{B} \left(\eta_k \hat{\mathbf{h}}_{b,k}^H \mathbf{w}_{b,k} + \eta_k^* \mathbf{w}_{b,k}^H \hat{\mathbf{h}}_{b,k} \right) \right) \Bigg). \end{aligned} \tag{23}$$

最优的 $\eta_k^{\dagger}$ 也可以通过取 $\frac{\partial (f_2(\boldsymbol{\eta}))}{\partial \eta_k^*} = 0$得到，其表达式为

$$\eta_k^{\dagger} = \frac{(\varpi_{k,k} + \vartheta_{k,k})^* \sqrt{(1+\gamma_k)\,\omega_k}}{\sum_{j=1}^{K} |\varpi_{k,j} + \vartheta_{k,j}|^2 + \delta^2}. \tag{24}$$

3) (21c) 的求解器：给定其他变量的一组暂定值，我们有

$$\begin{aligned}\mathcal{L}(\mathbf{w}_{b,k}) = & \sum_{k=1}^{K} (|\eta_k|^2 \sum_{j=1}^{K} \left(\left\| \left(\sum_{b'\neq b}^{B} \hat{\mathbf{h}}_{b',j}^H \mathbf{w}_{b',k} \right) \mathbf{w}_{b,k}^H \hat{\mathbf{h}}_{b,j} \right\|^2 + \left\| \mathbf{h}_{b,j}^H \mathbf{w}_{b,k} \right\|^2 \right) \\ & - \sqrt{(1+\gamma_k)\,\omega_k} \mathrm{Re}\left\{ \eta_k \hat{\mathbf{h}}_{b,k}^H \mathbf{w}_{b,k} \right\}) + \mu_b \|\mathbf{w}_{b,k}\|^2 + \mathbf{C}_1. \end{aligned} \tag{25}$$

其中，$\mathbf{C}_1$ 定义为

$$\begin{aligned}\mathbf{C}_1 = & \sum_{k=1}^{K} (|\eta_k|^2 \sum_{j=1}^{K} \sum_{b'\neq b}^{B} \left\| \hat{\mathbf{h}}_{b',j}^H \mathbf{w}_{b',k} \right\|^2 \sum_{j=1}^{K} -2\sqrt{(1+\gamma_k)\,\omega_k} \sum_{b'\neq b}^{B} \mathrm{Re}\left\{ \eta_k \hat{\mathbf{h}}_{b',k}^H \mathbf{w}_{b',k} \right\} + |\eta_k|^2 \delta^2 + \omega_k \gamma_k \\ & - \omega_k \log_2(1+\gamma_k)) + \sum_{b'\neq b}^{B} \mu_{b'} \left(\sum_{k=1}^{K} \left\| \mathbf{w}_{b',k} \right\|^2 - P_{b,\max} \right) + \mu_b \left(\sum_{k'\neq k}^{K} \left\| \mathbf{w}_{b,k'} \right\|^2 - P_{b,\max} \right) \\ & + \sum_{b=1}^{B} \mathbb{I}(\boldsymbol{\theta}_b) + \sum_{b=1}^{B} \frac{\rho_b}{2} \left\| \boldsymbol{\theta}_b - \boldsymbol{\theta}_{\bar{b}} + \frac{\boldsymbol{\lambda}_b}{\rho_b} \right\|^2. \end{aligned} \tag{26}$$

类似地，通过取 $\partial(\mathcal{L}(\mathbf{w}_{b,k}))/\partial\mathbf{w}_{b,k}^{H}=0$，可得到最优的 $\mathbf{w}_{b,k}^{\dagger}$，其表达式为

$$\mathbf{w}_{b,k}^{\dagger}=\frac{\sqrt{(1+\gamma_k)\,\omega_k}\eta_k^{*}\hat{\mathbf{h}}_{b,k}-\boldsymbol{\Omega}_{b,k}}{\left(\mu_b+|\eta_k|^2\sum_{j=1}^{K}\hat{\mathbf{h}}_{b,j}\hat{\mathbf{h}}_{b,j}^{H}\right)}, \tag{27}$$

其中$\boldsymbol{\Omega}_{b,k}=|\eta_k|^2\sum_{j=1}^{K}\hat{\mathbf{h}}_{b,k}(\varpi_{j,k}+\vartheta_{j,k}-\hat{\mathbf{h}}_{b,j}^{H}\mathbf{w}_{b,k})$；$\mu_b$ 是用于缩放$\mathbf{w}_{b,k}$以满足总功率约束的归一化因子，需要在每次迭代中动态更新。我们采用以下功率归一化方法，以避免在 D²-交替方向乘子法中更新 μ_b。具体而言，$\mathbf{w}_{b,k}^{l}$ 通过以下方式缩放

$$\mathbf{w}_{b,k}^{\dagger}=\frac{\sqrt{P_{b,\max}}\mathbf{w}_{b,k}^{\dagger}}{\sqrt{\sum_{k=1}^{K}\left\|\mathbf{w}_{b,k}^{\dagger}\right\|^2}}. \tag{28}$$

4）(21d)的求解器 of (21d): 对于问题（21d），我们首先将（19）改写为更直观的形式：

$$\mathcal{L}(\boldsymbol{\theta}_b)=\boldsymbol{\theta}_b^{H}\mathbf{S}\boldsymbol{\theta}_b-2\mathrm{Re}\left\{\boldsymbol{\theta}_b^{H}\mathbf{Z}\right\}+\sum_{b=1}^{B}\mathbb{I}(\boldsymbol{\theta}_b)+\mathbf{C}_2, \tag{29}$$

其中，$\mathbf{S}$、$\mathbf{Z}$和$\mathbf{C}_2$ 与 $\boldsymbol{\theta}_b$ 无关，分别由式（30）、（31）和（32）给出。注意，由于可行性约束，（29）是一个非凸问题。为求解该问题，我们基于深度学习构建了一个神经网络块，具体内容将在第四节讨论。

$$\mathbf{S}=\sum_{k=1}^{K}|\eta_j|^2\sum_{j=1}^{K}\mathbf{V}_j^{H}\mathbf{G}_b\mathbf{w}_{b,k}\mathbf{w}_{b,k}^{H}\mathbf{G}_b^{H}\mathbf{V}_j+\frac{\rho_b}{2}. \tag{30}$$

$$\mathbf{Z}=\sum_{k=1}^{K}|\eta_k|^2\sum_{j=1}^{K}\mathbf{V}_j^{H}\mathbf{G}_b\mathbf{w}_{b,k}\left(\mathbf{w}_{b,k}^{H}\hat{\mathbf{h}}_{b,j}-\varpi_{j,k}^{*}-\vartheta_{j,k}^{*}-\mathbf{w}_{b,k}^{H}\mathbf{h}_{b,j}\right)+\sqrt{(1+\gamma_k)\,\omega_k}\eta_k\mathbf{V}_k^{H}\mathbf{G}_b\mathbf{w}_{b,k}. \tag{31}$$

$$\begin{aligned}\mathbf{C}_2=&\sum_{k=1}^{K}\left(|\eta_k|^2\sum_{j=1}^{K}\left(\sum_{b'\neq b}^{B}\left\|\hat{\mathbf{h}}_{b',j}^{H}\mathbf{w}_{b',k}\right\|^2+2\mathrm{Re}\left\{\mathbf{h}_{b,j}^{H}\mathbf{w}_{b,k}\left(\sum_{b'\neq b}^{B}\mathbf{w}_{b',k}^{H}\hat{\mathbf{h}}_{b',j}\right)\right\}+\left\|\mathbf{h}_{b,j}^{H}\mathbf{w}_{b,k}\right\|^2\right)\right.\\&\left.-\sqrt{(1+\gamma_k)\,\omega_k}\sum_{b'\neq b}^{B}\mathrm{Re}\left\{\eta_k\hat{\mathbf{h}}_{b',k}^{H}\mathbf{w}_{b',k}\right\}+\omega_k\gamma_k-\omega_k\log_2(1+\gamma_k)+|\eta_k|^2\delta^2\right)\\&+\sum_{b'\neq b}^{B}\frac{\rho_{b'}}{2}\left\|\boldsymbol{\theta}_{b'}-\boldsymbol{\theta}_{\bar{b}'}+\frac{\boldsymbol{\lambda}_{b'}}{\rho_{b'}}\right\|^2+\frac{\rho_b}{2}\left\|\frac{\boldsymbol{\lambda}_b}{\rho_b}-\boldsymbol{\theta}_{\bar{b}}\right\|^2.\end{aligned} \tag{32}$$

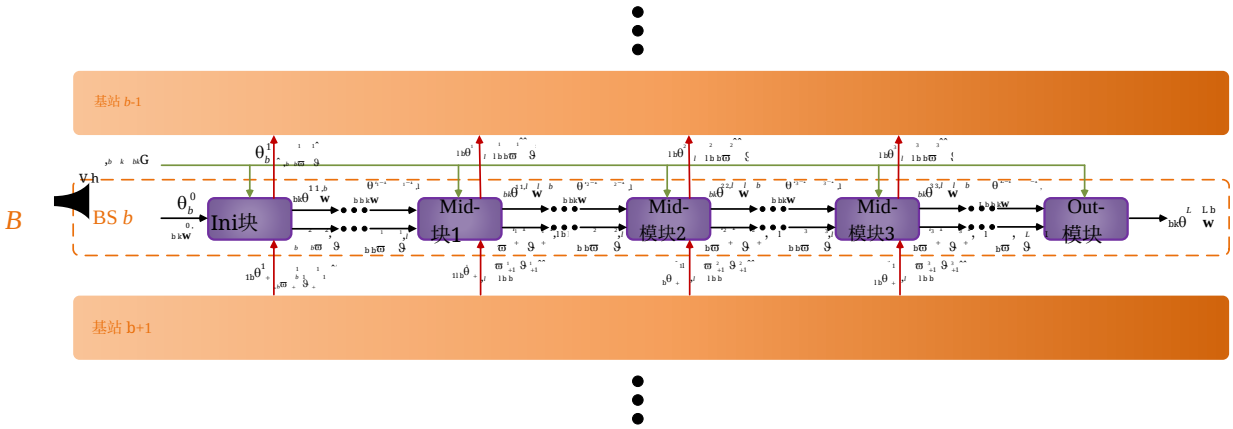

图2. D^2-交替方向乘子法的结构。

IV. D^2-ADMM：一种基于学习的算法展开方法

本节通过展开所提出的分布式ADMM设计，提出一种D^2-ADMM神经网络结构，用于设计基站预编码和RIS反射系数。此外，我们提出一种高效的单向信息交换策略，以连接不同基站并提升分布式设计的性能。最后，我们详细阐述D^2-ADMM的训练与实现。

A. 深度分布式*ADMM*的结构

所提出的分布式ADMM设计会迭代更新辅助变量、基站预编码、RIS反射系数向量和乘子。然而，由于传统分布式ADMM可能需要数百次甚至数千次迭代才能实现收敛，因此其计算复杂度较高。此外，由于必须手动选择关键超参数（例如功率归一化因子 $\{\mu_b|\forall b\in\mathcal{B}\}$和惩罚因子 $\{\rho_b|\forall b\in\mathcal{B}\}$），系统性能和收敛性也会受到影响。为克服这些缺点，我们将所提出的分布式ADMM设计展开为D^2-ADMM，以自动学习超参数 $\{\rho_b|\forall b\in\mathcal{B}\}$ 并绕过 $\{\mu_b|\forall b\in\mathcal{B}\}$。此外，我们创建了一个名为 θ-Block的神经网络块，用于求解复杂的问题（21d）。具体的D^2-ADMM结构如图2所示。

如图2所示， B 个D^2-ADMM分别在 B 个基站处实现。一个D^2-ADMM由 $L\geq B$ 个级联神经块组成。每个神经网络块均根据分布式ADMM设计中的一次迭代构建，这意味着一个神经网络块等效于传统迭代算法中的单次迭代。第（$l-1$）个神经网络块的输出构成

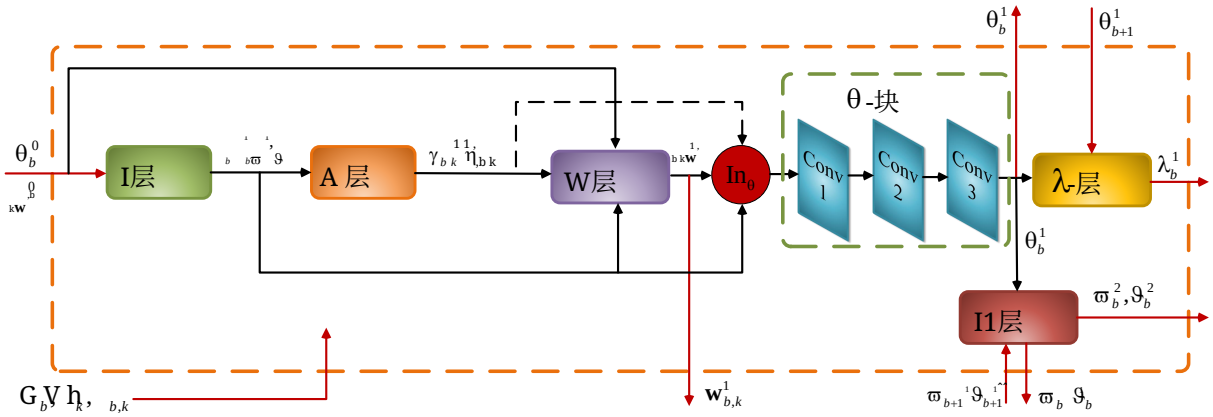

图3. 基于算法展开的Ini块结构。

第 l个神经网络块的输入。第一个神经网络块的输入经过初始化，最后一个神经网络块输出优化后的基站预编码矩阵和RIS反射系数向量。

具体而言，我们有五种不同类型的神经网络块，分别是初始化神经网络块（Ini块）、中间神经网络块1（中间块1）、中间神经网络块2（中间块2）、中间神经网络块3（中间块3）和输出神经网络块（输出块）。为便于说明，我们在图3中给出了Ini块的示意图。其他神经网络块的结构均以Ini块为基础，通过替换或删减某些部分构建而成。Ini块用于初始化网络，其中包括一个交叉项信息初始化层（I层）、一个辅助变量更新层（A层）、一个基站预编码更新层（W层）、一个可重构智能表面更新块（θ块）、一个乘子更新层（λ层）以及一个交叉项信息交换层1（I1层）。D²-交替方向乘子法的第一个神经网络块是Ini块。D²-交替方向乘子法的第2至第$B-1$个网络块构建为中间块1，其中包含一个 A层、一个 W层、一个 θ块、一个 λ层和一个I1层。D²-交替方向乘子法的第 B个神经网络块是中间块2，其结构与中间块1相似，区别在于将I1层替换为交叉项信息交换层2（I2层）。此外，第$B+1 \sim L-1$个神经网络块为中间块3，其结构与中间块2相似，不同之处在于使用交叉项信息交换层3（I3层）。D²-交替方向乘子法的最后一个神经网络块称为输出块，由一个 A层、一个 W层和一个 θ块组成。

接下来，我们将讨论各层和 θ-Block 的结构与功能。

1) 辅助变量更新层（A-层）： A-层根据公式（22）和（24）更新两个辅助变量， $\boldsymbol{\gamma}$ 和 $\boldsymbol{\eta}$。为体现迭代顺序，我们将公式（22）和（24）改写为

$$\gamma_{b,k}^{l}=\frac{\left|\varpi_{b,k,k}^{l}+\vartheta_{b,k,k}^{l}\right|^{2}}{\sum_{j=1,j\neq k}^{K}\left|\varpi_{b,k,j}^{l}+\vartheta_{b,k,j}^{l}\right|^{2}+\delta^{2}}, \tag{33}$$

$$\eta_{b,k}^{l}=\frac{\left(\varpi_{b,k,k}^{l}+\vartheta_{b,k,k}^{l}\right)^{*}\sqrt{\left(1+\gamma_{b,k}^{l}\right)\omega_{k}}}{\sum_{j=1}^{K}\left|\varpi_{b,k,j}^{l}+\vartheta_{b,k,j}^{l}\right|^{2}+\delta^{2}}, \tag{34}$$

分别表示第 b 个基站的第 l 个神经网络块的交叉项信息；$\gamma_{b,k}^{l}$ 和 $\eta_{b,k}^{l}$ 是第 b 个基站的第 l 个神经网络块的两个辅助变量。

2）基站预编码更新层（W层）：根据（27）， W层更新基站预编码矩阵$\mathbf{W}$ ，如下所示:

$$\mathbf{w}_{b,k}^{l}=\frac{\sqrt{\left(1+\gamma_{b,k}^{l}\right)\omega_{b,k}}\left(\eta_{k}^{l}\right)^{*}\hat{\mathbf{h}}_{b,k}^{l-1}-\boldsymbol{\Omega}_{b,k}^{l-1}}{\sum_{j=1}^{K}\left|\eta_{b,j}^{l}\right|^{2}\hat{\mathbf{h}}_{b,j}^{l-1}\left(\hat{\mathbf{h}}_{b,j}^{l-1}\right)^{H}}, \tag{35}$$

这里$\boldsymbol{\Omega}_{b}^{l-1}{}_{,k}=\sum_{j=1}^{K}\left|\eta_{b,j}^{l}\right|^{2}\hat{\boldsymbol{h}}_{b\,k}^{l-1},(\varpi_{b,j,k}^{l}+\vartheta_{b,j,k}^{l}-(\hat{\boldsymbol{h}}_{b}^{l-1},_{j})^{H}\boldsymbol{w}_{b\,k}^{l-1},)$ and $\hat{\boldsymbol{h}}_{b}^{l-1},_{j}=(\boldsymbol{h}_{b}^{H},_{j}+(\boldsymbol{\theta}_{b}^{l-1})^{H}V_{k}^{H}G_{b})^{H}$.

为满足功率约束，$\mathbf{w}_{b,k}^{l}$ 可改写为

$$\mathbf{w}_{b,k}^{l}=\frac{\sqrt{P_{b,\max}}\mathbf{w}_{b,k}^{l}}{\sqrt{\sum_{k=1}^{K}\left\|\mathbf{w}_{b,k}^{l}\right\|^{2}}}. \tag{36}$$

3) 可重构智能表面更新块（θ-块）：如前所述，(29) 是一个难以用传统方法求解的非凸函数。因此，我们引入 θ-块，旨在利用深度学习的推理能力来解决这一问题。 θ-块由多个卷积层组成。具体而言，我们首先将 (29) 重写为

$$\angle\left(\boldsymbol{\theta}_{b}\right)=f_{\theta}\left(\mathbf{S},\mathbf{Z}\right), \tag{37}$$

其中， f_{θ} 表示一个用作问题 (29) 求解器的非线性函数。

然后，我们使用多个卷积层来近似这个复杂的非线性函数f_{θ}。由于神经网络更适用于实值数据，我们首先将$\mathbf{S}$ 和$\mathbf{Z}$转换为实值序列 In_{θ} ，作为 θ-Block 的输入，表示如下。

$$\mathrm{In}_{\theta}=\left[\mathrm{Re}\left\{\mathbf{S}\right\},\mathrm{Im}\left\{\mathbf{S}\right\},\mathrm{Re}\left\{\mathbf{Z}\right\},\mathrm{Im}\left\{\mathbf{Z}\right\}\right]. \tag{38}$$

因此， θ-Block 的工作原理可表示为

$$\angle\left(\boldsymbol{\theta}_b\right)=f_{C,U}\left(\cdots f_{C,u}\left(\cdots f_{C,1}\left(\mathrm{In}_\theta|\upsilon_1\right)|\upsilon_u\right)|\upsilon_U\right), \tag{39}$$

其中，$f_{C,\ u}$ 是第 u个卷积层； U 表示卷积层的数量； υ_u 是第 u个卷积层的参数集。本文通过经验选择 $U=3$，这对于我们的问题已足够。

请注意，在所提出的架构中，每个卷积层的参数都可以通过端到端训练自动学习。

4）乘子更新层（λ-层）：乘子通过该层按照以下策略进行更新

$$\boldsymbol{\lambda}_b^l=\boldsymbol{\lambda}_b^{l-1}+\rho_b\left(\boldsymbol{\theta}_b^l-\boldsymbol{\theta}_{\bar{b}}^l\right), \tag{40}$$

其中， ρ_b 是可学习参数； $\boldsymbol{\theta}_{\bar{b}}^l$ 是从¯第 b个基站交换而来的RIS反射系数向量。

5）交叉项信息初始化层（*I*层）：同样，在分布式RIS辅助无蜂窝系统的协同设计中，基站之间需要共享CSI。然而，考虑到安全性以及直接进行CSI交换所带来的过高开销，我们定义 $\{\varpi_{b,k,j},\vartheta_{b,k,j}|\forall b\in\mathcal{B};\ \forall k,\ j\in\mathcal{K}\}$ 为 A层、W层和 θ块中的两类必要交叉信息。

I层初始化本地交叉项信息，表示为

$$\begin{cases}\hat{\varpi}_{b,k,j}^0=0,\\ \hat{\vartheta}_{b,k,j}^0=0,\end{cases} \tag{41a}$$

$$\begin{cases}\varpi_{b,k,j}^1=\mathbf{h}_{b,k}^H\mathbf{w}_{b,k}^0,\\ \vartheta_{b,k,j}^1=\left(\boldsymbol{\theta}_b^0\right)^H\mathbf{V}_k^H\mathbf{G}_b\mathbf{w}_{b,k}^0,\end{cases} \tag{41b}$$

其中，$\hat{}\varpi_{b,\ k,\ j}^0$ 和 $\hat{}\vartheta_{b,\ k,\ j}^0$ 是两组初始化的交叉项信息，将发送给相邻基站；$\varpi_{b,\ k,\ j}^1$ 和 $\vartheta_{b,\ k,\ j}^1$ 表示两组交叉项信息，将用于更新下一个神经网络块；$\mathbf{w}_{b,\ k}^0$ 和 $\boldsymbol{\theta}_b^0$ 均为随机初始化。

6) 交叉项信息层*1*（*I1*层）：I1层包括两个过程。过程1是将更新后的交叉项信息发送给相邻基站，如式（42a）所示，其中 $\hat{}\varpi_{b,k,j}^l$ 和 $\hat{}\vartheta_{b,k,j}^l$ 是需要与相邻基站共享的两条交叉项信息。此外，$\hat{}\varpi_{\bar{b}\,k\,,j}^{l-1}$ 和 $\hat{}\vartheta_{\bar{b}\,k\,,j}^{l-1}$ 表示从相邻基站接收的两个交叉项信息符号。 $\boldsymbol{\theta}_b^l$ 和 $\mathbf{w}_{b,k}^l$ 分别表示RIS反射系数向量和基站预编码向量的第 l次更新

在过程2中，根据从相邻基站接收的交叉项信息，确定更新下一个神经网络块所需的交叉项信息，如式（42b）所示，其中 $\varpi_{b\,k}^{l+1}{}_{,,j}$ 和 $\vartheta_{b\,k}^{l+1}{}_{,,j}$ 表示更新第（$l+1$）个神经网络块所需的两个交叉项信息符号。I1层配置用于第（$1\sim B-1$）个神经网络块。

$$\begin{cases} \hat{\varpi}_{b,k,j}^{l} = \hat{\varpi}_{\bar{b},k,j}^{l-1} + \mathbf{h}_{b,k}^{H}\mathbf{w}_{b,k}^{l}, \\ \hat{\vartheta}_{b,k,j}^{l} = \hat{\vartheta}_{\bar{b},k,j}^{l-1} + \left(\boldsymbol{\theta}_{b}^{l}\right)^{H}\mathbf{V}_{k}^{H}\mathbf{G}_{b}\mathbf{w}_{b,k}^{l}, \end{cases} \tag{42a}$$

$$\begin{cases} \varpi_{b,k,j}^{l+1} = \hat{\varpi}_{\bar{b},k,j}^{l} + \mathbf{h}_{b,k}^{H}\mathbf{w}_{b,k}^{l}, \\ \vartheta_{b,k,j}^{l+1} = \hat{\vartheta}_{\bar{b},k,j}^{l} + \left(\boldsymbol{\theta}_{b}^{l}\right)^{H}\mathbf{V}_{k}^{H}\mathbf{G}_{b}\mathbf{w}_{b,k}^{l}. \end{cases} \tag{42b}$$

7) 交叉项信息层*2*（*I2*层）：I2层的过程1与I1层相似，但过程2不同。具体而言，第 b 个基站在第一个神经网络块中的更新内容包含在更新第（$B+1$）个神经网络块所需的交叉项信息中。因此，我们必须从交叉项信息中消除过时的更新，并添加第 B个更新，以确保其中仅包含最新的更新。具体过程2表示如下

$$\begin{cases} \varpi_{b,k,j}^{B+1} = \hat{\varpi}_{\bar{b},k,j}^{B} - \mathbf{h}_{b,k}^{H}\mathbf{w}_{b,j}^{1} + \mathbf{h}_{b,k}^{H}\mathbf{w}_{b,j}^{B}, \\ \vartheta_{b,k,j}^{B+1} = \hat{\vartheta}_{\bar{b},k,j}^{B} - \left(\boldsymbol{\theta}_{b}^{1}\right)^{H}\mathbf{V}_{k}^{H}\mathbf{G}_{b}\mathbf{w}_{b,j}^{1} + \left(\boldsymbol{\theta}_{b}^{B}\right)^{H}\mathbf{V}_{k}^{H}\mathbf{G}_{b}\mathbf{w}_{b,j}^{B}. \end{cases} \tag{43}$$

因此，I2层仅在第 B个神经网络块中使用。

8) 交叉项信息层*3*（*I3*层）：当 $l \geq B+1$时，发送至相邻基站的交叉项信息以及用于更新下一个神经网络块的交叉项信息都需要消除过时的更新。因此，I3层的两个过程可描述为

$$\begin{cases} \hat{\varpi}_{b,k,j}^{l} = \hat{\varpi}_{\bar{b},k,j}^{l-1} - \mathbf{h}_{b,k}^{H}\mathbf{w}_{b,j}^{l-B+1} + \mathbf{h}_{b,k}^{H}\mathbf{w}_{b,j}^{l}, \\ \hat{\vartheta}_{b,k,j}^{l} = \hat{\vartheta}_{\bar{b},k,j}^{l-1} - \left(\boldsymbol{\theta}_{b}^{l-B+1}\right)^{H}\mathbf{V}_{k}^{H}\mathbf{G}_{b}\mathbf{w}_{b,j}^{l-B+1} + \left(\boldsymbol{\theta}_{b}^{l}\right)^{H}\mathbf{V}_{k}^{H}\mathbf{G}_{b}\mathbf{w}_{b,j}^{l}, \end{cases} \tag{44a}$$

$$\begin{cases} \varpi_{b,k,j}^{l+1} = \hat{\varpi}_{\bar{b},k,j}^{l} - \mathbf{h}_{b,k}^{H}\mathbf{w}_{b,j}^{l-B+2} + \mathbf{h}_{b,k}^{H}\mathbf{w}_{b,j}^{l}, \\ \vartheta_{b,k,j}^{l+1} = \hat{\vartheta}_{\bar{b},k,j}^{l} - \left(\boldsymbol{\theta}_{b}^{l-B+2}\right)^{H}\mathbf{V}_{k}^{H}\mathbf{G}_{b}\mathbf{w}_{b,j}^{l-B+2} + \left(\boldsymbol{\theta}_{b}^{l}\right)^{H}\mathbf{V}_{k}^{H}\mathbf{G}_{b}\mathbf{w}_{b,j}^{l}. \end{cases} \tag{44b}$$

我们在第（$B+1\sim L-1$）个神经网络块中部署I3层。

B. 信息交换策略

接下来，我们将详细介绍所提出的信息交换策略。为保护不同基站的信息隐私并降低所提系统的信息交换开销，

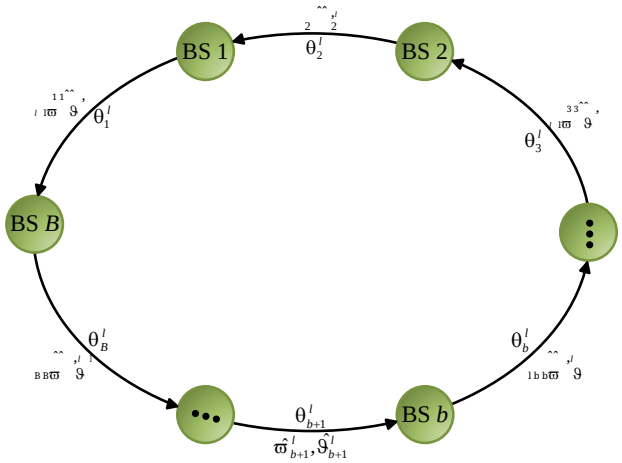

图 4. 所提出的信息交换策略。

我们定义了两类用于各基站更新的交叉项信息。每个神经网络块的更新都需要保证交叉项信息的完整性和及时性，如 I1层、I2层和 I3层的更新过程所示。在大多数现有的分布式信息交换策略中，每个基站通常会接收多个基站共享的信息 [35], [36]。这种交换策略会降低本文所定义交叉项信息的完整性和及时性，进而影响系统的收敛和性能。因此，我们提出了一种有效的单向信息交换策略，并假设所有基站均采用单向拓扑，如图 4 所示。

每个基站通过专用链路与两个相邻基站进行单向信息交换。例如，第 b 个基站从第 $(b+1)$ 个基站接收交叉项信息，并将其交叉项信息发送给第 $(b-1)$ 个基站。为确保交叉项信息的完整性，该策略至少需要 B 次信息交换。随着迭代的进行，通过用最新信息替换过时信息，确保交叉项信息的时效性。具体的交叉项信息处理在 I1层、I2层和 I3层完成。

除了交换交叉项信息外，我们还需要在各个基站之间交换由每个神经网络块更新的 RIS反射系数向量，以更新乘子λ。因此，第 b个基站需要发送第 l个神经网络块中的 $\{\hat{\varpi}^l_{b,k,j}|\forall k,\ j\in\mathcal{K}\}$（$K^2$维）、$\{\hat{\vartheta}^l_{b,k,j}|\forall k,\ j\in\mathcal{K}\}$（$K^2$ 维）以及 $\boldsymbol{\theta}^l_b$（RN 维）。因此，实际RIS辅助无小区系统中交换数据的总维度为 $B(L-1)(2K^2+RN)$，与直接交换信道状态信息相比显著降低。

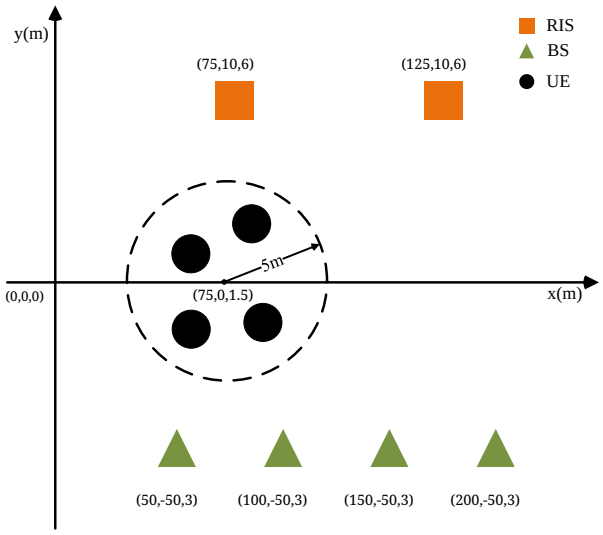

图 5. RIS辅助无小区系统的三维场景。

C. D^2-交替方向乘子法的训练

本节介绍所提出的D²-交替方向乘子法的具体训练和实际应用方法。第 b个基站处D²-交替方向乘子法的输入为其本地CSI、初始化的$\mathbf{w}_{b,\,k}^{0}$ 和$\boldsymbol{\theta}_b^0$，输出则为优化后的$\mathbf{w}_{b,\,k}^{L}$ 和 $\boldsymbol{\theta}_b^L$。随后，通过端到端训练更新D²-交替方向乘子法中的 θ-层参数和 ρ_b。训练所用的损失函数设为

$$f_{\text{Loss}} = \frac{1}{Q}\sum_{q=1}^{Q}\sum_{b=1}^{B}\underbrace{\left\|\boldsymbol{\theta}_{q,b} - \boldsymbol{\theta}_{q,\bar{b}}\right\|^2}_{\text{Consensus error}} - \text{WSR}_q, \tag{45}$$

其中， Q是一个训练批次的样本数。

通过最小化损失函数 f_{Loss}，在最大化加权和速率的同时最小化一致性误差。值得注意的是，训练过程在单个中央处理器上完成。训练完成后，我们将 B D²-交替方向乘子法部署到相应的基站，以实现实际的分布式实现。

V. 数值结果

本节给出仿真结果，以展示我们提出的用于RIS辅助无小区系统的D²-交替方向乘子法框架的有效性。

A. 仿真设置

我们考虑图 5 所示的典型 RIS辅助无小区系统三维场景。在该场景中，第 b 个基站部署在 $(200\times\frac{b}{B}, -50, 3)$ m 处。不失一般性，我们考虑

$R = 2$ 个 RIS，分别部署在 (75, 10, 6)m 和 (125,10, 6) m 处。由 B 个基站服务的 K 个用户设备随机分布在一个圆形区域内，该区域中心位于 (75, 0,1.5) m 处，半径为 5m，高度为 1.5 m。每个基站的天线数设为 $N_t = 2$。根据每个设备的位置信息，可通过式 (1) 确定相应的信道。在此设置中，我们假设每个信道的多径数为 3（1 条视距路径、2 条非视距路径），其到达角和出发角在范围 $[-\frac{\pi}{2}, \frac{\pi}{2}]$ 内随机选取。同样，所有基站具有相同的最大发射功率，即 $P_{b,\max} = P$。接收噪声功率设为 $\delta^2 = -80$ dBm。

为了更好地展示所提出的 D²-交替方向乘子法的性能，我们考虑了几种具有代表性的基准方法，如下所列。

- 集中式：假设所有基站都将本地CSI发送至中央处理器，以集中式设计基站预编码矩阵和可重构智能表面的反射系数向量 [36]。
- 最大比传输 随机 θ：一种分布式设计方法，其中可重构智能表面的反射系数向量采用随机配置，而基站预编码则设计为本地CSI的共轭[7]。
- *MRTComb MaxAO*：一种分布式算法，通过最大化级联信道的信道增益来配置可重构智能表面；基站预编码的设计与最大比传输 随机 θ相同。
- *LocalZF Comb MaxAO*：该分布式算法对可重构智能表面的设计与 MRT Comb MaxAO 相同，并采用 [57] 中提出的局部迫零算法来优化基站预编码矩阵。

B. D²-交替方向乘子法的训练性能

为了展示 D²-交替方向乘子法的收敛性，我们首先进行实验，评估 D²-交替方向乘子法训练过程中的各项指标，如图 6(a)–6(c) 所示，其中设置 $B = 4$、 $N = 50$、 $K = 4$、 $P = 30$ dBm。

具体而言，图 6(a) 展示了不同神经网络块数量下 D²-交替方向乘子法的训练损失。可以看出，随着训练的进行，D²-交替方向乘子法的训练损失能够收敛。此外，当$L \geq 6$时，不同 L 对应的最终收敛训练损失差异可以忽略不计。进一步地，图 6(b) 展示了 D²-交替方向乘子法的一致性误差随不同 L变化的情况。从图 6(b) 可以观察到，随着训练的进行，D²-交替方向乘子法的一致性误差能够收敛至最小值，而且 L 的变化不会严重影响一致性误差的收敛结果。训练阶段的加权和速率随神经网络块数量的变化情况

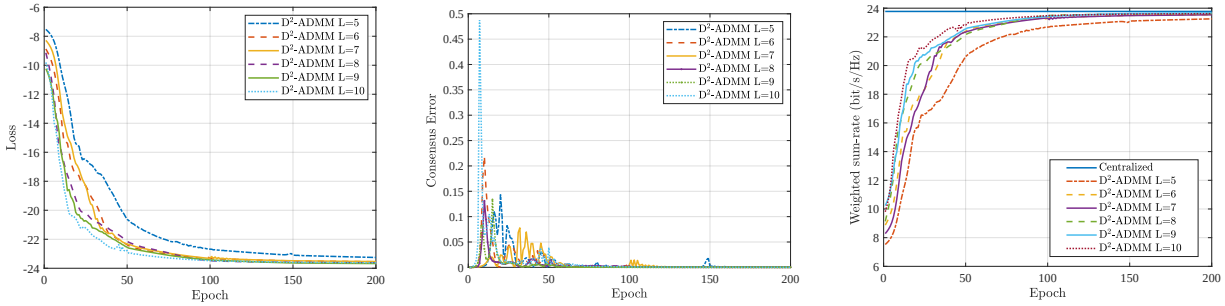

(a) (b) (c)

图6. (a) D^2-交替方向乘子法的训练损失；(b) D^2-交替方向乘子法在训练过程中的一致性误差；(c) D^2-交替方向乘子法在训练过程中的加权和速率；

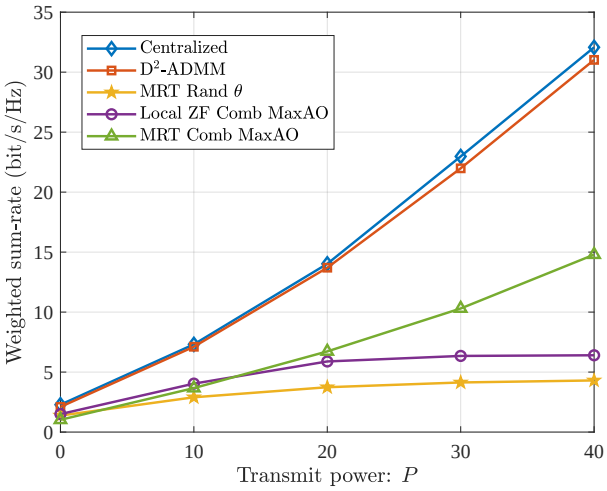

图7. 加权和速率与发射功率 P 的对比，其中 $B = 4$, $N_t = 2$, $N = 50$, $K = 4$.

如图 6(c) 所示，这表明随着训练的进行，D^2-交替方向乘子法能够逐步收敛至与集中式算法相当的性能。此外，在所考虑的仿真设置中，随着神经网络块数量增加，D^2-交替方向乘子法的收敛速度更快。同样，当仿真设置中的 $L \geq 6$ 时，最终收敛性能会达到饱和。

通过比较图6(a)–6(c)，可以得出结论：随着神经网络块数量 L 的增加，D^2-交替方向乘子法的性能几乎可以收敛到集中式算法的水平，并逐渐趋于饱和。考虑到神经网络块数量与系统性能之间的权衡，我们为神经网络块数量提供了一个经验选择准则：$L = B + 2$。

C. 不同设置下 *D*^{2}-交替方向乘子法的性能

本节比较了在各种设置下 D^2-ADMM 与基准算法的性能。

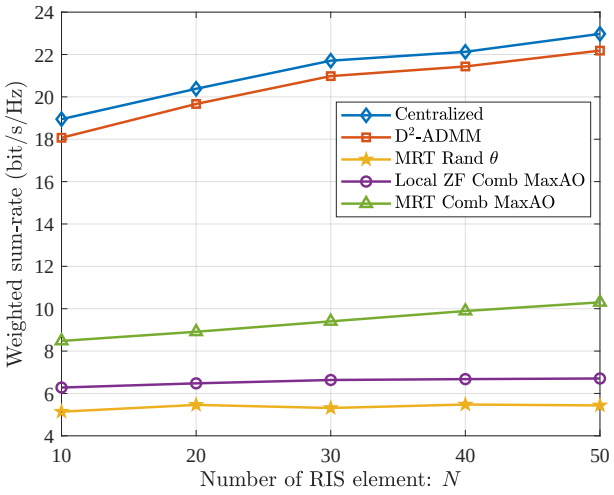

图8。 不同RIS单元数量 N下的加权和速率比较，其中 $B = 4$、 $N_t = 2$、 $K = 4$、 $P = 30$ dBm .

在图 7 中，我们比较了 P 时不同算法的 WSR 与发射功率之间的关系，其中$B = 4$、$N = 50$、 $K = 4$。根据第五节 A 小节给出的结论，我们选择$L = 6$ ，以平衡计算复杂度和系统性能。如图 7 所示，随着 P 增加，所有算法的 WSR 均有所提升。集中式算法表现最佳，因为它能够充分利用所有基站的信道状态信息。结果表明，D²-ADMM 的性能与集中式算法相当，例如，当 $P = 30$dBm 时，性能达到集中式算法的 95.6%。MRT Randθ 算法表现最差，因为未经优化的 RIS 反射系数无法带来任何收益。由于 Local ZF Comb MaxAO 和 MRT Comb MaxAO 算法是非分布式算法，且在系统设计时未纳入所有基站，因此与所提出的 D²-ADMM 相比，性能受到严重影响。例如，当 $P = 30$ dBm 时，采用 D²-ADMM 可获得约 213% 的 WSR 提升，相较于 Local ZF Comb MaxAO。

图8展示了在不同RIS单元数量 N下，D²-交替方向乘子法与基准方法的性能比较，其中 $B = 4$、 $K = 4$、 $P = 30$ dBm。从图8可以看出，随着 N 增加，集中式算法、D²-交替方向乘子法和局部ZF组合MaxAO算法的性能均有所提升。然而，MRT Comb MaxAO和MRT rand θ 算法几乎不会因RIS单元数量增加而受益。此外，D²-交替方向乘子法优于其他三种分布式设计算法，例如，当$N = 30$时，其性能比Local ZF Comb MaxAO高223%；并且其性能可与集中式方法相当，例如，当 $N = 30$时达到96.6%。

接下来，我们展示 图9展示了各种算法的加权和速率随用户设备数量变化的情况，其中

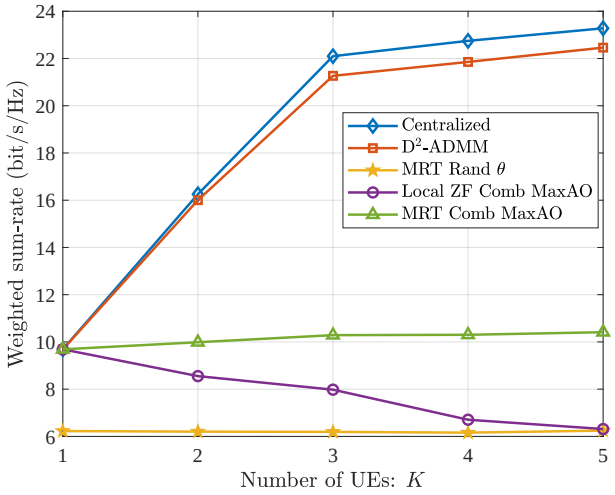

图9。 不同用户设备数量 K 下的加权和速率对比，其中 $B = 4$、 $N_t = 2$、 $N = 50$、 $P = 30$ dBm。

$B = 4, N = 50, P = 30$ dBm。集中式算法、D²-交替方向乘子法以及局部ZF组合MaxAO算法的性能会随着 K 增加而提升，这得益于用户设备数量增加所带来的空间复用增益。同样，D²-交替方向乘子法的性能可与集中式算法相当，例如当 $K = 5$时约为96.5%；且优于局部ZF组合MaxAO算法，例如当 $K = 5$时约为216%。当仅服务单个用户设备时，除MRT rand θ 算法外，其他四种算法的性能相同，因为此时用户间干扰消失。然而，随着更多用户设备接入网络，MRT组合MaxAO算法的性能会下降，这是因为分布式算法无法抑制用户间干扰。

最后，我们通过在图10中考虑不同数量的基站 B ，评估D²-交替方向乘子法算法相对于其他基准方法的性能，其中 $N = 50$、 $K = 4$、 $P = 30$ dBm。同样，D²-交替方向乘子法能够达到相当的性能，例如，当 $B = 5$ 时，其性能约为集中式算法的96.2%，且采用不同的 B。随着 B 增加，D²-交替方向乘子法的性能也会提升，这是因为更多基站能够为用户设备提供更多功率。

VI. 结论

本文研究了一种RIS辅助无小区系统，该系统能够提升通信容量并克服传统蜂窝网络的缺点。为联合设计基站的下行预编码和RIS的反射相移，我们提出了一种基于交替方向乘子法的分布式协作设计，能够充分利用并行计算资源。随后，我们通过展开所提出的分布式协作设计中的每次迭代，构建了一种神经网络框架D²-ADMM，以通过端到端训练自动学习超参数和非凸RIS求解器。

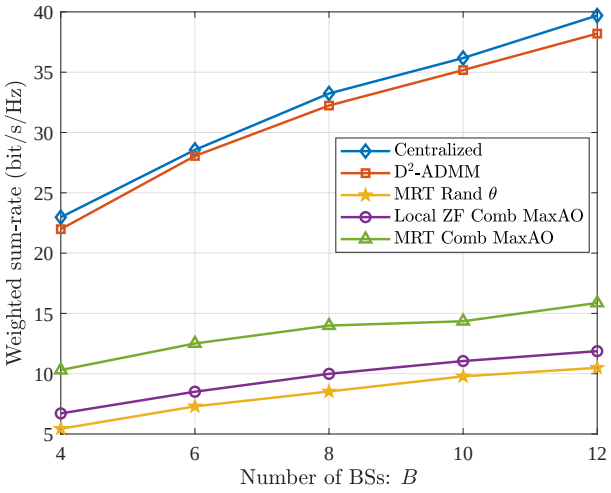

图10。 不同基站数量 B 下的加权和速率对比，其中 $N_t = 2$, $N = 50$, $K = 4$, $P = 30$ dBm .

与传统迭代算法相比，D^2-ADMM具有更快的收敛速度。此外，我们提出了一种有效的单向信息交换策略，以较小的交换开销实现所有基站的协作设计。最后，数值结果表明，与分布式非合作算法相比，所提出的D^2-ADMM将容量提升了约210%；与集中式算法相比，容量提升了近96%。

参考文献

[1] K. Samdanis 和 T. Taleb，“超越5G之路：关键技术的愿景与洞见”，*IEEE*网络，第34卷，第2期，第135–141页，2020年2月。[2] P. Popovski、K. F. Trillingsgaard、O. Simeone 和 G. Durisi，“面向增强型移动宽带、超可靠低时延通信和海量机器类通信的5G无线网络切片：通信理论视角”，*IEEE Access*，第6卷，第55 765–55779页，2018年9月。[3] P. Yang、Y. Xiao、M. Xiao 和 S. Li，“6G无线通信：愿景与潜在技术”，*IEEE*网络，第33卷，第4期，第70–75页，2019年8月。[4] J. Mitola、J. Guerci、J. Reed、Y.-D. Yao、Y. Chen、T. C. Clancy、J. Dwyer、H. Li、H. Man、R. McGwier 和 Y. Guo，“通过公私频谱共享提升5G体验质量”，*IEEE*通信杂志，第52卷，第5期，第77–85页，2014年。[5] S. Hur、T. Kim、D. J. Love、J. V. Krogmeier、T. A. Thomas 和 A. Ghosh，“小蜂窝网络中用于无线回传和接入的毫米波波束成形”，*IEEE Trans. Commun.*，第61卷，第10期，第4391–4403页，2013年10月。[6] C.-X. Wang、F. Haider、X. Gao、X.-H. You、Y. Yang、D. Yuan、H. M. Aggoune、H. Haas、S. Fletcher 和 E. Hepsaydir，“5G无线通信网络的蜂窝架构与关键技术”，*IEEE*通信杂志，第52卷，第2期，第122–130页，2014年2月。[7] H. Q. Ngo、A. Ashikhmin、H. Yang、E. G. Larsson 和 T. L. Marzetta，“无蜂窝大规模多输入多输出与小小区的比较”，*IEEE*无线通信汇刊，第16卷，第3期，第1834–1850页，2017年3月。

[8] W. Liu、S. Han 和 C. Yang，“大规模多输入多输出与小蜂窝网络的能量效率比较”，载于 IEEE GlobalSIP 会议论文集，美国佐治亚州亚特兰大，2014年12月，第617–621页。[9] E. Bj¨ornson、L. Sanguinetti 和 M. Kountouris，“部署密集网络以实现最大能量效率：小小区与大规模多输入多输出相结合”，IEEE通信选定领域期刊，第34卷，第4期，第832–847页，2016年4月。[10] H. S. Dhillon、M. Kountouris 和 J. G. Andrews，“下行MIMO异构网络：建模、排序结果与性能分析”，IEEE无线通信汇刊，第12卷，第10期，第5208–5222页，2013年10月。[11] S. Zhou、M. Zhao、X. Xu、J. Wang 和 Y. Yao，“分布式无线通信系统：面向未来公共无线接入的新架构”，IEEE通信杂志，第41卷，第3期，第108–113页，2003年3月。[12] E. Nayebi、A. Ashikhmin、T. L. Marzetta、H. Yang 和 B. D. Rao，“无蜂窝大规模多输入多输出系统中的预编码与功率优化”，IEEE无线通信汇刊，第16卷，第7期，第4445–4459页，2017年7月。[13] E. Bj¨ornson 和 L. Sanguinetti，“通过最小均方误差处理和集中式实现，使无蜂窝大规模多输入多输出具备竞争力”，IEEE无线通信汇刊，第19卷，第1期，第77–90页，2020年1月。[14] H. Q. Ngo、A. Ashikhmin、H. Yang、E. G. Larsson 和 T. L. Marzetta，“无蜂窝大规模多输入多输出：为所有人提供始终优质的服务”，载于 IEEE SPAWC 会议论文集，瑞典斯德哥尔摩，2015年6月，第201–205页。[15] M. Xiao、S. Mumtaz、Y. Huang、L. Dai、Y. Li、M. Matthaiou、G. K. Karagiannidis、E. Bj¨ornson、K. Yang、C.-L. I 和 A. Ghosh，“面向未来移动网络的毫米波通信”，IEEE通信选定领域期刊，第35卷，第9期，第1909–1935页，2017年9月。[16] Z. C hen、X. Ma、B. Zhang、Y. Zhang、Z. Niu、N. Kuang、W. Chen、L. Li 和 S. Li，“太赫兹通信综述”，《中国通信》，第16卷，第2期，第1–35页，2019年2月。[17] Q. Wu 和 R. Zhang，“迈向智能可重构环境：智能反射表面辅助无线网络”，IEEE通信杂志，第58卷，第1期，第106–112页，2020年1月。[18] C. Huang、A. Zappone、G. C. Alexandropoulos、M. Debbah 和 C. Yuen，“可重构智能表面在无线通信能量效率方面的应用”，IEEE无线通信汇刊，第18卷，第8期，第4157–4170页，2019年8月。[19] W. Xu、L. Gan 和 C. Huang，“具有实际约束的RIS辅助多用户多输入单输出通信的鲁棒深度学习波束成形设计”，IEEE认知通信与网络汇刊，第8卷，第2期，第694–706页，2022年6月。[20] J. An、C. Xu、L. Gan 和 L. Hanzo，“基于离散相移的RIS辅助多输入多输出系统低复杂度信道估计与无源波束成形”，IEEE Trans. Commun.，第70卷，第2期，第1245–1260页，2022年2月。[21] W. Xu、J. An、C. Huang、L. Gan 和 C. Yuen，“基于位置感知模仿环境的RIS辅助毫米波多输入多输出系统深度强化学习”，IEEE无线通信快报，第11卷，第7期，第1493–1497页，2022年7月。[22] S. Buzzi、C. D’Andrea、A. Zappone 和 C. D’Elia，“以用户为中心的5G蜂窝网络：资源分配及与无蜂窝大规模多输入多输出方案的比较”，IEEE无线通信汇刊，第19卷，第2期，第1250–1264页，2020年2月。[23] M. Alonzo、S. Buzzi、A. Zappone 和 C. D’Elia，“毫米波下无蜂窝和以用户为中心的大规模多输入多输出中的能效功率控制”，IEEE绿色通信与网络汇刊，第3卷，第3期，第651–663页，2019年9月。[24] E. Nayebi、A. Ashikhmin、T. L. Marzetta、H. Yang 和 B. D. Rao，“无蜂窝大规模多输入多输出系统中的预编码与功率优化”，IEEE无线通信汇刊，第16卷，第7期，第4445–4459页，2017年7月。[25] P. Liu、K. Luo、D. Chen 和 T. Jiang，“采用迫零检测器的无蜂窝大规模多输入多输出系统频谱效率分析”，IEEE无线通信汇刊，第19卷，第2期，第795–807页，2020年2月。[26] J. Wang、B. Wang、J. Fang 和 H. Li，“毫米波无蜂窝大规模多输入多输出系统：联合波束成形与接入点-用户关联”，IEEE无线通信快报，第11卷，第2期，第298–302页，2022年。[27] A. Tolli、H. Ghauch、J. Kaleva、P. Komulainen、M. Bengtsson、M. Skoglund、M. Honig、E. Lahetkangas、E. Tiirola 和 K. Pajukoski，“采用前向-后向训练的5G无线接入分布式协同传输”，IEEE通信杂志，第57卷，第1期，第58–64页，2019年1月。

[28] J. Kaleva、A. T¨olli、M. Juntti、R. A. Berry 和 M. L. Honig，“采用导频辅助波束成形器估计的分布式联合预编码”，IEEE信号处理汇刊，第66卷，第9期，第2330–2341页，2018年5月。[29] Q. Wu 和 R. Zhang，“通过联合有源和无源波束成形实现智能反射面增强型无线网络”，IEEE无线通信汇刊，第18卷，第11期，第5394–5409页，2019年11月。[30] J. An 和 L. Gan，“IRS辅助MISO系统的低复杂度设计与最优训练开销”，IEEE无线通信快报，第10卷，第8期，第1820–1824页，2021年8月。[31] 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通信选定领域期刊，第38卷，第8期，第1839–1850页，2020年10月。[32] C. Huang、S. Hu、G. C. Alexandropoulos、A. Zappone、C. Yuen、R. Zhang、M. Di Renzo 和 M. Debbah，“面向6G无线网络的全息MIMO表面：机遇、挑战与趋势”，IEEE无线通信，第27卷，第5期，第118–125页，2020年10月。[33] E. Shi、J. Zhang、S. Chen、J. Zheng、Y. Zhang、D. W. Kwan Ng 和 B. Ai，“RIS辅助无小区大规模MIMO系统中的无线能量传输：机遇与挑战”，IEEE通信杂志，第60卷，第3期，第26–32页，2022年3月。[34] B. Al-Nahhas、M. Obeed、A. Chaaban 和 M. J. Hossain，“RIS辅助无小区大规模MIMO：性能分析与竞争力”，载于IEEE ICC研讨会论文集，加拿大魁北克省蒙特利尔，2021年6月，第1–6页。[35] Q. N. Le、V.-D. Nguyen、O. A. Dobre 和 R. Zhao，“有限回程条件下RIS辅助无小区网络的能效最大化”，IEEE通信快报，第25卷，第6期，第1974–1978页，2021年6月。[36] Z.Zhang 和 L. Dai，“面向宽带可重构智能表面辅助无小区网络的联合预编码框架”，IEEE信号处理汇刊，第69卷，第4085–4101页，2021年6月。[37] S. Huang、Y. Ye、M. Xiao、H. V. Poor 和 M. Skoglund，“智能反射面增强型无小区网络的分布式波束成形设计”，IEEE无线通信快报，第10卷，第3期，第673–677页，2021年3月。[38] J. An、C. Xu、L. Wang、Y. Liu、L. Gan 和 L. Hanzo，“可重构智能表面辅助多用户通信中叠加的直达链路和反射链路的联合训练”，IEEE绿色通信与网络汇刊，第6卷，第2期，第739–754页，2022年6月。[39] J. An、C. Xu、Q. Wu、D. W. K. Ng、M. D. Renzo、C. Yuen 和 L. Hanzo，“可重构智能表面的基于码本的解决方案及其开放挑战”，IEEE无线通信，第1–8页，2022年，提前发表。[40] W. Xu、J. An、Y. Xu、C. Huang、L. Gan 和 C. Yuen，“基于深度学习的RIS辅助MU-MISO网络时变信道预测”，IEEE认知通信与网络汇刊，第8卷，第4期，第1802–1815页，2022年。[41] H. Huang、S. Guo、G. Gui、Z. Yang、J. Zhang、H. Sari 和 F. Adachi，“物理层5G无线技术的深度学习：机遇、挑战与解决方案”，IEEE无线通信，第27卷，第1期，第214–222页，2020年2月。[42] V. Monga、Y. Li 和 Y. C. Eldar，“算法展开：用于信号与图像处理的可解释、高效深度学习”，IEEE信号处理杂志，第38卷，第2期，第18–44页，2021年3月。[43] B. Xin、Y. Wang、W. Gao、D. Wipf 和 B. Wang，“深度网络能实现最大稀疏性吗？”，神经信息处理系统进展，第29卷，2016年。[44] J. Liu 和 X. Chen，“ALISTA：解析权重不逊于LISTA中的学习得到的权重”，载于ICLR论文集，2019年。[45] X. Chen、J. Liu、Z. Wang 和 W. Yin，“展开的ISTA及其实用权重和阈值的理论线性收敛”，神经信息处理系统进展，第31卷，2018年。[46] Y. Yang、J. Sun、H. Li 和 Z. Xu，“ADMM-CSNet：一种用于图像压缩感知的深度学习方法”，IEEE模式分析与机器智能汇刊，第42卷，第3期，第521–538页，2020年3月。[47] S. A. H. Hosseini、B. Yaman、S. Moeller、M. Hong 和 M. Akc¸akaya，“用于加速MRI的稠密循环神经网络：优化算法的历史感知展开”，IEEE信号处理专题期刊，第14卷，第6期，第1280–1291页，2020年10月。

[48] Y. Li、M. Tofighi、J. Geng、V. Monga 和 Y. C. Eldar，“通过算法展开实现高效且可解释的深度盲图像去模糊”，*IEEE*计算成像汇刊，第6卷，第666–681页，2020年1月。[49] X. Zhang、Y. Lu、J. Liu 和 B. Dong，“动态展开循环复原器：一种用于图像复原的移动端点控制方法”，*arXiv*预印本 *arXiv:1805.07709*，2018年。[50] J. R. Hershey、J. L. Roux 和 F. Weninger，“深度展开：基于模型启发的新型深度架构”，*arXiv*预印本 *arXiv:1409.2574*，2014年。[51] S. Lohit、D. Liu、H. Mansour 和 P. T. Boufounos，“用于多光谱图像融合的展开式投影梯度下降”，载于*IEEE*国际声学、语音与信号处理会议论文集，英国布莱顿，2019年5月，第7725–7729页。[52] P. Wang、J. Fang、H. Duan 和 H. Li，“智能反射面辅助毫米波系统的压缩信道估计”，*IEEE*信号处理快报，第27卷，第905–909页，2020年5月。[53] K. Shen 和 W. Yu，“通信系统的分式规划——第二部分：基于匹配的上行链路调度”，*IEEE*信号处理汇刊，第66卷，第10期，第2631–2644页，2018年5月。[54] 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。[55] Y. Ye、H. Chen、Z. Ma 和 M. Xiao，“基于并行随机游走的分布式共识优化”，*IEEE*通信快报，第24卷，第2期，第391–395页，2020年2月。[56] X. Yu、J.-C. Shen、J. Zhang 和 K. B. Letaief，“毫米波MIMO系统混合预编码的交替最小化算法”，*IEEE*信号处理专题期刊，第10卷，第3期，第485–500页，2016年4月。[57] G. Interdonato、M. Karlsson、E. Bj¨ornson 和 E. G. Larsson，“无小区大规模MIMO的局部部分迫零预编码”，*IEEE*无线通信汇刊，第19卷，第7期，第4758–4774页，2020年7月。