



(12) 发明专利

(10) 授权公告号 CN 113411112 B

(45) 授权公告日 2023. 03. 28

(21) 申请号 202110645677.0

(22) 申请日 2021.06.09

(65) 同一申请的已公布的文献号
申请公布号 CN 113411112 A

(43) 申请公布日 2021.09.17

(73) 专利权人 西安交通大学
地址 710049 陕西省西安市咸宁西路28号

(72) 发明人 徐静 王樵之 许崇斌 王磊

(74) 专利代理机构 西安通大专利代理有限责任
公司 61200
专利代理师 朱海临

(51) Int. Cl.
H04B 7/06 (2006.01)

(56) 对比文件

CN 110988854 A, 2020.04.10

US 2013304266 A1, 2013.11.14

CN 106982085 A, 2017.07.25

成文婧等. 协同系统鲁棒波束成形算法研究. 《电波科学学报》. 2012, (第04期), 全文.

审查员 郭云领


权利要求书8页 说明书13页 附图2页

(54) 发明名称

一种分布式鲁棒多小区协作波束成形ADMM网络的构建方法

(57) 摘要

本发明公开了一种分布式鲁棒多小区协作波束成形ADMM网络的构建方法, 针对最坏情况信干噪比 (SINR) 约束的多小区协作波束成形 (MCBF) 设计问题。从多小区鲁棒波束成形ADMM算法出发, 将本地波束成形向量求解子问题通过Schur补定理与对角矩阵转化为标准形式。然后通过HKM方向原始对偶内点法求解本地波束成形向量求解子问题, 将隐式迭代转化为显式迭代。通过“展开”思想, 将ADMM算法映射到一个数据流程图, 并将原ADMM算法的各个计算环节转换为具有可学习参数的神经元, 构建MCBF-ADMM网络。通过端到端学习, 实现数据驱动的最优参数设计。有效的提高了波束成形的精度, 增加了波束成形对于不同信道环境的适应性。



1. 一种分布式鲁棒多小区协作波束成形ADMM网络的构建方法,其特征在于,包括以下步骤:

步骤1, 优化问题的转化

利用半定义松弛 (SDR) 对最坏情况下的鲁棒MCBF设计进行“线性化”; 利用线性矩阵不等式LMI的有限凸约束, 将无穷多个约束表达为有限凸约束; 将上述鲁棒MCBF设计转化为半定规划问题; 通过ADMM将半定规划问题转化为三个步骤的迭代求解:

$Z^{(n,q)}$ 步骤: 每个基站处求解本地波束成形矩阵;

$X^{(n,q)}$ 步骤: 更新松弛变量;

$M^{(n,q)}$ 步骤: 更新对偶变量;

半定规划问题如下:

$$\begin{aligned} \min_{\{\mathbf{W}_{nk}\}, \{\lambda_{mnk}\}, \{t_{mnk}\}} & \sum_{n=1}^{N_c} \alpha_n \left(\sum_{k=1}^K \text{Tr}(\mathbf{W}_{nk}) \right) \\ \text{s.t. } & \Phi_{nk}(\{\mathbf{W}_{ni}\}_{i=1}^K, \{t_{mnk}\}_m, \lambda_{nnk}) \geq \mathbf{0} \\ & \Psi_{mnk}(\{\mathbf{W}_{mi}\}_{i=1}^K, t_{mnk}, \lambda_{mnk}) \geq \mathbf{0} \quad \forall m \neq n \\ & \mathbf{W}_{nk} \geq \mathbf{0}, \lambda_{mnk} \geq 0 \quad \forall m, n, k \end{aligned} \quad (1)$$

其中: $t_{mnk} = \max \mathbf{h}_{mnk}^H (\sum_{i=1}^K \mathbf{W}_{mi}) \mathbf{h}_{mnk}$ s.t. $\mathbf{e}_{mnk}^H \mathbf{Q}_{mnk} \mathbf{e}_{mnk} \leq 1$;

$$\begin{aligned} & \Phi_{nk}(\{\mathbf{W}_{ni}\}_{i=1}^K, \{t_{mnk}\}_m, \lambda_{nnk}) \\ \triangleq & \begin{bmatrix} \mathbf{U}_{nk} + \lambda_{nnk} \mathbf{Q}_{nnk} & \mathbf{U}_{nk} \hat{\mathbf{h}}_{nnk} \\ \hat{\mathbf{h}}_{nnk}^H \mathbf{U}_{nk} & \hat{\mathbf{h}}_{nnk}^H \mathbf{U}_{nk} \hat{\mathbf{h}}_{nnk} - \lambda_{nnk} - \sum_{m \neq n} t_{mnk} - \sigma_{nk}^2 \end{bmatrix} \geq \mathbf{0} \end{aligned} \quad (2)$$

$$\begin{aligned} & \Psi_{mnk}(\{\mathbf{W}_{mi}\}_{i=1}^K, t_{mnk}, \lambda_{mnk}) \\ \triangleq & \begin{bmatrix} -\sum_{i=1}^K \mathbf{W}_{mi} + \lambda_{mnk} \mathbf{Q}_{mnk} & -\left(\sum_{i=1}^K \mathbf{W}_{mi}\right) \hat{\mathbf{h}}_{mnk} \\ -\hat{\mathbf{h}}_{mnk}^H \left(\sum_{i=1}^K \mathbf{W}_{mi}\right) & -\hat{\mathbf{h}}_{mnk}^H \left(\sum_{i=1}^K \mathbf{W}_{mi}\right) \hat{\mathbf{h}}_{mnk} + t_{mnk} - \lambda_{mnk} \end{bmatrix} \end{aligned} \quad (3)$$

$\geq \mathbf{0}, m \in \mathcal{N}_c \setminus \{n\}$

其中: $\mathbf{U}_{nk} \triangleq \frac{1}{\gamma_{nk}} \mathbf{W}_{nk} - \sum_{i \neq k}^K \mathbf{W}_{ni}$;

迭代求解完成后, 在 $Z^{(n,q)}$ 子步骤完成后得到最优波束成形矩阵;

所述求解三个迭代步骤的具体方法如下:

$Z^{(n,q)}$ 步骤: 每个基站处求解本地波束成形矩阵, 求解如下式的问题:

$$\begin{aligned}
& \{\mathbf{t}_n(q+1), p_n(q+1)\} \\
& = \arg \min \left(\alpha_n p_n + \frac{c}{2} \|\mathbf{E}_n \mathbf{t}(q) - \mathbf{t}_n\|^2 \right. \\
& \left. + \frac{c}{2} (\rho_n(q) - p_n)^2 - \mathbf{v}_n^T(q) \mathbf{t}_n - \mu_n(q) p_n \right) \\
& \text{s.t. } (\{\mathbf{W}_{nk}\}_k, \{\lambda_{nmk}\}_{m,k}, \mathbf{t}_n, p_n) \in \mathcal{C}_n
\end{aligned} \tag{4}$$

其中, $\alpha_n > 0$ 是基站 BS_n 的功率权重, $\rho_n \geq 0$ 是松弛变量, $\frac{c}{2} \|\mathbf{E}_n \mathbf{t}(q) - \mathbf{t}_n\|^2$ 与 $\frac{c}{2} \sum_{n=1}^{N_c} (\rho_n - p_n)^2$ 是惩罚项, c 是惩罚参数;

定义以下变量:

$$\begin{aligned}
\mathbf{t} & = \left[[t_{121}, \dots, t_{12K}], \dots, [t_{N_c(N_c-1)1}, \dots, t_{N_c(N_c-1)K}] \right]^T \in \mathbb{R}^{N_c(N_c-1)K} \\
\mathbf{t}_n & = \left[[T_{n1}, \dots, T_{nK}], [t_{n11}, \dots, t_{n1K}], \dots, [t_{nN_c1}, \dots, t_{nN_cK}] \right]^T \in \mathbb{R}_+^{N_c K}, n \in \mathcal{N}_t \\
T_{nk} & = \sum_{m \neq n}^{N_c} t_{mnk}
\end{aligned} \tag{5}$$

$\mathbf{E}_n \in \{0,1\}^{N_c K \times N_c(N_c-1)K}$ 是 \mathbf{t} 到 \mathbf{t}_n 的映射矩阵;

对于 $\forall n \in \mathcal{N}_c$ 集合 \mathcal{C}_n 定义为:

$$\begin{aligned}
\mathcal{C}_n & = \{(\{\mathbf{W}_{nk}\}_k, \{\lambda_{nmk}\}_{m,k}, \mathbf{t}_n, p_n) \mid \\
& \Phi_{nk}(\{\mathbf{W}_{ni}\}_{i=1}^K, T_{nk}, \lambda_{nnk}) \geq \mathbf{0}, \forall k, \\
& \Psi_{nmk}(\{\mathbf{W}_{ni}\}_{i=1}^K, t_{nmk}, \lambda_{nmk}) \geq \mathbf{0} \forall m \neq n, k, \\
& \lambda_{nmk} \geq 0, \forall m, k, \sum_{k=1}^K \text{Tr}(\mathbf{W}_{nk}) = p_n, \\
& \mathbf{W}_{nk} \geq \mathbf{0}, \forall k, T_{nk} \geq 0, \forall k\} \\
& = \hat{\mathbf{h}}_{mnk} + \mathbf{e}_{mnk}, \forall m, n
\end{aligned} \tag{6}$$

$$\in \mathcal{N}_c, k \in \mathcal{K}$$

$X^{(n,q)}$ 步骤:更新松弛变量:

$$\mathbf{t}(q+1) = \mathbf{E}^\dagger(\tilde{\mathbf{t}}(q+1) - \frac{1}{c} \tilde{\mathbf{v}}(q)) \tag{7}$$

$$\rho_n(q+1) = p_n(q+1) - \frac{1}{c} \mu_n(q), n \in \mathcal{N}_c \tag{8}$$

式中 $\tilde{\mathbf{t}}(q+1) = [\mathbf{t}_1^T(q+1), \dots, \mathbf{t}_{N_c}^T(q+1)]^T$, $\tilde{\mathbf{v}}(q) = [\mathbf{v}_1^T(q), \dots, \mathbf{v}_{N_c}^T(q)]^T$, $\mathbf{E} = [\mathbf{E}_1^T, \dots, \mathbf{E}_{N_c}^T]^T$;

$M^{(n,q)}$ 步骤:更新对偶变量:

$$v_n(q+1) = v_n(q) + c(\mathbf{E}_n \mathbf{t}(q+1) - \mathbf{t}_n(q+1)) \tag{9}$$

$$\mu_n(q+1) = \mu_n(q) + c(\rho_n(q+1) - p_n(q+1)) \quad (10)$$

式中 $\mathbf{n} \in \mathcal{N}_c$;

令 Q 表示迭代求解的总次数, 上述三个迭代步骤求解完成后, 在 $Z^{(n, Q)}$ 子步骤完成后得到最优波束成形矩阵 $\{\mathbf{W}_{nk}^*\}$;

步骤2, 将本地波束成形优化问题转化为标准SDP问题; 具体方法如下:

标准SDP问题:

$$\begin{aligned} \max_{\mathbf{y}} \quad & \mathbf{b}^T \mathbf{y} \\ \text{s.t.} \quad & \sum_{i=1}^m y_i \mathbf{A}_i + \mathbf{S} = \mathbf{C} \\ & \mathbf{S} \geq 0 \end{aligned} \quad (11)$$

其中 $\mathbf{b} \in \mathbb{R}^m$, $\mathbf{A}_i \in \mathbb{S}^n$, $\mathbf{C} \in \mathbb{S}^n$, $\mathbf{S} \in \mathbb{S}^n$, y_i 代表向量 \mathbf{y} 的第 i 个元素, m 与 n 分别表示优化向量与约束矩阵的维度;

添加松弛变量 P'_n 与 T'_{ni} , 使满足:

$$\begin{aligned} P'_n &\geq (\rho_n(q) - p_n)^2 \\ T'_{ni} &\geq (\eta_{ni}(q) - t_{ni})^2, i = 1, \dots, N_c K, \\ \sum_{i=1}^{N_c K} T'_{ni} &\geq \|\mathbf{E}_n \mathbf{t}(q) - \mathbf{t}_n\|^2 \end{aligned} \quad (12)$$

其中 $\boldsymbol{\eta}_n(q) \triangleq \mathbf{E}_n \mathbf{t}(q)$, $\eta_{ni}(q)$ 与 t_{ni} 分别表示 $\boldsymbol{\eta}_n(q)$ 与 \mathbf{t}_n 的第 i 个元素; 求解本地波束成形的非线性SDP问题转化为:

$$\begin{aligned} & \{\mathbf{t}_n(q+1), p_n(q+1)\} \\ & = \arg \min \left(\alpha_n p_n + \frac{c}{2} \sum_{i=1}^{N_c K} T'_{ni} + \frac{c}{2} P'_n - \mathbf{v}_n^T(q) \mathbf{t}_n - \mu_n(q) p_n \right) \\ & \quad \text{s.t. } (\{\mathbf{W}_{nk}\}_k, \{\lambda_{nmk}\}_{m,k}, \mathbf{t}_n, p_n) \in \mathcal{C}_n \\ & \quad P'_n \geq (\rho_n(q) - p_n)^2 \\ & \quad T'_{ni} \geq (\eta_{ni}(q) - t_{ni})^2, i = 1, \dots, N_c K, n = 1, \dots, N_c \end{aligned} \quad (13)$$

利用Schur定理, 将非线性约束转化为半正定约束:

$$\begin{aligned} P'_n \geq (\rho_n(q) - p_n)^2 &\Rightarrow \boldsymbol{\Omega}_n \triangleq \begin{bmatrix} P'_n & \rho_n(q) - p_n \\ \rho_n(q) - p_n & 1 \end{bmatrix} \geq 0 \\ T'_{ni} \geq (\eta_{ni}(q) - t_{ni})^2 &\Rightarrow \mathbf{Y}_{ni} \triangleq \begin{bmatrix} T'_{ni} & \eta_{ni}(q) - t_{ni} \\ \eta_{ni}(q) - t_{ni} & 1 \end{bmatrix} \geq 0 \end{aligned} \quad (14)$$

至此, 非线性SDP问题转化为以下具有LMI约束的线性SDP问题;

$$\begin{aligned}
& \{\mathbf{t}_n(q+1), p_n(q+1)\} \\
& = \arg \min \left(\alpha_n p_n + \frac{c}{2} \sum_{i=1}^{N_c K} T'_{ni} + \frac{c}{2} P'_n - \mathbf{v}_n^T(q) \mathbf{t}_n - \mu_n(q) p_n \right) \\
& \quad \text{s.t. } (\{\mathbf{W}_{nk}\}_k, \{\lambda_{nmk}\}_{m,k}, \mathbf{t}_n, p_n) \in \mathbf{C}_n \\
& \quad \quad \mathbf{\Omega}_n \geq 0, \mathbf{Y}_{ni} \geq 0, i = 1, \dots, N_c K
\end{aligned} \tag{15}$$

将多个离散的LMI约束转换成一个LMI约束,即构造对角矩阵:

$$\begin{aligned}
\mathbf{D}_n & \stackrel{\Delta}{=} \text{diag}(\Phi_{n1}, \dots, \Phi_{nK}, \Psi_{nm1}, \dots, \Psi_{nmK} \\
& \quad \mathbf{W}_{n1}, \dots, \mathbf{W}_{nK}, \lambda_{nm1}, \dots, \lambda_{nmK}, T_{n1}, \dots, T_{nK} \\
& \quad \mathbf{Y}_{n1}, \dots, \mathbf{Y}_{nN_c K}, \mathbf{\Omega}_n) \geq 0
\end{aligned} \tag{16}$$

其中 $m, n \in \mathcal{N}_c, m \neq n$; 最终线性SDP问题转化为:

$$\begin{aligned}
\{\mathbf{t}_n(q+1), p_n(q+1)\} & = \arg \min \left(\alpha_n p_n + \frac{c}{2} \sum_{i=1}^{N_c(N_c-1)K} T'_{ni} \right. \\
& \quad \left. + \frac{c}{2} P'_n - \mathbf{v}_n^T(q) \mathbf{t}_n - \mu_n(q) p_n \right) \\
& \quad \text{s.t. } \mathbf{D}_n \geq 0
\end{aligned} \tag{17}$$

将 $Z^{(n,q)}$ 与标准SDP问题联系,得到:

$$\begin{aligned}
\mathbf{y} & \rightarrow \mathbf{y}_n^z(q) = [\text{svec}(\mathbf{W}_{n1})^T, \dots, \text{svec}(\mathbf{W}_{nK})^T, \\
& \quad \lambda_{nm1}, \dots, \lambda_{nmK}, \mathbf{t}_n^T, T'_{n1}, \dots, T'_{nN_c K}, P'_n]^T \\
\mathbf{b}^T \mathbf{y} & \rightarrow - \left(\alpha_n p_n + \frac{c}{2} \sum_{i=1}^{N_c K} T'_{ni} + \frac{c}{2} P'_n - \mathbf{v}_n^T(q) \mathbf{t}_n - \mu_n(q) p_n \right) \\
\mathbf{S} & \rightarrow \mathbf{D}_n, \mathbf{b} \rightarrow \mathbf{b}_n^z(q), \mathbf{A}_i \rightarrow \mathbf{A}_{ni}^z(q), (i = 1, \dots, N_y), \mathbf{C} \rightarrow \mathbf{C}_n^z(q)
\end{aligned} \tag{18}$$

其中, N_y 为 $\mathbf{y}_n^z(q)$ 的元素个数; 通过对目标函数和约束条件的分解, 得到 $\mathbf{b}_n^z(q)$, $\mathbf{C}_n^z(q)$ 和 $\mathbf{A}_{ni}^z(q)$ 的显示表达式; 使用隐式表达式代替; 至此, $Z^{(n)}$ 问题转化为如下标准形式的SDP问题:

$$\begin{aligned}
\mathbf{Z}^{(n,q)}: & \max_{\mathbf{y}_n^z(q)} \mathbf{b}_n^{z,T}(q) \mathbf{y}_n^z(q) \\
& \text{s.t. } \sum_{i=1}^m \mathbf{y}_i(q) \mathbf{A}_{ni}^z(q) + \mathbf{D}_n = \mathbf{C}_n^z(q) \\
& \quad \mathbf{D}_n \geq 0
\end{aligned} \tag{19}$$

步骤3, 通过定义数据流图与神经元, 构造ADMM网络; 具体方法如下:

通过展开方法, 将ADMM算法映射到数据流图与神经元上; 整个网络分为 N_c 个子网络, 每个子网络对应每个基站处的本地网络; 在输入层中, 输入复数信道的I/Q变换, 即输入层输

$\lambda[\mathcal{R}(\mathbf{h}_{nmk}), \mathcal{J}(\mathbf{h}_{nmk})]$;

其中, n 表示基站的编号, q 表示网络的层编号, l 表示子网络的层编号;输入层输入数据后, ADMM算法展开为网络, ADMM算法的第 q 次迭代对应数据流图中的第 q 层;在图中的第 q 层, ADMM算法迭代时的3个子步骤被映射为具有可学习参数的3种节点类型, 即本地波束成形矩阵求解节点 $Z^{(n,q)}$, 松弛变量更新节点 $X^{(n,q)}$, 对偶变量更新节点 $M^{(n,q)}$; 3种节点类型的运算, 组合为整个网络的一层;整个数据流图是由多个同样的层构成的;

输出层与输入层对应, 获得实部与虚部分开的波束成形向量;在最终的网络训练中, 选取功率的归一化均方误差NRMSE作为损失函数来训练网络;输入一组信道实现向量后, 数据在图中流动, 最终得到波束成形向量的决策;

步骤4, 通过端到端监督学习得到最终的网络;具体方法如下:

选取归一化根均方误差NRMSE作为损失函数来训练网络;给定训练数据时, 网络输出与最优功率之间的损失函数定义为:

$$E(\Theta) = \frac{\|P^{Net}(\Theta, Q) - P^*\|_2}{\|P^*\|_2} \quad (27)$$

式中, P^* 为求解式(1)表示的集中式优化问题得到的最优波束成形向量的总功率, $P^{Net}(\Theta, Q)$ 为网络参数是 Θ 网络迭代 Q 层的ADMM-Net输出的波束成形向量对应的发射总功率:

$$P^{Net}(\Theta, Q) = \sum_{n=1}^{N_c} p_n(Q+1);$$

训练得到最终的网络后, 输入信道向量通过ADMM网络即可得到预测的最优的多小区协作波束成型矩阵 $\{\mathbf{W}_{nk}^*\}$, 使用秩一分解 $\mathbf{W}_{nk}^* = \mathbf{w}_{nk}^* (\mathbf{w}_{nk}^*)^H$ 得到最优波束成形向量 $\{\mathbf{w}_{nk}^*\}$ 。

2. 根据权利要求1所述的分布式鲁棒多小区协作波束成形ADMM网络的构建方法, 其特征在于, 所述步骤1中最坏情况下的鲁棒MCBF设计如下:

$$\begin{aligned} \min_{\{\mathbf{w}_{nk}\}_{n,k}} & \sum_{n=1}^{N_c} \alpha_n \left(\sum_{k=1}^K \|\mathbf{w}_{nk}\|^2 \right) \\ \text{s.t.} & \text{SINR}_{nk}(\{\mathbf{w}_{m1}, \dots, \mathbf{w}_{mK}\}_{m=1}^{N_c}, \{\hat{\mathbf{h}}_{mnk} + \mathbf{e}_{mnk}\}_{m=1}^{N_c}) \geq \gamma_{nk} \\ & \forall \mathbf{e}_{mnk}^H \mathbf{Q}_{mnk} \mathbf{e}_{mnk} \leq 1, m, n \in \mathcal{N}_c, k \in \mathcal{K} \end{aligned}$$

式中, $\alpha_n > 0$ 为基站 BS_n 的功率权重, $\mathbf{w}_{nk} \in \mathbb{C}^{N_t}$ 是基站 BS_n 处发送移动台 MS_{nk} 数据的波束成形向量, SINR如下:

$$\begin{aligned} \text{SINR}_{nk} & \left(\{\mathbf{w}_{m1}, \dots, \mathbf{w}_{mK}\}_{m=1}^{N_c}, \{\hat{\mathbf{h}}_{mnk} + \mathbf{e}_{mnk}\}_{m=1}^{N_c} \right) \\ & = \frac{|\mathbf{h}_{nnk}^H \mathbf{w}_{nk}|^2}{\sum_{i \neq k}^K \cdot |\mathbf{h}_{nnk}^H \mathbf{w}_{ni}|^2 + \sum_{m \neq n}^{N_c} \cdot \sum_{i=1}^K \cdot |\mathbf{h}_{mnk}^H \mathbf{w}_{mi}|^2 + \sigma_{nk}^2} \end{aligned}$$

3. 根据权利要求1所述的分布式鲁棒多小区协作波束成形ADMM网络的构建方法, 其特征在于, 所述Schur定理如下:

设 $\mathbf{A} = \begin{bmatrix} \mathbf{B} & \mathbf{C}^T \\ \mathbf{C} & \mathbf{D} \end{bmatrix}$ 是一个对称矩阵, 其中 \mathbf{B} 是 $k \times k$ 的块矩阵, \mathbf{D} 为 1×1 的块矩阵; 假设 \mathbf{B} 是正定的, 则 \mathbf{A} 是正定或半正定的当且仅当矩阵 $\mathbf{D} - \mathbf{C}\mathbf{B}^{-1}\mathbf{C}^T$ 为正定或半正定的; 矩阵 $\mathbf{D} - \mathbf{C}\mathbf{B}^{-1}\mathbf{C}^T$ 称为矩阵 \mathbf{A} 中 \mathbf{B} 的 Schur 补。

4. 根据权利要求1所述的分布式鲁棒多小区协作波束成形ADMM网络的构建方法, 其特征在于, 所述标准SDP问题的原始对偶内点法的计算方法如下:

步骤2-1: 给定初始迭代 $(\mathbf{X}(1), \mathbf{y}(1), \mathbf{S}(1))$, 其中 $\mathbf{X}(1), \mathbf{S}(1)$ 满足正定性; 设置步长 α, β ; 设置终止条件 δ ;

步骤2-2: 求解第1次迭代的HKM方向 $(\Delta \mathbf{X}(1), \Delta \mathbf{y}(1), \Delta \mathbf{S}(1))$;

解集 $(\mathbf{X}, \mathbf{y}, \mathbf{S})$ 更新: $\mathbf{X}(1+1) = \mathbf{X}(1) + \alpha \Delta \mathbf{X}(1)$;

$\mathbf{y}(1+1) = \mathbf{y}(1) + \beta \Delta \mathbf{y}(1), \mathbf{S}(1+1) = \mathbf{S}(1) + \beta \Delta \mathbf{S}(1)$

直到满足终止条件 relgap 和 ϕ 都小于 δ ;

$$\text{其中 } \text{relgap} = \frac{\mathbf{x} \cdot \mathbf{s}}{1 + \max(|\mathbf{C} \cdot \mathbf{X}|, |\mathbf{b}^T \mathbf{y}|)}, \phi = \max\left(\frac{\|\mathbf{b} - \mathbf{A}\mathbf{x}\|}{1 + \|\mathbf{b}\|}, \frac{\|\mathbf{c} - \mathbf{s} - \mathbf{A}^T \mathbf{y}\|}{1 + \|\mathbf{C}\|}\right), \mathbf{A} = \begin{bmatrix} \text{svec}(\mathbf{A}_1)^T \\ \vdots \\ \text{svec}(\mathbf{A}_m)^T \end{bmatrix},$$

$\mathbf{x} = \text{svec}(\mathbf{X}), \mathbf{s} = \text{svec}(\mathbf{S}), \mathbf{c} = \text{svec}(\mathbf{C})$; 此处 m 代表优化变量 \mathbf{y} 的维度。

5. 根据权利要求1所述的分布式鲁棒多小区协作波束成形ADMM网络的构建方法, 其特征在于, 所述步骤3中构造ADMM网络的具体方法如下:

初始化神经元 $\mathbf{Z}_0^{(n,q)}$; $\mathbf{Z}_0^{(n,q)}$ 执行基于HKM方向原始对偶内点法的初始化, 并将其它节点的输入整理成可代入标准形式; 该神经元输入变量为 $t(q), \rho_n(q), v_n(q), \mu_n(q)$ 与信道矩阵 $\mathbf{H} = [\mathbf{h}_{111}, \dots, \mathbf{h}_{11k}, \dots, \mathbf{h}_{N_c N_c k}]$, \mathbf{H} 视为全局变量, 在所有网络层共享, 输出变量为后续原始对偶内点法的初始迭代 $(\mathbf{X}_n(q, 1), \mathbf{y}_n(q, 1), \mathbf{S}_n(q, 1))$, 以及标准SDP问题的信息 $\mathbf{b}_n(q), \mathbf{C}_n(q), \mathbf{A}_{ni}(q), i = 1, \dots, N_y$:

$$\mathbf{X}_n(q, 1) = \mathbf{I}_{N_D}, \mathbf{y}_n(q, 1) = \mathbf{0}_{N_y \times 1}, \mathbf{S}_n(q, 1) = \mathbf{I}_{N_D}$$

$$\mathbf{b}_n(q) = \mathbf{b}_n^z(q), \mathbf{C}_n(q) = \mathbf{C}_n^z(q), \mathbf{A}_{ni}(q) = \mathbf{A}_{ni}^z(q) \quad (20)$$

式中 N_D 为约束矩阵的阶数, N_y 为优化变量的数量; 在本地波束成形矩阵求解节点 $\mathbf{Z}^{(n,q)}$ 中共享 $\mathbf{b}_n(q), \mathbf{C}_n(q), \mathbf{A}_{ni}(q), i = 1, \dots, N_y$; 学习参数 $\mathbf{c}_z^{(n,q)}$ 是从惩罚参数 c 扩展而来, 包含在 $\mathbf{b}_n(q)$ 中;

中心路径方向求解神经元 $\mathbf{Z}_1^{(n,q,l)}$:

该神经元的输入变量为 $\mathbf{X}_n(q, 1), \mathbf{y}_n(q, 1), \mathbf{S}_n(q, 1)$, 输出变量为算法解集的更新方向 $\Delta \mathbf{X}_n(q, 1), \Delta \mathbf{y}_n(q, 1), \Delta \mathbf{S}_n(q, 1)$; $\mathbf{Z}_1^{(n,q,l)}$ 执行基于HKM方向原始对偶内点法的中心路径方向求解, 得到第1次迭代对应的变量更新HKM方向;

$$\begin{aligned}
\Delta \mathbf{y}_n(q, l) &= \mathbf{M}_n(q, l)^{-1} \mathbf{h}_n(q, l), \\
\Delta \mathbf{s}_n(q, l) &= \mathbf{R}_{dn}(q, l) - \mathbf{A}_{sn}(q)^T \Delta \mathbf{y}_n(q, l), \\
\Delta \mathbf{x}_n(q, l) &= \mathcal{E}_n^{-1}(q, l) \text{svec}(\mathbf{R}_{cn}(q, l)) - \mathcal{E}_n^{-1}(q, l) \mathcal{F}_n(q, l) \Delta \mathbf{s}_n(q, l), \\
\mathbf{M}_n(q, l) &= \mathbf{A}_{sn}(q)^T \mathcal{E}_n^{-1}(q, l) \mathcal{F}_n(q, l) \mathbf{A}_{sn}(q), \\
\mathbf{h}_n(q, l) &= \mathbf{r}_{pn}(q, l) - \mathbf{A}_{sn}(q)^T \mathcal{E}_n^{-1}(q, l) \text{svec}(\mathbf{R}_{cn}(q, l)) \\
&+ \mathbf{A}_{sn}(q)^T \mathcal{E}_n^{-1}(q, l) \mathcal{F}_n(q, l) \mathbf{R}_{dn}(q, l), \\
\mathbf{r}_{pn}(q, l) &= \mathbf{b}_n(q) - \mathbf{A}_{sn}(q) \mathbf{x}_n(q, l), \\
\mathbf{R}_{dn}(q, l) &= \mathbf{c}_n(q) - \mathbf{s}_n(q, l) - \mathbf{A}_{sn}(q)^T \mathbf{y}_n(q, l), \\
\mathcal{E}_n(q, l) &= \mathbf{P}_n(q, l) \circledast \mathbf{P}_n^{-T}(q, l) \mathbf{s}_n(q, l), \\
\mathcal{F}_n(q, l) &= \mathbf{P}_n(q, l) \mathbf{x}_n(q, l) \circledast \mathbf{P}_n^{-T}(q, l), \\
\mathbf{A}_{sn}(q) &= \begin{bmatrix} \text{svec}(\mathbf{A}_{n1}(q))^T \\ \vdots \\ \text{svec}(\mathbf{A}_{nN_y}(q))^T \end{bmatrix}, \\
\mathbf{x}_n(q, l) &= \text{svec}(\mathbf{X}_n(q, l)), \\
\mathbf{s}_n(q, l) &= \text{svec}(\mathbf{S}_n(q, l)), \\
\mathbf{c}_n(q) &= \text{svec}(\mathbf{C}_n(q))
\end{aligned} \tag{21}$$

式中 $\mu \triangleq \mathbf{X}_n(q, l) \cdot \mathbf{S}_n(q, l) / N_D$, 用 a_{ij} 表示矩阵 \mathbf{A} 第 i 行第 j 列的元素, 则 $\text{svec}(\mathbf{A})$ 是矩阵线性化算子 $\text{svec}(\mathbf{A}) \triangleq [a_{11}, \sqrt{2}a_{12}, a_{22}, \sqrt{2}a_{13}, \sqrt{2}a_{23}, a_{33}, \dots]$, \circledast 表示矩阵的克罗内克积; 在 HKM 方向中的对称化算子为 $\mathbf{P}_n(q, l) = \mathbf{S}_n^{\frac{1}{2}}(q, l)$; $\delta^{(n, q, l)}$ 为可学习参数, 来自原始对偶内点法的步长 δ ;

解集更新神经元 $Z_2^{(n, q, l)}$:

该神经元输入参数为 $\Delta X_n(q, l)$, $\Delta y_n(q, l)$, $\Delta S_n(q, l)$, $X_n(q, l)$, $y_n(q, l)$, $S_n(q, l)$, 输出变量为解集更新值; $Z_2^{(n, q, l)}$ 执行基于 HKM 方向原始对偶内点法的解集更新:

$$\begin{aligned}
\mathbf{X}_n(q, l+1) &= \mathbf{X}_n(q, l) + \alpha_n(q, l) \Delta \mathbf{X}_n(q, l) \\
\mathbf{y}_n(q, l+1) &= \mathbf{y}_n(q, l) + \beta_n(q, l) \Delta \mathbf{y}_n(q, l) \\
\mathbf{S}_n(q, l+1) &= \mathbf{S}_n(q, l) + \beta_n(q, l) \Delta \mathbf{S}_n(q, l) \\
\alpha_n(q, l) &= \min\left(1, \epsilon_n(q, l) \frac{-1}{\lambda_{\min}((\mathbf{X}_n(q, l))^{-1} \Delta \mathbf{X}_n(q, l))}\right) \\
\beta_n(q, l) &= \min\left(1, \epsilon_n(q, l) \frac{-1}{\lambda_{\min}((\mathbf{S}_n(q, l))^{-1} \Delta \mathbf{S}_n(q, l))}\right) \\
\epsilon_n(q, l) &= 0.9 + 0.09 \min(\alpha_n(q, l), \beta_n(q, l))
\end{aligned} \tag{22}$$

其中, $\Delta X_n(q, l) = \text{smat}(\Delta x_n(q, l))$, $\Delta S_n(q, l) = \text{smat}(\Delta s_n(q, l))$, $\text{smat}(\cdot)$ 是 $\text{svec}(\cdot)$ 的逆操作; 式中 $\alpha_n(q, l)$ 与 $\beta_n(q, l)$ 为解集更新的步长; 在计算 ϵ 时, 首先将 ϵ 的初值设置为 1, 得到预测的 $\alpha_n(q, l)$ 与 $\beta_n(q, l)$, 然后计算 $\epsilon_n(q, l)$;

在网络的最后一层, $Z^{(n,q)}$ 节点除了计算得到 $p_n(Q+1)$ 外, 还输出最优波束成形矩阵 $\{\mathbf{W}_{nk}^*\}$;

松弛变量更新节点 $X^{(n,q)}$; 该节点根据式 (23) 与式 (24) 更新松弛变量, 包含 $X_t^{(n,q)}$ 与 $X_p^{(n,q)}$ 两类神经元;

干扰松弛变量更新神经元 $X_t^{(n,q)}$:

$$\mathbf{t}(q+1) = \mathbf{E}^\dagger(\tilde{\mathbf{t}}(q+1) - \frac{1}{c_t^{(n,q)}} \tilde{\mathbf{v}}(q)) \quad (23)$$

该神经元输入变量 $\tilde{\mathbf{t}}(q+1) = [\mathbf{t}_1^T(1, q+1), \dots, \mathbf{t}_{N_c}^T(N_c, q+1)]^T$ 、 $\tilde{\mathbf{v}}(q) = [\mathbf{v}_1^T(n, q), \dots, \mathbf{v}_{N_c}^T(n, q)]^T$, \mathbf{E} 为固定矩阵, $(\mathbf{E})^\dagger$ 表示 \mathbf{E} 的伪逆, $c_t^{(n,q)}$ 为可学习参数, 来自对 (11) 中惩罚参数的 c 扩展;

功率松弛变量更新神经元 $X_p^{(n,q)}$:

$$\rho_n(q+1) = p_n(q+1) - \frac{1}{c_\rho^{(n,q)}} \mu_n(q) \quad (24)$$

该神经元输入变量为 $p_n(q+1)$ 、 $\mu_n(q)$, $c_\rho^{(n,q)}$ 为可学习参数, 是对惩罚参数 c 的扩展;

对偶变量更新节点 $M^{(n,q)}$; 该节点根据式 (25) 与式 (26) 更新对偶变量, 包含 $M_v^{(n,q)}$ 与 $M_\mu^{(n,q)}$ 两类神经元;

干扰对偶变量更新神经元 $M_v^{(n,q)}$:

$$\mathbf{v}_n(q+1) = \mathbf{v}_n(q) + c_v^{(n,q)} (\mathbf{E}_n \mathbf{t}(q+1) - \mathbf{t}_n(n+1)) \quad (25)$$

该神经元输入变量 $\mathbf{t}(q+1)$ 、 $\mathbf{t}_n(q+1)$ 、 $\mathbf{v}_n(q)$, \mathbf{E}_n 为固定矩阵; 将惩罚参数 c 扩展为可学习参数 $c_v^{(n,q)}$;

功率对偶变量神经元 $M_\mu^{(n,q)}$:

$$\mu_n(q+1) = \mu_n(q) + c_\mu^{(n,q)} (\rho_n(q+1) - p_n(q+1)) \quad (26)$$

该神经元输入变量 $p_n(q+1)$ 、 $\rho_n(q+1)$ 与 $\mu_n(q)$; 其中, $c_\mu^{(n,q)}$ 为可学习参数, 是对惩罚参数 c 的扩展。

一种分布式鲁棒多小区协作波束成形ADMM网络的构建方法

技术领域

[0001] 本发明属于通信领域,涉及无线通信中的多小区波束成形领域,具体涉及一种分布式鲁棒多小区协作波束成形ADMM网络的构建方法。

背景技术

[0002] 与传统的单小区波束成形设计相比,多小区协作波束成形能够显著的提高系统的吞吐量,近年来受到广泛关注。在多小区协作波束成形可以有效的减小小区间干扰(ICI)。

[0003] 以上方法基于完备的信道状态信息(CSI)与控制中心的控制,然而在实际的多小区系统中,会遇到以下问题:

[0004] 第一,在实际场景中,由于不完善的信道估计与有限的反馈,BS无法得到完美的信道状态信息(CSI)。

[0005] 第二,未来的无线通信系统趋向于BS互相之间直接连接成网络,即不使用控制中心。

[0006] 很多研究者也综合考虑了两个问题,Dahrouj等人(Dahrouj H,Yu W.Coordinated beamforming for the multicell multi-antenna wireless system[J].IEEE Transactions on Wireless Communications,2010,9(5):1748-1759.)提出了基于对偶分解和交替优化的分布式优化算法,沈等人(Shen C,Chang T H,Wang K Y,et al.Distributed Robust Multicell Coordinated Beamforming With Imperfect CSI:An ADMM Approach[J].IEEE Transactions on Signal Processing,2012,60(6):2988-3003.)则提出了基于交替方向乘子法(ADMM)的分布式优化算法。

[0007] 可以看到,传统的分布式鲁棒波束成形方法主要集中在多种不同的分解方法,这些分解方法需要超参数设置。并且,面对不同的问题时,需要选取不同的超参数,大大减低了算法的普适性。一种基于传统算法,同时基于数据驱动,普适性强的多小区协作波束成形算法是迫切需要的。

发明内容

[0008] 本发明的目的在于解决现有技术中的问题,提供一种分布式鲁棒多小区协作波束成形ADMM网络的构建方法,通过展开方法构建网络,通过端到端学习,实现了数据驱动的最优参数设计,使得在同样的迭代次数下波束成形的预测精度提高,也可满足波束成形预测对于不同信道环境的适应性。

[0009] 为达到上述目的,本发明采用以下技术方案予以实现:

[0010] 一种分布式鲁棒多小区协作波束成形ADMM网络的构建方法,包括以下步骤:

[0011] 步骤1,优化问题的转化

[0012] 利用半定义松弛(SDR)对最坏情况下的鲁棒MCBF设计进行“线性化”;利用线性矩阵不等式LMI的有限凸约束,将无穷多个约束表达为有限凸约束;将上述鲁棒MCBF设计转化为半定规划问题;通过ADMM将半定规划问题转化为三个步骤的迭代求解:

- [0013] $Z^{(n,q)}$ 步骤:每个基站处求解本地波束成形矩阵;
- [0014] $X^{(n,q)}$ 步骤:更新松弛变量;
- [0015] $M^{(n,q)}$ 步骤:更新对偶变量;
- [0016] 迭代求解完成后,在 $Z^{(n,q)}$ 子步骤完成后得到最优波束成形矩阵;
- [0017] 步骤2,将本地波束成形优化问题转化为标准SDP问题;
- [0018] 步骤3,通过定义数据流图与神经元,构造ADMM网络;
- [0019] 步骤4,通过端到端监督学习得到最终的神经网络。
- [0020] 与现有技术相比,本发明具有以下有益效果:
- [0021] 本发明针对最坏情况信干噪比(SINR)约束的多小区协作波束成形(MCBF)设计问题。从多小区鲁棒波束成形ADMM算法出发,将本地波束成形向量求解子问题通过Schur补定理与对角矩阵转化为标准形式。然后通过HKM方向原始对偶内点法求解本地波束成形向量求解子问题,将隐式迭代转化为显式迭代。通过“展开”思想,将ADMM算法映射到一个数据流图,并将原ADMM算法的各个计算环节转换为具有可学习参数的神经元,构建MCBF-ADMM网络。通过端到端学习,实现数据驱动的最优参数设计。
- [0022] 本发明是在最坏情况信干噪比(SINR)约束的多小区协作波束成形(MCBF)ADMM网络方法,有效的提高了波束成形的精度,增加了波束成形对于不同信道环境的适应性。

附图说明

- [0023] 为了更清楚的说明本发明实施例的技术方案,下面将对实施例中所需要使用的附图作简单地介绍,应当理解,以下附图仅示出了本发明的某些实施例,因此不应被看作是对范围的限定,对于本领域普通技术人员来讲,在不付出创造性劳动的前提下,还可以根据这些附图获得其他相关的附图。
- [0024] 图1为本发明针对的多小区下行链路系统示意图。
- [0025] 图2为本发明构建的ADMM网络数据流图。
- [0026] 图3为本发明构建的ADMM网络神经元结构图。

具体实施方式

- [0027] 为使本发明实施例的目的、技术方案和优点更加清楚,下面将结合本发明实施例中的附图,对本发明实施例中的技术方案进行清楚、完整地描述,显然,所描述的实施例是本发明一部分实施例,而不是全部的实施例。通常在此处附图中描述和示出的本发明实施例的组件可以以各种不同的配置来布置和设计。
- [0028] 因此,以下对在附图中提供的本发明的实施例的详细描述并非旨在限制要求保护的本发明的范围,而是仅仅表示本发明的选定实施例。基于本发明中的实施例,本领域普通技术人员在没有作出创造性劳动前提下所获得的所有其他实施例,都属于本发明保护的范围。
- [0029] 应注意到:相似的标号和字母在下面的附图中表示类似项,因此,一旦某一项在一个附图中被定义,则在随后的附图中不需要对其进行进一步定义和解释。
- [0030] 在本发明实施例的描述中,需要说明的是,若出现术语“上”、“下”、“水平”、“内”等指示的方位或位置关系为基于附图所示的方位或位置关系,或者是该发明产品使用时惯常

摆放的方位或位置关系,仅是为了便于描述本发明和简化描述,而不是指示或暗示所指的装置或元件必须具有特定的方位、以特定的方位构造和操作,因此不能理解为对本发明的限制。此外,术语“第一”、“第二”等仅用于区分描述,而不能理解为指示或暗示相对重要性。

[0031] 此外,若出现术语“水平”,并不表示要求部件绝对水平,而是可以稍微倾斜。如“水平”仅仅是指其方向相对“竖直”而言更加水平,并不是表示该结构一定要完全水平,而是可以稍微倾斜。

[0032] 在本发明实施例的描述中,还需要说明的是,除非另有明确的规定和限定,若出现术语“设置”、“安装”、“相连”、“连接”应做广义理解,例如,可以是固定连接,也可以是可拆卸连接,或一体地连接;可以是机械连接,也可以是电连接;可以是直接相连,也可以通过中间媒介间接相连,可以是两个元件内部的连通。对于本领域的普通技术人员而言,可以根据具体情况理解上述术语在本发明中的具体含义。

[0033] 下面结合附图对本发明做进一步详细描述:

[0034] 如图1所示由 N_c 小区组成的多小区下行链路系统,每个小区有一个带有 N_t 个天线的基站(BS)和 K 个单天线的移动台(MS)组成。 N_c 个BS被假设为在同一个频段工作且每一个BS都使用波束成形传输与同小区的MS通信,每个MS只由一个BS服务。

[0035] 用 BS_n 表示第 n 个BS,用 $MS_{n,k}$ 表示第 n 个小区的第 k 个MS,其中 $n \in \mathcal{N}_c \triangleq \{1, 2, \dots, N_c\}$, $k \in \mathcal{K} \triangleq \{1, 2, \dots, K\}$, BS_n 向 $MS_{n,k}$ 发送的符号用 $s_{nk}(t) \in \mathbb{C}$ 表示,相关波束成形向量用 $\mathbf{w}_{nk} \in \mathbb{C}^{N_t}$ 表示,则 BS_n 的输出信号为:

$$[0036] \quad \mathbf{x}_n(t) = \sum_{k=1}^K \mathbf{w}_{nk} s_{nk}(t)$$

[0037] 式中 $n \in \mathcal{N}_c$, $MS_{n,k}$ 的接收到的信号可以表示为:

$$[0038] \quad \begin{aligned} y_{nk}(t) &= \sum_{m=1}^{N_c} \mathbf{h}_{mnk}^H \mathbf{x}_m(t) + z_{nk}(t) \\ &= \mathbf{h}_{nnk}^H \mathbf{w}_{nk} s_{nk}(t) + \sum_{i \neq k} \mathbf{h}_{nnk}^H \mathbf{w}_{ni} s_{ni}(t) \\ &\quad + \sum_{m \neq n} \sum_{i=1}^K \mathbf{h}_{mnk}^H \mathbf{w}_{mi} s_{mi}(t) + z_{nk}(t) \end{aligned}$$

[0039] 式中, $\mathbf{h}_{mnk} \in \mathbb{C}^{N_t}$ 为 BS_m 到 $MS_{n,k}$ 的信道向量, $z_{nk}(t) \in \mathbb{C}$ 为 $MS_{n,k}$ 的加性噪声,噪声均值为0,方差 $\sigma_{nk}^2 > 0$ 。 $z_{nk}(t)$ 表示接收机噪声与来自非对应的BS的干扰。在式(2-2)中,第一项表示发送给 $MS_{n,k}$ 的信号,第二与第三项表示小区内干扰与小区外干扰(ICI)。假设 $s_{nk}(t)$ 统计独立,且具有零均值,则有 $\mathbb{E}\{|s_{nk}(t)|^2\} = 1$,其中 $n \in \mathcal{N}_c$, $k \in \mathcal{K}$,每个MS采用

单用户检测方法(即没有其他用户的信息)。可以得到 MS_{nk} 的SINR计算公式为:

$$\begin{aligned} & \text{SINR}_{nk}(\mathbf{w}_{m1}, \dots, \mathbf{w}_{mK}_{m=1}^{N_c}, \mathbf{h}_{mnk}_{m=1}^{N_c}) \\ [0040] \quad &= \frac{|\mathbf{h}_{nnk}^H \mathbf{w}_{nk}|^2}{\sum_{i \neq k}^K |\mathbf{h}_{nnk}^H \mathbf{w}_{ni}|^2 + \sum_{m \neq n}^{N_c} \sum_{i=1}^K |\mathbf{h}_{mnk}^H \mathbf{w}_{mi}|^2 + \sigma_{nk}^2} \end{aligned}$$

[0041] 考虑多小区波束成形设计中的最坏情况,可以将BS估计的信道状态信息(CSI)表示为 $\hat{\mathbf{h}}_{mnk} \in \mathbb{C}^{N_t}$, $n, m \in \mathcal{N}_c, k \in \mathcal{K}$, 这里 $\mathcal{N}_c \triangleq \{1, 2, \dots, N_c\}$ 表示BS的索引集合, $\mathcal{K} \triangleq \{1, 2, \dots, K\}$ 表示移动台(MS)的索引集合。在一个具体的实施场景:小尺度衰落信道中, $\hat{\mathbf{h}}$ 服从均值为0,方差为1的独立同分布的复高斯分布。则精确的基站 BS_m 到移动台 MS_{nk} 的CSI可以表示为 $\mathbf{h}_{mnk} \in \mathbb{C}^{N_t}$:

$$[0042] \quad \mathbf{h}_{mnk} = \hat{\mathbf{h}}_{mnk} + \mathbf{e}_{mnk}, \forall m, n \in \mathcal{N}_c, k \in \mathcal{K} \quad (1)$$

[0043] 式中 $\mathbf{e}_{mnk} \in \mathbb{C}^{N_t}$ 表示CSI误差,误差满足以下椭圆误差模型:

$$[0044] \quad \mathbf{e}_{mnk}^H \mathbf{Q}_{mnk} \mathbf{e}_{mnk} \leq 1 \quad (2)$$

[0045] 式中 $\mathbf{Q}_{mnk} \in \mathbb{H}^{N_t}$, $\mathbf{Q}_{mnk} > \mathbf{0}$ 为椭圆的大小,在实际使用时 $\mathbf{Q}_{mnk} = \epsilon_{mnk}^{-2} \mathbf{I}_{N_t}$, $\epsilon_{mnk}^2 > 0$,模型简化为球形误差模型。

[0046] 为了保证所有可能的CSI误差都能满足SINR要求,考虑了以下最坏情况下的鲁棒MCBF设计:

$$\begin{aligned} [0047] \quad & \min_{\{\mathbf{w}_{nk}\}_{n,k}} \sum_{n=1}^{N_c} \alpha_n \left(\sum_{k=1}^K \|\mathbf{w}_{nk}\|^2 \right) \\ & \text{s.t.} \quad \text{SINR}_{nk}(\{\mathbf{w}_{m1}, \dots, \mathbf{w}_{mK}\}_{m=1}^{N_c}, \{\hat{\mathbf{h}}_{mnk} + \mathbf{e}_{mnk}\}_{m=1}^{N_c}) \geq \gamma_{nk} \\ & \quad \forall \mathbf{e}_{mnk}^H \mathbf{Q}_{mnk} \mathbf{e}_{mnk} \leq 1, m, n \in \mathcal{N}_c, k \in \mathcal{K} \end{aligned} \quad (3)$$

[0048] 式中 $\alpha_n > 0$ 为基站 BS_n 的功率权重, $\mathbf{w}_{nk} \in \mathbb{C}^{N_t}$ 是基站 BS_n 处发送移动台 MS_{nk} 数据的波束成形向量,SINR计算公式为:

$$\begin{aligned} [0049] \quad & \text{SINR}_{nk} \left(\{\mathbf{w}_{m1}, \dots, \mathbf{w}_{mK}\}_{m=1}^{N_c}, \{\hat{\mathbf{h}}_{mnk} + \mathbf{e}_{mnk}\}_{m=1}^{N_c} \right) \\ &= \frac{|\mathbf{h}_{nnk}^H \mathbf{w}_{nk}|^2}{\sum_{i \neq k}^K \cdot |\mathbf{h}_{nnk}^H \mathbf{w}_{ni}|^2 + \sum_{m \neq n}^{N_c} \cdot \sum_{i=1}^K \cdot |\mathbf{h}_{mnk}^H \mathbf{w}_{mi}|^2 + \sigma_{nk}^2} \end{aligned} \quad (4)$$

[0050] 第一步:优化问题的转化

[0051] 考虑到每个SINR约束都包含信道状态信息(CSI)误差,利用半定义松弛(SDR)对问题(3)进行“线性化”。SDR的思想是将每个秩一矩阵 $\mathbf{w}_{nk}(\mathbf{w}_{nk})^H$ 替换为一个一般秩半正定矩阵 $\mathbf{W}_{nk} \geq \mathbf{0}$ 。利用线性矩阵不等式(LMI)的有限凸约束将无穷多个约束表达为有限凸约束。最后,将上述鲁棒MCBF设计转化为以下半定规划问题:

$$\begin{aligned}
& \min_{\{\mathbf{W}_{nk}\}, \{\lambda_{mnk}\}, \{t_{mnk}\}} \sum_{n=1}^{N_c} \alpha_n \left(\sum_{k=1}^K \text{Tr}(\mathbf{W}_{nk}) \right) \\
& \text{s.t. } \Phi_{nk}(\{\mathbf{W}_{ni}\}_{i=1}^K, \{t_{mnk}\}_m, \lambda_{nnk}) \geq \mathbf{0} \\
& \quad \Psi_{mnk}(\{\mathbf{W}_{mi}\}_{i=1}^K, t_{mnk}, \lambda_{mnk}) \geq \mathbf{0} \quad \forall m \neq n \\
& \quad \mathbf{W}_{nk} \geq \mathbf{0}, \lambda_{mnk} \geq 0 \quad \forall m, n, k
\end{aligned} \tag{5}$$

[0053] 其中: $t_{mnk} = \max \mathbf{h}_{mnk}^H (\sum_{i=1}^K \mathbf{W}_{mi}) \mathbf{h}_{mnk}$ s.t. $\mathbf{e}_{mnk}^H \mathbf{Q}_{mnk} \mathbf{e}_{mnk} \leq 1$ 。

$$\begin{aligned}
& \Phi_{nk}(\{\mathbf{W}_{ni}\}_{i=1}^K, \{t_{mnk}\}_m, \lambda_{nnk}) \\
& \triangleq \begin{bmatrix} \mathbf{U}_{nk} + \lambda_{nnk} \mathbf{Q}_{nnk} & \mathbf{U}_{nk} \hat{\mathbf{h}}_{nnk} \\ \hat{\mathbf{h}}_{nnk}^H \mathbf{U}_{nk} & \hat{\mathbf{h}}_{nnk}^H \mathbf{U}_{nk} \hat{\mathbf{h}}_{nnk} - \lambda_{nnk} - \sum_{m \neq n} t_{mnk} - \sigma_{nk}^2 \end{bmatrix} \geq \mathbf{0} \\
& \Psi_{mnk}(\{\mathbf{W}_{mi}\}_{i=1}^K, t_{mnk}, \lambda_{mnk}) \\
& \triangleq \begin{bmatrix} -\sum_{i=1}^K \mathbf{W}_{mi} + \lambda_{mnk} \mathbf{Q}_{mnk} & -\left(\sum_{i=1}^K \mathbf{W}_{mi}\right) \hat{\mathbf{h}}_{mnk} \\ -\hat{\mathbf{h}}_{mnk}^H \left(\sum_{i=1}^K \mathbf{W}_{mi}\right) & -\hat{\mathbf{h}}_{mnk}^H \left(\sum_{i=1}^K \mathbf{W}_{mi}\right) \hat{\mathbf{h}}_{mnk} + t_{mnk} - \lambda_{mnk} \end{bmatrix}
\end{aligned} \tag{6}$$

$$\geq \mathbf{0}, m \in \mathcal{N}_c \setminus \{n\}$$

[0055] 其中: $\mathbf{U}_{nk} \triangleq \frac{1}{\gamma_{nk}} \mathbf{W}_{nk} - \sum_{i \neq k} \mathbf{W}_{ni}$ 。

[0056] 通过ADMM方法,可以将上述问题(5)转化为三个步骤的迭代求解。

[0057] $Z^{(n,q)}$ 步骤:每个基站处求解本地波束成形矩阵,求解如下式(8)的问题:

$$\begin{aligned}
& \{\mathbf{t}_n(q+1), p_n(q+1)\} \\
& = \arg \min \left(\alpha_n p_n + \frac{c}{2} \|\mathbf{E}_n \mathbf{t}(q) - \mathbf{t}_n\|^2 \right. \\
& \left. + \frac{c}{2} (\rho_n(q) - p_n)^2 - \mathbf{v}_n^T(q) \mathbf{t}_n - \mu_n(q) p_n \right) \\
& \text{s.t. } (\{\mathbf{W}_{nk}\}_k, \{\lambda_{nmk}\}_{m,k}, \mathbf{t}_n, p_n) \in \mathcal{C}_n
\end{aligned} \tag{8}$$

[0059] 其中 $\rho_n \geq 0$ 是松弛变量, $\frac{c}{2} \|\mathbf{E}_n \mathbf{t}(q) - \mathbf{t}_n\|^2$ 与 $\frac{c}{2} \sum_{n=1}^{N_c} (\rho_n - p_n)^2$ 是惩罚项, c 是惩罚参数。

[0060] 定义以下变量:

$$\begin{aligned}
& \mathbf{t} = \left[[t_{121}, \dots, t_{12K}], \dots, [t_{N_c(N_c-1)1}, \dots, t_{N_c(N_c-1)K}] \right]^T \in \mathbb{R}^{N_c(N_c-1)K} \\
[0061] \quad \mathbf{t}_n &= \left[[T_{n1}, \dots, T_{nK}], [t_{n11}, \dots, t_{n1K}], \dots, [t_{nN_c1}, \dots, t_{nN_cK}] \right]^T \in \mathbb{R}_+^{N_c K}, n \in \mathcal{N}_t \quad (9) \\
& T_{nk} = \sum_{m \neq n}^{N_c} \cdot t_{mnk}
\end{aligned}$$

[0062] $\mathbf{E}_n \in \{0,1\}^{N_c K \times N_c(N_c-1)K}$ 是 \mathbf{t} 到 \mathbf{t}_n 的映射矩阵

[0063] 对于 $\forall n \in \mathcal{N}_c$ 集合 \mathcal{C}_n 定义为:

$$\begin{aligned}
& \mathcal{C}_n = \{ (\{\mathbf{W}_{nk}\}_k, \{\lambda_{nmk}\}_{m,k}, \mathbf{t}_n, p_n) \mid \\
& \Phi_{nk}(\{\mathbf{W}_{ni}\}_{i=1}^K, T_{nk}, \lambda_{nnk}) \geq \mathbf{0}, \forall k, \\
& \Psi_{nmk}(\{\mathbf{W}_{ni}\}_{i=1}^K, t_{nmk}, \lambda_{nmk}) \geq \mathbf{0} \forall m \neq n, k, \\
[0064] \quad & \lambda_{nmk} \geq 0, \forall m, k, \sum_{k=1}^K \text{Tr}(\mathbf{W}_{nk}) = p_n, \quad = \hat{\mathbf{h}}_{mnk} + \mathbf{e}_{mnk}, \forall m, n \quad (10) \\
& \mathbf{W}_{nk} \geq \mathbf{0}, \forall k, T_{nk} \geq 0, \forall k \} \\
& \in \mathcal{N}_c, k \in \mathcal{K}
\end{aligned}$$

[0065] $X^{(n,q)}$ 步骤:更新松弛变量:

$$[0066] \quad \mathbf{t}(q+1) = \mathbf{E}^\dagger(\tilde{\mathbf{t}}(q+1) - \frac{1}{c} \tilde{\mathbf{v}}(q)) \quad (11)$$

$$[0067] \quad \rho_n(q+1) = p_n(q+1) - \frac{1}{c} \mu_n(q), n \in \mathcal{N}_c \quad (12)$$

[0068] 式中 $\tilde{\mathbf{t}}(q+1) = [\mathbf{t}_1^T(q+1), \dots, \mathbf{t}_{N_c}^T(q+1)]^T$, $\tilde{\mathbf{v}}(q) = [\mathbf{v}_1^T(q), \dots, \mathbf{v}_{N_c}^T(q)]^T$, $\mathbf{E} = [\mathbf{E}_1^T, \dots, \mathbf{E}_{N_c}^T]^T$ 。

[0069] $M^{(n,q)}$ 步骤:更新对偶变量:

$$[0070] \quad v_n(q+1) = v_n(q) + c(E_n t(q+1) - t_n(q+1)) \quad (13)$$

$$[0071] \quad \mu_n(q+1) = \mu_n(q) + c(\rho_n(q+1) - p_n(q+1)) \quad (14)$$

[0072] 式中 $n \in \mathcal{N}_c$ 。

[0073] 令 Q 表示迭代求解的总次数,上述三个子问题迭代求解完成后,可以在 $Z^{(n,q)}$ 子步骤完成后得到最优波束成形矩阵 $\{\mathbf{W}_{nk}^*\}$,可以证明,迭代到的最优波束成形矩阵 $\{\mathbf{W}_{nk}^*\}$ 秩为 1,因此可以使用秩一分解 $\mathbf{W}_{nk}^* = \mathbf{w}_{nk}^* (\mathbf{w}_{nk}^*)^H$ 得到最优波束成形向量 $\{\mathbf{w}_{nk}^*\}$ 。

[0074] 第二步:本地波束成形优化问题转化为标准SDP问题;

[0075] 标准SDP问题:

$$\begin{aligned}
& \max_{\mathbf{y}} \quad \mathbf{b}^T \mathbf{y} \\
[0076] \quad & \text{s.t.} \quad \sum_{i=1}^m y_i \mathbf{A}_i + \mathbf{S} = \mathbf{C} \\
& \quad \quad \mathbf{S} \geq \mathbf{0}
\end{aligned} \tag{15}$$

[0077] 其中 $\mathbf{b} \in \mathbb{R}^m$, $\mathbf{A}_i \in \mathbb{S}^n$, $\mathbf{C} \in \mathbb{S}^n$, $\mathbf{S} \in \mathbb{S}^n$, y_i 代表向量 \mathbf{y} 的第 i 个元素, m 与 n 分别表示优化向量与约束矩阵的维度。

[0078] 添加松弛变量 P'_n 与 T'_{ni} , 使满足:

$$\begin{aligned}
& P'_n \geq (\rho_n(q) - p_n)^2 \\
& T'_{ni} \geq (\eta_{ni}(q) - t_{ni})^2, i = 1, \dots, N_c K, \\
[0079] \quad & \sum_{i=1}^{N_c K} T'_{ni} \geq \|\mathbf{E}_n \mathbf{t}(q) - \mathbf{t}_n\|^2
\end{aligned} \tag{16}$$

[0080] 其中 $\boldsymbol{\eta}_n(q) \triangleq \mathbf{E}_n \mathbf{t}(q)$, $\eta_{ni}(q)$ 与 t_{ni} 分别表示 $\boldsymbol{\eta}_n(q)$ 与 \mathbf{t}_n 的第 i 个元素。求解本地波束成形的非线性SDP问题 (8) 转化为:

$$\begin{aligned}
& \{\mathbf{t}_n(q+1), p_n(q+1)\} \\
[0081] \quad & = \arg \min \left(\alpha_n p_n + \frac{c}{2} \sum_{i=1}^{N_c K} T'_{ni} + \frac{c}{2} P'_n - \mathbf{v}_n^T(q) \mathbf{t}_n - \mu_n(q) p_n \right) \\
& \quad \text{s.t.} \quad (\{\mathbf{W}_{nk}\}_k, \{\lambda_{nmk}\}_{m,k}, \mathbf{t}_n, p_n) \in \mathcal{C}_n \\
& \quad \quad P'_n \geq (\rho_n(q) - p_n)^2 \\
& \quad \quad T'_{ni} \geq (\eta_{ni}(q) - t_{ni})^2, i = 1, \dots, N_c K, n = 1, \dots, N_c
\end{aligned} \tag{17}$$

[0082] 定理1 (Schur补定理) 设 $\mathbf{A} = \begin{bmatrix} \mathbf{B} & \mathbf{C}^T \\ \mathbf{C} & \mathbf{D} \end{bmatrix}$ 是一个对称矩阵, 其中 \mathbf{B} 是 $k \times k$ 的块矩阵, \mathbf{D} 为 1×1 的块矩阵。假设 \mathbf{B} 是正定的, 则 \mathbf{A} 是正定 (半正定) 的当且仅当矩阵 $\mathbf{D} - \mathbf{C}\mathbf{B}^{-1}\mathbf{C}^T$ 为正定 (半正定) 的。矩阵 $\mathbf{D} - \mathbf{C}\mathbf{B}^{-1}\mathbf{C}^T$ 称为矩阵 \mathbf{A} 中 \mathbf{B} 的Schur补。

[0083] 借助Schur定理, 将非线性约束转化为半正定约束:

$$\begin{aligned}
& P'_n \geq (\rho_n(q) - p_n)^2 \Rightarrow \boldsymbol{\Omega}_n \triangleq \begin{bmatrix} P'_n & \rho_n(q) - p_n \\ \rho_n(q) - p_n & 1 \end{bmatrix} \geq \mathbf{0} \\
[0084] \quad & T'_{ni} \geq (\eta_{ni}(q) - t_{ni})^2 \Rightarrow \mathbf{Y}_{ni} \triangleq \begin{bmatrix} T'_{ni} & \eta_{ni}(q) - t_{ni} \\ \eta_{ni}(q) - t_{ni} & 1 \end{bmatrix} \geq \mathbf{0}
\end{aligned} \tag{18}$$

[0085] 至此, 式 (8) 转化为以下具有LMI约束的线性SDP问题 (19)。

$$\begin{aligned}
& \{\mathbf{t}_n(q+1), p_n(q+1)\} \\
[0086] \quad & = \arg \min \left(\alpha_n p_n + \frac{c}{2} \sum_{i=1}^{N_c K} T'_{ni} + \frac{c}{2} P'_n - v_n^T(q) \mathbf{t}_n - \mu_n(q) p_n \right) \\
& \quad \text{s.t. } (\{\mathbf{W}_{nk}\}_k, \{\lambda_{nmk}\}_{m,k}, \mathbf{t}_n, p_n) \in \mathbf{C}_n \\
& \quad \quad \mathbf{\Omega}_n \geq 0, \mathbf{Y}_{ni} \geq 0, i = 1, \dots, N_c K
\end{aligned} \tag{19}$$

[0087] 然后,将多个离散的LMI约束转换成一个LMI约束,即构造对角矩阵:

$$\begin{aligned}
[0088] \quad & \mathbf{D}_n \stackrel{\Delta}{=} \text{diag}(\Phi_{n1}, \dots, \Phi_{nK}, \Psi_{nm1}, \dots, \Psi_{nmK} \\
& \mathbf{W}_{n1}, \dots, \mathbf{W}_{nK}, \lambda_{nm1}, \dots, \lambda_{nmK}, T_{n1}, \dots, T_{nK} \\
& \mathbf{Y}_{n1}, \dots, \mathbf{Y}_{nN_c K}, \mathbf{\Omega}_n) \geq 0
\end{aligned} \tag{20}$$

[0089] 其中有 $m, n \in \mathcal{N}_c, m \neq n$ 。最终问题 (19) 可以转化为:

$$\begin{aligned}
[0090] \quad & \{\mathbf{t}_n(q+1), p_n(q+1)\} = \arg \min \left(\alpha_n p_n + \frac{c}{2} \sum_{i=1}^{N_c(N_c-1)K} T'_{ni} \right. \\
& \quad \left. + \frac{c}{2} P'_n - v_n^T(q) \mathbf{t}_n - \mu_n(q) p_n \right) \\
& \quad \text{s.t. } \mathbf{D}_n \geq 0
\end{aligned} \tag{21}$$

[0091] 将 $Z^{(n,q)}$ 与标准SDP问题联系起来有:

$$\begin{aligned}
& \mathbf{y} \rightarrow \mathbf{y}_n^z(q) = [\text{svec}(\mathbf{W}_{n1})^T, \dots, \text{svec}(\mathbf{W}_{nK})^T, \\
& \quad \lambda_{nm1}, \dots, \lambda_{nmK}, \mathbf{t}_n^T, T'_{n1}, \dots, T'_{nN_c K}, P'_n]^T, \\
[0092] \quad & \mathbf{b}^T \mathbf{y} \rightarrow - \left(\alpha_n p_n + \frac{c}{2} \sum_{i=1}^{N_c K} T'_{ni} + \frac{c}{2} P'_n - v_n^T(q) \mathbf{t}_n - \mu_n(q) p_n \right) \\
& \mathbf{S} \rightarrow \mathbf{D}_n, \mathbf{b} \rightarrow \mathbf{b}_n^z(q), \mathbf{A}_i \rightarrow \mathbf{A}_{ni}^z(q), (i = 1, \dots, N_y), \mathbf{C} \rightarrow \mathbf{C}_n^z(q)
\end{aligned} \tag{22}$$

[0093] 这里 N_y 为 $\mathbf{y}_n^z(q)$ 的元素个数。通过对目标函数和约束条件的分解,可以得到 $\mathbf{b}_n^z(q), \mathbf{C}_n^z(q)$ 和 $\mathbf{A}_{ni}^z(q)$ 的显示表达式。在这种情况下,避免冗余,使用隐式表达式代替。至此, $Z^{(n)}$ 问题转化为如下标准形式的SDP问题:

$$\begin{aligned}
[0094] \quad & \mathbf{Z}^{(n,q)}: \max_{\mathbf{y}_n^z(q)} \mathbf{b}_n^{z,T}(q) \mathbf{y}_n^z(q) \\
& \quad \text{s.t. } \sum_{i=1}^m \mathbf{y}_i(q) \mathbf{A}_{ni}^z(q) + \mathbf{D}_n = \mathbf{C}_n^z(q) \\
& \quad \quad \mathbf{D}_n \geq 0
\end{aligned} \tag{23}$$

[0095] 第三步:通过定义数据流图与神经元,构造ADMM网络。

[0096] 通过展开方法,将ADMM算法映射到数据流图与神经元上。数据流图(图2)由ADMM算法中不同子问题求解对应的节点和节点间数据流对应的有向边构成。整个网络分为 N_c 个子

网络,每个子网络对应每个基站处的本地网络。在输入层中,输入复数信道的I/Q变换,即输入层输入 $[\mathcal{R}(\mathbf{h}_{nmk}), \mathcal{J}(\mathbf{h}_{nmk})]$ 。

[0097] 其中,n表示基站的编号,q表示网络的层编号,l表示子网络的层编号。输入层输入数据后,ADMM算法展开为网络,ADMM算法的第q次迭代对应数据流图中的第q层。在图中的第q层,ADMM算法迭代时的3个子步骤被映射为具有可学习参数的3种节点类型,即本地波束成形矩阵求解节点 $Z^{(n,q)}$,松弛变量更新节点 $X^{(n,q)}$,对偶变量更新节点 $M^{(n,q)}$ 。3种节点类型的运算,组合为整个网络的一层。整个数据流图是由多个同样的层构成的,这与ADMM算法中的一步迭代对应。神经网络层与算法迭代的重要区别就是展开过程中,将原算法的算法参数转化为可学习参数。网络中单向箭头表示数据的流动方向,双向箭头表示不同基站的 $Z^{(n,q)}$ 节点输出的 $t_n(q+1)$ 的广播与接收。除了 $t_n(q+1)$ 需要被广播外,其它的运算都可以在每个基站对应的本地网络完成。

[0098] 输出层与输入层对应,获得实部与虚部分开的波束成形向量。在最终的网络训练中,选取功率的归一化均方误差(NRMSE)作为损失函数来训练网络。

[0099] 这样,输入一组信道实现向量后,数据在图中流动,最终得到波束成形向量的决策。本发明所构造的ADMM网络基于该数据流图,它保留图的结构,并将运算节点转化为具有可学习参数的神经元。

[0100] 下面仅对其中某个基站 BS_n 处的网络进行分析,其它基站的网络具有相同的结构。每个基站处的子网络的每一层有三种图节点。以第q层为例,这三种图节点为 $X^{(n,q)}$, $M^{(n,q)}$ 与 $Z^{(n,q)}$ 。其中,节点 $X^{(n,q)}$ 与 $M^{(n,q)}$ 具有简单的显式表达,可以通过两个神经元组成, $Z^{(n,q)}$ 节点为SDP问题的求解,可以展开为子网络来实现功能。

[0101] 图3展示了三种类型的图节点及第q层的数据流。其中,矩形框表示特定神经元,圆圈表示有数据通信(即连接)的神经元。梯形表示本基站信号 $t_n(q)$ 的广播与其它基站 $t_n(q)$ 信号的接收,实线箭头表示前向传播中的数据流,虚线箭头表示反向传播计算梯度时的反向数据流。

[0102] 本地波束成形矩阵求解节点 $Z^{(n,q)}$ 。该节点的功能是通过HKM方向的原始对偶内点法对SDP问题(23)进行求解。将该迭代求解过程转化为一个子网络。根据算法1中的迭代,将节点 $Z^{(n,q)}$ 分解为一个初始化神经元 $Z_0^{(n,q)}$ 级联多个中心路径方向求解神经元 $Z_1^{(n,q,l)}$ 与解集更新神经元 $Z_2^{(n,q,l)}$ 。下述为基于HKM方向求解标准SDP问题(15)的原始对偶内点法的算法步骤:

[0103] 步骤1:给定初始迭代 $(X(1), y(1), S(1))$,其中 $X(1), S(1)$ 满足正定性。设置步长 α, β 。设置终止条件 δ ;

[0104] 步骤2:循环

[0105] 求解第l次迭代的HKM方向 $(\Delta X(l), \Delta y(l), \Delta S(l))$;

[0106] 解集 (X, y, S) 更新: $X(l+1) = X(l) + \alpha \Delta X(l)$,

[0107] $y(l+1) = y(l) + \beta \Delta y(l), S(l+1) = S(l) + \beta \Delta S(l)$;

[0108] 直到满足终止条件 $relgap$ 和 ϕ 都小于 δ ;

[0109] 其中

$$\text{relgap} = \frac{\mathbf{x} \cdot \mathbf{s}}{1 + \max(|\mathbf{C} \cdot \mathbf{x}|, |\mathbf{b}^T \mathbf{y}|)}, \phi = \max\left(\frac{\|\mathbf{b} - \mathbf{A}\mathbf{x}\|}{1 + \|\mathbf{b}\|}, \frac{\|\mathbf{c} - \mathbf{s} - \mathbf{A}^T \mathbf{y}\|}{1 + \|\mathbf{C}\|}\right), \mathbf{A} = \begin{bmatrix} \text{svec}(\mathbf{A}_1)^T \\ \vdots \\ \text{svec}(\mathbf{A}_m)^T \end{bmatrix}, \mathbf{x} = \text{svec}$$

(X), $\mathbf{s} = \text{svec}(\mathbf{S})$, $\mathbf{c} = \text{svec}(\mathbf{C})$ 。此处 m 代表优化变量 \mathbf{y} 的维度

[0110] 上述基于HKM方向原始对偶内点法求解标准SDP问题(15)的算法中使用relgap与 ϕ 来判断算法的终止。在ADMM-Net求解问题(23)时,由于神经网络的确定性,不能用终止条件来决定算法的结束(用终止条件来判断算法的结束会导致算法的迭代次数不同,进而神经网络中的子网络层数无法固定)。为了获得准确的结果,通过固定子网层数为一个足够大的数来保证收敛性。这里将子网络总层数记作 L 。具体的神经网络构建包括:

[0111] 初始化神经元 $\mathbf{Z}_0^{(n,q)}$ 。 $\mathbf{Z}_0^{(n,q)}$ 执行基于HKM方向原始对偶内点法的初始化,并将其它节点的输入整理成可代入该算法的标准形式。该神经元输入变量为 $t(q)$ 、 $\rho_n(q)$ 、 $v_n(q)$ 、 $\mu_n(q)$ 与信道矩阵 $\mathbf{H} = [\mathbf{h}_{111}, \dots, \mathbf{h}_{11k}, \dots, \mathbf{h}_{N_c N_c K}]$ (\mathbf{H} 视为全局变量,在所有网络层共享),输出变量为后续原始对偶内点法的初始迭代($X_n(q, 1)$, $y_n(q, 1)$, $S_n(q, 1)$),以及标准SDP问题的信息 $b_n(q)$, $C_n(q)$, $A_{ni}(q)$, $i = 1, \dots, N_y$,

$$[0112] \quad \mathbf{X}_n(q, 1) = \mathbf{I}_{N_D}, \mathbf{y}_n(q, 1) = \mathbf{0}_{N_y \times 1}, \mathbf{S}_n(q, 1) = \mathbf{I}_{N_D}$$

$$[0113] \quad \mathbf{b}_n(q) = \mathbf{b}_n^z(q), \mathbf{C}_n(q) = \mathbf{C}_n^z(q), \mathbf{A}_{ni}(q) = \mathbf{A}_{ni}^z(q) \quad (24)$$

[0114] 式中 N_D 为约束矩阵的阶数, N_y 为优化变量的数量。由于子网络的后续网络层都需要SDP问题的参数信息,因此在本地波束成形矩阵求解节点 $\mathbf{Z}^{(n,q)}$ 中共享 $b_n(q)$, $C_n(q)$, $A_{ni}(q)$, $i = 1, \dots, N_y$ 。这里可学习参数 $\mathbf{c}_z^{(n,q)}$ 是从(8)的惩罚参数 c 扩展而来,包含在 $b_n(q)$ 中。

[0115] 中心路径方向求解神经元 $\mathbf{Z}_1^{(n,q,l)}$:

[0116] 该神经元的输入变量为 $X_n(q, 1)$, $y_n(q, 1)$, $S_n(q, 1)$,输出变量为算法解集的更新方向 $\Delta X_n(q, 1)$, $\Delta y_n(q, 1)$, $\Delta S_n(q, 1)$ 。 $\mathbf{Z}_1^{(n,q,l)}$ 执行基于HKM方向原始对偶内点法的中心路径方向求解,得到第 l 次迭代对应的变量更新HKM方向。

$$\begin{aligned}
\Delta \mathbf{y}_n(q, l) &= \mathbf{M}_n(q, l)^{-1} \mathbf{h}_n(q, l), \\
\Delta \mathbf{s}_n(q, l) &= \mathbf{R}_{dn}(q, l) - \mathbf{A}_{sn}(q)^T \Delta \mathbf{y}_n(q, l), \\
\Delta \mathbf{x}_n(q, l) &= \mathcal{E}_n^{-1}(q, l) \text{svec}(\mathbf{R}_{cn}(q, l)) - \mathcal{E}_n^{-1}(q, l) \mathcal{F}_n(q, l) \Delta \mathbf{s}_n(q, l), \\
\mathbf{M}_n(q, l) &= \mathbf{A}_{sn}(q)^T \mathcal{E}_n^{-1}(q, l) \mathcal{F}_n(q, l) \mathbf{A}_{sn}(q), \\
\mathbf{h}_n(q, l) &= \mathbf{r}_{pn}(q, l) - \mathbf{A}_{sn}(q)^T \mathcal{E}_n^{-1}(q, l) \text{svec}(\mathbf{R}_{cn}(q, l)) \\
&\quad + \mathbf{A}_{sn}(q)^T \mathcal{E}_n^{-1}(q, l) \mathcal{F}_n(q, l) \mathbf{R}_{dn}(q, l), \\
\mathbf{r}_{pn}(q, l) &= \mathbf{b}_n(q) - \mathbf{A}_{sn}(q) \mathbf{x}_n(q, l), \\
\mathbf{R}_{dn}(q, l) &= \mathbf{c}_n(q) - \mathbf{s}_n(q, l) - \mathbf{A}_{sn}(q)^T \mathbf{y}_n(q, l), \\
\mathcal{E}_n(q, l) &= \mathbf{P}_n(q, l) \circledast \mathbf{P}_n^{-T}(q, l) \mathbf{s}_n(q, l), \\
\mathcal{F}_n(q, l) &= \mathbf{P}_n(q, l) \mathbf{x}_n(q, l) \circledast \mathbf{P}_n^{-T}(q, l), \\
\mathbf{A}_{sn}(q) &= \begin{bmatrix} \text{svec}(\mathbf{A}_{n1}(q))^T \\ \vdots \\ \text{svec}(\mathbf{A}_{nN_y}(q))^T \end{bmatrix}, \\
\mathbf{x}_n(q, l) &= \text{svec}(\mathbf{X}_n(q, l)), \\
\mathbf{s}_n(q, l) &= \text{svec}(\mathbf{S}_n(q, l)), \\
\mathbf{c}_n(q) &= \text{svec}(\mathbf{C}_n(q))
\end{aligned} \tag{25}$$

[0118] 式中 $\mu \triangleq \mathbf{X}_n(q, l) \cdot \mathbf{S}_n(q, l) / N_D$, 用 $a_{i,j}$ 表示矩阵 \mathbf{A} 第 i 行第 j 列的元素, 则 $\text{svec}(\mathbf{A})$ 是矩阵线性化算子 $\text{svec}(\mathbf{A}) \triangleq [a_{11}, \sqrt{2}a_{12}, a_{22}, \sqrt{2}a_{13}, \sqrt{2}a_{23}, a_{33}, \dots]$, \circledast 表示矩阵的克罗内克积。在 HKM 方向中的对称化算子为 $\mathbf{P}_n(q, l) = \mathbf{S}_n^{\frac{1}{2}}(q, l) \cdot \delta^{(n,q,l)}$ 为可学习参数, 来自原始对偶内点法的步长 δ 。

[0119] 解集更新神经元 $Z_2^{(n,q,l)}$:

[0120] 该神经元输入参数为 $\Delta X_n(q, l)$, $\Delta y_n(q, l)$, $\Delta S_n(q, l)$, $X_n(q, l)$, $y_n(q, l)$, $S_n(q, l)$, 输出变量为解集更新值。 $Z_2^{(n,q,l)}$ 执行基于 HKM 方向原始对偶内点法的解集更新步骤:

$$\begin{aligned}
\mathbf{X}_n(q, l+1) &= \mathbf{X}_n(q, l) + \alpha_n(q, l) \Delta \mathbf{X}_n(q, l) \\
\mathbf{y}_n(q, l+1) &= \mathbf{y}_n(q, l) + \beta_n(q, l) \Delta \mathbf{y}_n(q, l) \\
\mathbf{S}_n(q, l+1) &= \mathbf{S}_n(q, l) + \beta_n(q, l) \Delta \mathbf{S}_n(q, l) \\
\alpha_n(q, l) &= \min \left(1, \epsilon_n(q, l) \frac{-1}{\lambda_{\min}((\mathbf{X}_n(q, l))^{-1} \Delta \mathbf{X}_n(q, l))} \right) \\
\beta_n(q, l) &= \min \left(1, \epsilon_n(q, l) \frac{-1}{\lambda_{\min}((\mathbf{S}_n(q, l))^{-1} \Delta \mathbf{S}_n(q, l))} \right) \\
\epsilon_n(q, l) &= 0.9 + 0.09 \min(\alpha_n(q, l), \beta_n(q, l))
\end{aligned} \tag{26}$$

[0122] 其中 $\Delta X_n(q, l) = \text{smat}(\Delta x_n(q, l))$, $\Delta S_n(q, l) = \text{smat}(\Delta s_n(q, l))$, $\text{smat}(\cdot)$ 是 $\text{svec}(\cdot)$ 的逆操作。式中 $\alpha_n(q, l)$ 与 $\beta_n(q, l)$ 为解集更新的步长。。在计算 ϵ 时, 首先将 ϵ 的初

值设置为1,得到预测的 $\alpha_n(q,1)$ 与 $\beta_n(q,1)$,然后计算 $\epsilon_n(q,1)$ 。

[0123] 如图3所示,在网络的最后一层(第Q层), $Z^{(n,q)}$ 节点除了计算得到 $p_n(Q+1)$ 外,还输出最优波束成形矩阵 $\{\mathbf{W}_{nk}^*\}$ 。

[0124] 松弛变量更新节点 $\mathbf{X}^{(n,q)}$ 。该节点根据式(27)与式(28)更新松弛变量,包含 $X_t^{(n,q)}$ 与 $X_p^{(n,q)}$ 两类神经元。

[0125] 干扰松弛变量更新神经元 $X_t^{(n,q)}$:

$$[0126] \quad \mathbf{t}(q+1) = \mathbf{E}^\dagger(\tilde{\mathbf{t}}(q+1) - \frac{1}{c_t^{(n,q)}} \tilde{\mathbf{v}}(q)) \quad (27)$$

[0127] 该神经元输入变量 $\tilde{\mathbf{t}}(q+1) = [\mathbf{t}_1^T(1, q+1), \dots, \mathbf{t}_{N_c}^T(N_c, q+1)]^T$ 、 $\tilde{\mathbf{v}}(q) = [\mathbf{v}_1^T(n, q), \dots, \mathbf{v}_{N_c}^T(n, q)]^T$, \mathbf{E} 为固定矩阵, $(\mathbf{E})^\dagger$ 表示 \mathbf{E} 的伪逆, $c_t^{(n,q)}$ 为可学习参数,来自对(11)中惩罚参数的 c 扩展。

[0128] 功率松弛变量更新神经元 $X_p^{(n,q)}$:

$$[0129] \quad \rho_n(q+1) = p_n(q+1) - \frac{1}{c_p^{(n,q)}} \mu_n(q) \quad (28)$$

[0130] 该神经元输入变量为 $p_n(q+1)$ 、 $\mu_n(q)$, $c_p^{(n,q)}$ 为可学习参数,是对(12)中惩罚参数 c 的扩展。

[0131] 对偶变量更新节点 $M^{(n,q)}$ 。该节点根据式(29)与式(30)更新对偶变量,包含 $M_v^{(n,q)}$ 与 $M_\mu^{(n,q)}$ 两类神经元。

[0132] 干扰对偶变量更新神经元 $M_v^{(n,q)}$:

$$[0133] \quad v_n(q+1) = v_n(q) + c_v^{(n,q)} (\mathbf{E}_n \mathbf{t}(q+1) - \mathbf{t}_n(n+1)) \quad (29)$$

[0134] 该神经元输入变量 $\mathbf{t}(q+1)$ 、 $\mathbf{t}_n(q+1)$ 、 $v_n(q)$, \mathbf{E}_n 为固定矩阵。这里将(13)中的惩罚参数 c 扩展为可学习参数 $c_v^{(n,q)}$ 。

[0135] 功率对偶变量神经元 $M_\mu^{(n,q)}$:

$$[0136] \quad \mu_n(q+1) = \mu_n(q) + c_\mu^{(n,q)} (\rho_n(q+1) - p_n(q+1)) \quad (30)$$

[0137] 该神经元输入变量 $p_n(q+1)$ 、 $\rho_n(q+1)$ 与 $\mu_n(q)$ 。其中, $c_\mu^{(n,q)}$ 为可学习参数,是对(14)中的惩罚参数 c 的扩展。

[0138] 第四步:通过端到端监督学习得到最终的神经网络。

[0139] 选取归一化根均方误差 (NRMSE) 作为损失函数来训练网络。给定训练数据时, 网络输出与最优功率之间的损失函数定义为:

$$[0140] \quad E(\Theta) = \frac{\|P^{Net}(\Theta, Q) - P^*\|_2}{\|P^*\|_2} \quad (31)$$

[0141] 式中, P^* 为求解式 (5) 表示的集中式优化问题得到的最优波束成形向量的总功率, $P^{Net}(\Theta, Q)$ 为网络参数是 Θ 网络迭代 Q 层的 ADMM-Net 输出的波束成形向量对应的发射总功率: $P^{Net}(\Theta, Q) = \sum_{n=1}^{N_c} p_n(Q+1)$ 。与深度学习中常用的均方误差 (MSE) 损失相比, NRMSE 能直观地反映学习的精度。

[0142] 训练得到最终的神经网络后, 输入信道向量通过 ADMM-Net 网络即可得到预测的最优的多小区协作波束成型矩阵 $\{\mathbf{W}_{nk}^*\}$, 使用秩一分解 $\mathbf{W}_{nk}^* = \mathbf{w}_{nk}^* (\mathbf{w}_{nk}^*)^H$ 得到最优波束成形向量 $\{\mathbf{w}_{nk}^*\}$ 。

[0143] 以上仅为本发明的优选实施例而已, 并不用于限制本发明, 对于本领域的技术人员来说, 本发明可以有各种更改和变化。凡在本发明的精神和原则之内, 所作的任何修改、等同替换、改进等, 均应包含在本发明的保护范围之内。




图1

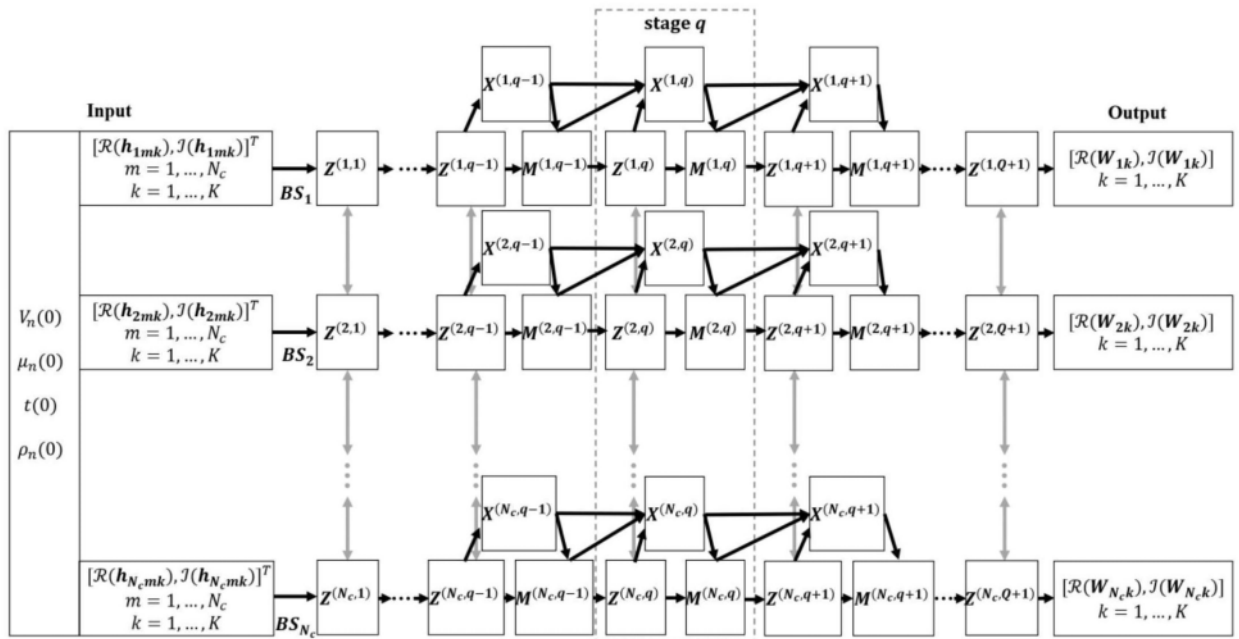


图2

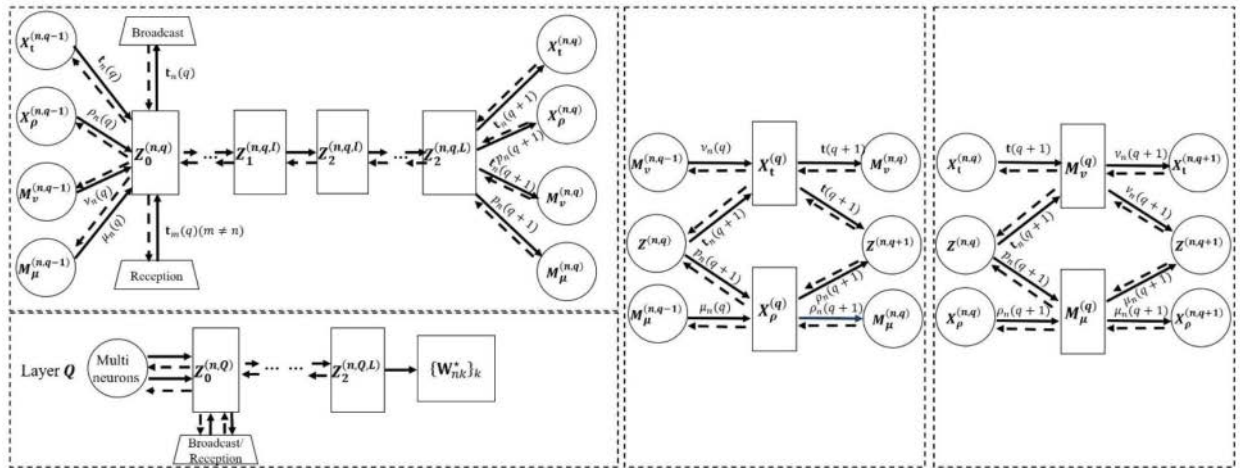


图3