

改进鲸鱼优化算法辅助 RIS 级联信道估计

彭艺^{1,2},王俊¹,杨青青^{1,2†},王健明¹,李辉¹

(1. 昆明理工大学 信息工程与自动化学院, 云南昆明 650031;
2. 昆明理工大学 云南省计算机技术应用重点实验室, 云南昆明 650500)

摘要:针对可重构智能表面辅助无线通信系统进行级联信道估计时存在导频开销大、自适应能力差等问题,提出一种结合改进鲸鱼优化算法的双结构稀疏分段弱正交匹配追踪算法。该算法首先采用自适应门限分段弱正交匹配追踪算法选择多个强相关性的原子来构成原子支撑集,并通过改进鲸鱼优化算法优化原子门限阈值,使其能够根据无线信道的变化动态调整,有效提取原子支撑集,提高信道估计精度,降低算法运行时间。仿真结果表明,相较于传统的级联信道估计方案,本文所提方案在归一化均方根误差方面表现出较好的性能,能以更小的导频开销获得更好的信道精度,且在不同的信道条件下具有更好的自适应性和鲁棒性。

关键词:信道估计;可重构智能表面;分段弱正交匹配追踪;鲸鱼优化算法;归一化均方根误差

中图分类号:TN928 文献标志码:A

Improved Whale Optimization Algorithm Assisted RIS Cascade Channel Estimation

PENG Yi^{1,2}, WANG Jun¹, YANG Qingqing^{1,2†}, WANG Jianming¹, LI Hui¹

(1. Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650031, China;
2. Yunnan Key Laboratory of Computer Technologies Application, Kunming University of Science and Technology,
Kunming 650500, China)

Abstract: To address the challenges of excessive pilot overhead and limited adaptability in cascade channel estimation for reconfigurable intelligent surface (RIS) assisted wireless communication systems, this paper proposes an improved whale optimization algorithm integrated with a dual-structure sparse stagewise weak orthogonal matching pursuit algorithm (IWOA-DS-SWOMP). The framework employs an adaptive threshold-controlled SWOMP mechanism to iteratively select multiple highly correlated atoms for constructing atomic support sets, while the atomic selection threshold via IWOA is dynamically optimized to adapt to real-time channel variations. This dual optimization strategy enhances atomic support set extraction accuracy, improves channel estimation precision, and reduces algorithm runtime. Simulation results demonstrate that the proposed scheme achieves superior normalized mean square error (NMSE) performance compared to conventional RIS cascade channel estimation methods,

* 收稿日期:2024-12-16

基金项目:国家自然科学基金资助项目(61761025), National Natural Science Foundation of China(61761025); 云南省基础研究计划重点项目(202401AS070105), Yunnan Province Basic Research Program Key Project (202401AS070105)

作者简介:彭艺(1975—),女,云南德宏人,昆明理工大学教授,博士

† 通信联系人,E-mail: 294753033@qq.com

attaining higher channel estimation accuracy with reduced pilot overhead while exhibiting enhanced adaptability and robustness under diverse channel conditions.

Key words: channel estimation; reconfigurable intelligent surface; stagewise weak orthogonal matching pursuit; whale optimization algorithm; normalized mean square error

随着移动通信和互联网技术的进步,结合 6G、物联网、人工智能等新兴技术,电子消费行业和智能电子产品正在加速发展。智能业务依赖于通信网络,但日益增长的需求和复杂的场景对网络提出了巨大挑战。作为无线通信环境智能化的关键技术,可重构智能表面(reconfigurable intelligent surface, RIS)引起广泛关注^[1]。RIS 由大量可独立控制的无源反射元件组成,能够调节入射信号的振幅和相位,从而重塑无线电环境^[2]。将 RIS 与毫米波、大规模多输入多输出(multiple-input multiple-output, MIMO)等技术结合,可低功耗实现高频谱效率和广覆盖,成为下一代通信系统的关键解决方案^[3-4]。然而,RIS 的引入增加了信道矩阵的维度,并需要在基站(base station, BS)或用户设备(user equipment, UE)上进行 BS-RIS-UE 链路的级联信道估计^[5]。这不仅增加了信道估计中的导频开销和处理复杂度,也为获取精确的信道状态信息(channel state information, CSI)带来了困难。

信道估计是无线通信系统中一个至关重要的环节,准确的 CSI 是确保系统可靠性和高效性的基础^[6]。传统的信道估计方法,如最小二乘(least squares, LS)和最小均方误差(minimum mean square error, MMSE)方法,由于其复杂度低、实现简单,被广泛用于 RIS 辅助通信系统中的信道估计^[7-8]。文献[9]提出了基于 LS 和 MMSE 的 RIS 信道估计方法,并通过实验证明了其在低复杂度时实现的有效性。然而,这类方法的主要不足在于它们需要大量的导频信号,其数量必须至少与信道参数的数量相等,这在大规模 RIS 系统中会导致频谱效率低下,增加了通信系统的开销。

深度学习(deep learning, DL)方法因其强大的非线性映射能力,近年来在信道估计领域取得了一定的成果^[10]。文献[11]提出了一种基于 DL 的 RIS 信道估计方法,通过训练深度神经网络来学习从导频信号到 CSI 的映射关系。尽管这种方法在估计精度上表现出色,但其缺点也很明显。首先,DL 模型的训

练需要大量数据和计算资源;其次,训练好的模型在面对新的环境或配置时,泛化能力较差,限制了其实用性^[12-13]。

为了解决上述问题,压缩感知(compressed sensing, CS)技术因其能够有效地利用信号的稀疏性,减少所需的导频开销,而在 RIS 信道估计中展现出巨大潜力^[14]。CS 理论表明,通过设计适当的测量矩阵,可以在远少于传统方法所需导频数量的情况下,重建稀疏信号^[15]。结合 RIS 毫米波信道的稀疏特性,CS 方法为信道估计提供了一种高效且低复杂度的解决方案。文献[16]提出一种基于三步正交匹配追踪算法,通过扩大训练的样本数量来克服噪声影响,来降低 RIS 通信系统的导频开销;文献[17]针对 RIS 辅助多用户 MIMO 系统,发现 BS 和 RIS 之间有共同信道,所有用户的级联信道矩阵具有共同的行-列-块稀疏结构,基于此提出行结构稀疏的正交匹配追踪算法;文献[18]为了进一步降低导频开销,利用角域级联信道的双结构稀疏性,提出基于双结构的正交匹配追踪算法(dual structure-orthogonal matching pursuit, DS-OMP),该算法只估计非零元素的位置,减少了冗余的估计开销;此外,文献[19]提出的分段弱正交匹配追踪算法(stagewise weak orthogonal matching pursuit, SWOMP)可以在稀疏性等先验知识未知的情况下重构信道状态信息,在选择原子时不仅仅只选择相关性最强的原子,而是选择多个相关性强的原子。然而原子选择阈值是基于经验来进行人为设置的,因此对于不同场景可能出现不稳定的重构性能。文献[20]提出基于正交频分复用系统信道估计的鲸鱼优化算法(whale optimization algorithm, WOA),使用 WOA 搜索最佳信道统计特性。在估计精度、导频开销和自适应性之间进行协调实现,也是 RIS 信道估计的关键挑战之一。

现有 DS-OMP 算法依赖信道稀疏度的先验知识,但在实际场景中,信道的稀疏特性往往是未知的,导致其适用性受限。为此,提出 DS-SWOMP (dual structure-stagewise weak orthogonal matching

pursuit) 算法, 通过融合 SWOMP 算法的原子选择机制, 实现无稀疏先验约束的信道估计。同时, 针对 DS-SWOMP 中固定原子阈值导致场景适应性差以及 WOA 收敛速度慢、全局搜索能力不足以及计算冗余严重等问题, 提出基于改进鲸鱼优化算法(improved whale optimization algorithm, IWOA) 的自适应信道估计方案, 实现参数动态优化与计算效率的联合提升。

1 RIS 辅助通信系统

图 1 展示了 RIS 辅助无线通信系统模型。从用户到 BS 有两种信道, 一个是视距信道, 另一个是由 RIS 构建的级联信道。级联信道通过 RIS 将入射信号反射到期望的方向。假设 BS 由 $M = M_1 \times M_2$ 个天线组成并均匀分布在一个平面阵列中, M_1 表示水平方向上的天线数量, M_2 表示垂直方向上的天线数量。同样地, RIS 包括 $N = N_1 \times N_2$ 个反射单元, N_1 和 N_2 分别表示水平和垂直方向上的元件数量。此外, 配备有单个天线的 k 个 ($k = 1, 2, \dots, K$) 用户随机分布在环境中。

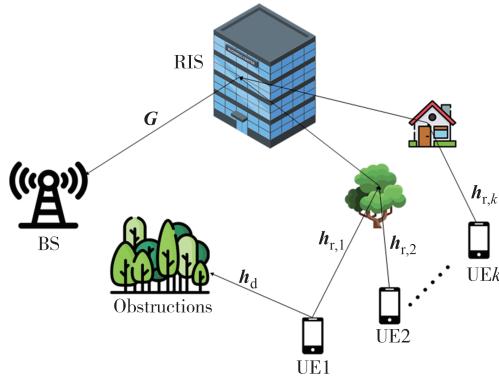


图 1 RIS 辅助无线通信系统模型

Fig.1 RIS auxiliary wireless communication system model

RIS 到 BS 的信道表示为 $\mathbf{G} \in \mathbb{C}^{M \times N}$, 第 k 个用户到 RIS 的信道用 $\mathbf{h}_{r,k} \in \mathbb{C}^{N \times 1}$ 表示。在 RIS 辅助通信系统中, BS 与用户之间通过毫米波进行通信, 而视距信道 \mathbf{h}_d 容易被密集的建筑物或者阻碍物阻挡。因此, 级联信道的获取对于高效的通信是十分有必要的。

假设 BS 和 UE 之间的视距信道是已知的。针对上行链路的级联信道估计问题, 所有用户将通过 RIS 同时向 BS 发送导频符号。根据正交导频传输策略, 所有用户在 Q 个时隙内向 BS 发送导频符号, 其中导频符号对于发送端和接收端均是已知的。具体而言, $x_{k,q}$ 表示在第 q 个 ($q = 1, 2, \dots, Q$) 时隙中第 k 个

用户发送的导频符号。在去除视距信道 \mathbf{h}_d 的影响后, BS 从第 k 个用户接收到的有效信号 $\mathbf{y}_{k,q} \in \mathbb{C}^{M \times 1}$ 可以表示为:

$$\begin{aligned} \mathbf{y}_{k,q} &= \mathbf{G} \operatorname{diag}(\boldsymbol{\theta}_q) \mathbf{h}_{r,k} x_{k,q} + \mathbf{w}_{k,q} = \\ &\quad \mathbf{G} \operatorname{diag}(\mathbf{h}_{r,k}) \boldsymbol{\theta}_q x_{k,q} + \mathbf{w}_{k,q} \end{aligned} \quad (1)$$

式中: $\boldsymbol{\theta}_q = [\boldsymbol{\theta}_{q,1}, \dots, \boldsymbol{\theta}_{q,N}]^T \in \mathbb{C}^{N \times 1}$ 是 RIS 处的反射向量; $\boldsymbol{\theta}_{q,n}$ 表示第 q 个时隙中第 n 个 ($n=1, \dots, N$) RIS 单元的反射系数; $\mathbf{w}_{k,q} \sim \mathcal{CN}(0, \mathbf{I}_M)$ 表示接收到噪声信号, 服从循环对称复高斯分布。

1.1 信道模型

级联信道由 RIS 构建的 $\mathbf{h}_{r,k}$ -RIS- \mathbf{G} 信道构成, 信道模型均采用 Saleh-Valenzuela 毫米波信道模型。将信道 \mathbf{G} 表示为^[21]:

$$\mathbf{G} = \sqrt{\frac{MN}{L_G}} \sum_{l_1=1}^{L_G} \alpha_{l_1}^G \mathbf{b}(\vartheta_{l_1}^{G_r}, \psi_{l_1}^{G_r}) \mathbf{a}(\vartheta_{l_1}^{G_t}, \psi_{l_1}^{G_t})^T \quad (2)$$

式中: L_G 表示 RIS 和 BS 之间的路径数量; $\alpha_{l_1}^G$ ($|\alpha_{l_1}^G| = 10^{-3} d_{\text{BR}}^{-2.2}$) 表示第 l_1 条路径的路径损耗的复增益; d_{BR} 表示 BS 与 RIS 之间的距离; $\vartheta_{l_1}^{G_r}$ 和 $\psi_{l_1}^{G_r}$ 分别是 BS 和 RIS 处的第 l_1 条路径的方位角; $\vartheta_{l_1}^{G_t}$ 和 $\psi_{l_1}^{G_t}$ 分别是 BS 和 RIS 处的第 l_1 条路径的仰角。同样地, 第 k 个用户和 RIS 之间的信道 $\mathbf{h}_{r,k}$ 表示为^[21]:

$$\mathbf{h}_{r,k} = \sqrt{\frac{N}{L_{r,k}}} \sum_{l_2=1}^{L_{r,k}} \alpha_{l_2}^{r,k} \mathbf{a}(\vartheta_{l_2}^{r,k}, \psi_{l_2}^{r,k}) \quad (3)$$

$L_{r,k}$ 表示第 k 个用户与 RIS 之间的路径数; $\alpha_{l_2}^{r,k}$ ($|\alpha_{l_2}^{r,k}| = 10^{-3} d_{\text{RU}}^{-2.8}$) 表示第 l_2 条路径的路径损耗的复增益; d_{RU} 表示 RIS 与用户之间的距离; $\vartheta_{l_2}^{r,k}$ 和 $\psi_{l_2}^{r,k}$ 分别表示第 l_2 条路径在 RIS 处的方位角和仰角; $\mathbf{b}(\vartheta, \psi)$ 以及 $\mathbf{a}(\vartheta, \psi)$ 分别表示与 BS 和 RIS 相关的归一化阵列响应矢量, 对于典型的均匀平面阵列, $\mathbf{a}(\vartheta, \psi)$ 可以表示为:

$$\mathbf{a}(\vartheta, \psi) = \mathbf{a}_h \otimes \mathbf{a}_v \quad (4)$$

式中: \otimes 表示 Kronecker 内积, \mathbf{a}_h 是水平响应矢量, 可以表示为:

$$\mathbf{a}_h = \frac{1}{\sqrt{N_1}} \left[e^{-j2\pi d \sin(\vartheta) \cos(\psi) n_1 / \lambda} \right] \quad (5)$$

同样地, \mathbf{a}_v 是垂直响应矢量, 可以表示为:

$$\mathbf{a}_v = \frac{1}{\sqrt{N_2}} \left[e^{-j2\pi d \sin(\psi) n_2 / \lambda} \right] \quad (6)$$

式中: λ 为载波波长; d 为天线间距, 通常情况下满足 $d = \lambda/2$; $\mathbf{n}_1 = [0, 1, \dots, N_1 - 1]$; $\mathbf{n}_2 = [0, 1, \dots, N_2 - 1]$ 。

第 k 个用户的级联信道可以进一步在虚拟角域进行表示, 将级联信道 \mathbf{H}_k 分解为:

$$\mathbf{H}_k = \mathbf{U}_M \tilde{\mathbf{H}}_k \mathbf{U}_N^T \quad (7)$$

式中: $\tilde{\mathbf{H}}_k \in \mathbb{C}^{M \times N}$ 表示角域级联信道; $\mathbf{U}_M \in \mathbb{C}^{M \times M}$ 和 $\mathbf{U}_N \in \mathbb{C}^{N \times N}$ 分别是 BS 和 RIS 处的字典酉矩阵. \mathbf{U}_M 可以通过以下方式进行计算^[22]:

$$\mathbf{U}_M = \mathbf{l}_{M_h} \otimes \mathbf{l}_{M_v} \quad (8)$$

式中: $\mathbf{l}_{M_h} \in \mathbb{C}^{M_1 \times M_1}$, $\mathbf{l}_{M_v} \in \mathbb{C}^{M_2 \times M_2}$ 分别是 BS 的水平和垂直变换矩阵, \mathbf{l}_{M_h} 可以表示为:

$$\mathbf{l}_{M_h} = \left[\mathbf{a}_h(0), \mathbf{a}_h\left(\frac{1}{M_1}\right), \dots, \mathbf{a}_h\left(\frac{M_1 - 1}{M_1}\right) \right] \quad (9)$$

\mathbf{l}_{M_v} 可以表示为:

$$\mathbf{l}_{M_v} = \left[\mathbf{a}_v(0), \mathbf{a}_v\left(\frac{1}{M_2}\right), \dots, \mathbf{a}_v\left(\frac{M_2 - 1}{M_2}\right) \right] \quad (10)$$

同样地, \mathbf{U}_N 可以表示为:

$$\mathbf{U}_N = \mathbf{l}_{N_h} \otimes \mathbf{l}_{N_v} \quad (11)$$

式中: $\mathbf{l}_{N_h} \in \mathbb{C}^{N_1 \times N_1}$, $\mathbf{l}_{N_v} \in \mathbb{C}^{N_2 \times N_2}$ 分别为 RIS 的水平和垂直变换矩阵.

1.2 问题求解

根据级联信道 $\mathbf{H}_k \triangleq \mathbf{G}\text{diag}(\mathbf{h}_{r,k})$, 可以将式(1)改写成:

$$\mathbf{y}_{k,q} = \mathbf{H}_k \boldsymbol{\theta}_q \mathbf{x}_{k,q} + \mathbf{w}_{k,q} \quad (12)$$

经过 Q 个导频传输时隙后, 通过假设 $x_{k,q} = 1$ 获得测量矩阵 $\mathbf{Y}_k = [\mathbf{y}_{k,1}, \dots, \mathbf{y}_{k,Q}] \in \mathbb{C}^{M \times Q}$, 可以表示为:

$$\mathbf{Y}_k = \mathbf{H}_k \boldsymbol{\Theta} + \mathbf{W}_k \quad (13)$$

式中: $\boldsymbol{\Theta} = [\boldsymbol{\theta}_1, \dots, \boldsymbol{\theta}_Q]$; $\mathbf{W}_k = [\mathbf{w}_{k,1}, \dots, \mathbf{w}_{k,Q}]$. 将式(7)代入式(13)中可得:

$$\mathbf{Y}_k = \mathbf{U}_M \tilde{\mathbf{H}}_k \mathbf{U}_N^T \boldsymbol{\Theta} + \mathbf{W}_k \quad (14)$$

在实际的通信环境中, BS 和 RIS 一般架设在高层建筑物上, 散射体的总数将被限制在一定范围内, 并且几乎所有的反射、折射、衍射等路径都将被引入到 $\tilde{\mathbf{H}}_k$ 中, 只涉及少量的单元. 在这种情况下, 角域级联信道 $\tilde{\mathbf{H}}_k$ 的元素仅在几行或几列内为非零元素, 而其余元素保持为零, 导致级联信道 $\tilde{\mathbf{H}}_k$ 的稀疏性. 因此, 可以通过 CS 重建算法, 进行稀疏信道的重建, 下面考虑 CS 理论来解决级联信道的估计问题.

设 $\tilde{\mathbf{Y}}_k = (\mathbf{U}_M^H \mathbf{Y}_k)^H \in \mathbb{C}^{Q \times M}$ 为有效测量矩阵, $\tilde{\mathbf{W}}_k = (\mathbf{U}_M^H \mathbf{W}_k)^H \in \mathbb{C}^{Q \times M}$ 为有效噪声矩阵, 可以将式(14)重写为 CS 模型:

$$\tilde{\mathbf{Y}}_k = \tilde{\boldsymbol{\Theta}} \tilde{\mathbf{H}}_k^H + \tilde{\mathbf{W}}_k \quad (15)$$

式中: $\tilde{\boldsymbol{\Theta}} = (\mathbf{U}_N^T \boldsymbol{\Theta})^H \in \mathbb{C}^{Q \times N}$ 为传感矩阵.

虽然可以通过传统的 CS 算法分别估计每个用户的角域级联信道, 但角域级联信道的稀疏性难以准确确定, 这表明如果所采用的原子支撑集没有很好的选择, 传统 CS 方法进行估计时的精度将会严重下降. 为了保证估计精度, 传统 CS 算法所需的导频开销依然较大, 尤其在拥有大量元件的 RIS 场景中, 这种方法难以实际应用. 因此, 在实际 RIS 通信当中, 估计精度、导频开销和适应性之间的权衡将成为更关键的挑战.

2 信道估计方案

2.1 SWOMP 算法

与 OMP 算法不同, SWOMP 算法在每次迭代过程中, 首先通过重构信号的残差来确定原子的选择标准, 从而构建候选集. 其次, 利用正交候选集选出用来描述信号的原子, 并将其存入支撑集中. 然后, 通过求解最小二乘问题对支撑集中原子进行信号重构, 进而更新残差值. 在每轮迭代中, SWOMP 算法根据设定的阈值准则选择最优原子, 其中阈值定义为: $\text{Th} = \alpha \max \{ \text{abs}(u) \}$, 其中, 原子门限阈值 α 的取值范围为 $[0, 1]$, $u = \text{abs}[\mathbf{A}^T \mathbf{r}_{s-1}] = \text{abs} \langle \mathbf{a}_j, \mathbf{r}_{s-1} \rangle (1 \leq j \leq N)$, \mathbf{A} 表示传感矩阵, \mathbf{a}_j 表示 \mathbf{A} 的第 j 列, \mathbf{r}_{s-1} 表示残差, $\langle \mathbf{a}, \mathbf{r}_{s-1} \rangle$ 表示求 \mathbf{a} 和 \mathbf{r}_{s-1} 的内积, s 表示迭代次数.

2.2 IWOA

针对 WOA 算法收敛慢、全局搜索弱、参数固化等问题, 提出 IWOA 算法, 通过引入游动幅度因子 ε 与目标吸引力因子 γ 增强搜索能力, 并借助缓存机制减少适应度函数调用, 以提高收敛速度与计算效率.

WOA 是一种新型的自然元启发式优化算法, 它模仿了座头鲸的狩猎行为^[23]. 鲸鱼通常会在猎物附近徘徊, 形成一个缩小的圆圈, 并沿着圆圈制造出独特的气泡以进行捕猎. 为了将鲸鱼的捕食行为应用于优化算法, 需对这个过程进行数学建模. 首先, 鲸鱼的初始种群需要在随机过程中创建; 然后, 将鲸鱼的狩猎过程分为两个阶段, 即开发和随机探索.

2.2.1 开发阶段

鲸鱼在捕猎时会将猎物包围起来, 鲸鱼的收缩过程可以描述为:

$$\mathbf{X}(t+1) = \mathbf{X}^*(t) - \mathbf{E} \cdot \mathbf{D} \quad (16)$$

式中: t 表示当前的迭代次数; $X^*(t)$ 表示第 t 次迭代中最佳位置,可以描述为:

$$X^*(t) = \arg \min_{X_i(t)} f(X_i(t)) \quad (17)$$

式中: $i = 1, 2, \dots, P$, P 表示鲸鱼个体的数量; $X_i(t)$ 表示第 i 个鲸鱼的位置; $f(\cdot)$ 表示适应度函数,采用均方误差(mean square error, MSE)进行衡量:

$$f(X_i(t)) = \frac{1}{K} \sum_{k=1}^K \left(\|H_k - \hat{H}_k(X_i(t))\|_F^2 \right) \quad (18)$$

式中: H_k 是真实信道矩阵, \hat{H}_k 为信道估计值.

在每次迭代中,通过比较所有鲸鱼个体的适应度值,选择当前种群中适应度最优,即MSE最小的鲸鱼个体位置作为全局的最佳位置 $X^*(t)$,引导其他鲸鱼个体向最优方向移动.

D 用于量化当前位置与最优位置之间的距离,调整步长的随机性:

$$D = |\mathbf{F} \cdot X^*(t) - \mathbf{X}(t)| \quad (19)$$

式中: $X(t)$ 是当前鲸鱼的位置.系数向量 E 、 F 可以表示为:

$$E = 2e \cdot r - e \quad (20)$$

$$F = 2 \cdot r \quad (21)$$

式中: r 是在 $[0, 1]$ 范围内均匀分布产生的随机向量; e 为收敛因子,随迭代次数 t 的增加从2逐步线性递减到0,可以表示为:

$$e = 2 - 2t/t_{\max} \quad (22)$$

式中: t_{\max} 为最大迭代次数.

鲸鱼通过式(16)更新位置,即鲸鱼会根据最佳位置来更新自己的位置.系数向量 E 和 F 是负责控制鲸鱼向最佳位置靠近的参数,它们共同控制了算法在搜索空间中的全局探索和局部开发能力.利用鲸鱼当前位置和最佳位置来模拟鲸鱼向上螺旋运动的觅食行为,其数学模型可以描述为:

$$X(t+1) = X^*(t) + D' \times e^{bl} \times \cos(2\pi l) \quad (23)$$

式中: $D' = |X^*(t) - X(t)|$ 表示鲸鱼与当前全局最优个体之间的距离; b 表示限定对数螺旋形状的常数; l 是 $[-1, 1]$ 区间内的随机数.

为了更好地描述鲸鱼在收缩包围和螺旋路径之间进行选择的自然行为,其数学模型描述为:

$$X(t+1) = \begin{cases} X^*(t) - E \cdot D, & p < 0.5 \\ X^*(t) + D' \times e^{bl} \times \cos(2\pi l), & p \geq 0.5 \end{cases} \quad (24)$$

式中: p 表示 $[0, 1]$ 范围内均匀分布生成的随机数.

2.2.2 随机搜索阶段

在WOA中,鲸鱼不仅局限于更新自己的最佳位置.为提高WOA的搜索能力,该算法会随机选择一只鲸鱼来引导其他鲸鱼.为了达到这个目标,使系数向量 $|E| > 1$,远离目前已知的最优个体,该阶段的数学模型为:

$$D = |\mathbf{F} \cdot X_{\text{rand}} - \mathbf{X}| \quad (25)$$

$$X(t+1) = X_{\text{rand}} - E \cdot D \quad (26)$$

式中: X_{rand} 表示当前种群中随机选择的鲸鱼的位置向量.

2.2.3 算法改进

WOA在解决实际问题时,往往存在收敛速度慢,全局搜索能力不足,参数固定而无法动态适应不同阶段的需求,为克服上述问题,本文提出一种IWOA,通过引入游动幅度因子 ε 和目标吸引力因子 γ ,进一步增强算法的全局搜索和局部开发能力.同时,引入缓存机制,减少调用适应度函数的次数,减少算法的运算时间.

在WOA中,系数向量 E 决定了鲸鱼个体的行为是否偏向于探索新区域或开发已有区域,改进算法中引入游动幅度因子 ε 对 E 进行重新定义,使得在算法前期, ε 的值较大,增强其全局探索能力;在算法后期, ε 的值减小,增强其对局部的开发能力.式(20)可以重新定义为:

$$E = \varepsilon \times (2e \cdot r - e) \quad (27)$$

其中 ε 的动态调整遵循:

$$\varepsilon = \varepsilon_{\max} - \frac{t}{t_{\max}} (\varepsilon_{\max} - \varepsilon_{\min}) \quad (28)$$

在WOA中随机游动行为描述为式(24),在改进算法中,将目标吸引力因子 γ 作为动态参数对参数 b 进行调节,使得在算法初期, γ 较小,有利于随机探索新的区域;在算法后期, γ 值增大,有助于算法快速收敛至最优解.其中 γ 可以表示为:

$$\gamma = \gamma_{\min} + \frac{t}{t_{\max}} (\gamma_{\max} - \gamma_{\min}) \quad (29)$$

式(23)可以更新为:

$$X(t+1) = X^*(t) + D' \times e^{\gamma l} \times \cos(2\pi l) \quad (30)$$

在WOA中所有鲸鱼个体都根据最佳位置或随机鲸鱼的位置进行统一更新.而在IWOA中,选取前一部分个体用于专注最佳位置的更新,引入游动幅

度因子 ε , 将鲸鱼个体划分为不同的优先级, 有针对性地优化了一部分关键个体, 进而提升算法的全局探索和开发效率. 对剩余个体采用基于目标吸引力因子 γ 的螺旋更新测量, 使算法能够在后期有效跳出局部最优解.

对于前一部分个体, 即 $i \in [1, \lfloor P \times \lambda \rfloor]$, 其更新规则为:

$$X_i(t+1) = \begin{cases} X_{\text{rand}}(t) - E \cdot D, & |E| \geq 1 \\ X^*(t) - E \cdot D, & |E| < 1 \end{cases} \quad (31)$$

对于后一部分个体, 即 $i \in [\lceil P \times \lambda \rceil, P]$, 其更新规则为:

$$X_i(t+1) = X^*(t) + D' \times e^{\gamma l} \times \cos(2\pi l) \quad (32)$$

式中: λ 为 $[0, 1]$ 之间的数, 表示选取优异个体的比例.

为降低算法的复杂度, 在 IWOA 中引入缓存机制, 可以有效降低算法的运行时间. 在算法的每次迭代中, 为每个鲸鱼个体计算适应度前, 首先检查缓存中是否已存在该鲸鱼位置对应的适应度值, 将鲸鱼个体带来的当前位置向量转化为唯一的字符串键, 为每个位置生成对应的缓存键值对, 当某个位置的适应度值已在缓存中时, 直接读取缓存; 否则计算适应度值并存储到缓存中. 表 1 为 IWOA 算法的具体流程.

表 1 IWOA

Tab.1 Improved whale optimization algorithm

算法 1:IWOA

输入: 鲸鱼个体数 P , 最大迭代次数 t_{\max} , 参数上界, 参数下界, 维度 \dim , 适应度函数 $f(\cdot)$

1. 初始化动态因子: $\varepsilon_{\max}, \varepsilon_{\min}, \gamma_{\max}, \gamma_{\min}$
2. for $t = 1, 2, \dots, t_{\max}$ do
3. 由式(28)~式(29)更新动态因子 ε, γ 的值
4. 引入缓存机制并通过式(18)计算适应度函数 $f(\cdot)$ 的值
5. 更新适应度值以及领导者的位置 $X^*(t)$
6. for $i = 1, 2, \dots, \lfloor P \times \lambda \rfloor$ do
7. 由式(27)更新参数 E , 由式(31)更新鲸鱼下一次的位置
8. end for
9. for $i = \lceil P \times \lambda \rceil, \dots, P$ do
10. 由式(32)更新鲸鱼下一次的位置
11. end for
12. end for
13. 得到最优解 $X^*(t)$

2.3 IWOA-DS-SWOMP 算法

根据级联信道的表达式 $\mathbf{H}_k \triangleq \mathbf{G}\text{diag}(\mathbf{h}_{r,k})$, 将式(2)和式(3)代入, 可以获得级联信道 \mathbf{H}_k 的完整表达式:

$$\mathbf{H}_k = \sqrt{\frac{MN}{L_G}} \sum_{l_1=1}^{L_G} \alpha_{l_1}^G \mathbf{b}(\vartheta_{l_1}^{G_t}, \psi_{l_1}^{G_t}) \mathbf{a}(\vartheta_{l_1}^{G_t}, \psi_{l_1}^{G_t})^T \cdot \text{diag}\left(\sqrt{\frac{N}{L_{r,k}}} \sum_{l_2=1}^{L_{r,k}} \alpha_{l_2}^{r,k} \mathbf{a}(\vartheta_{l_2}^{r,k}, \psi_{l_2}^{r,k})\right) \quad (33)$$

对角矩阵 $\text{diag}(\mathbf{a})$ 与向量 \mathbf{a}^T 的乘积等效于每个元素进行相位叠加, 对应角度进行加法操作, 其数学表达式为:

$$\begin{aligned} \mathbf{a}(\vartheta_{l_1}^{G_t}, \psi_{l_1}^{G_t})^T \cdot \text{diag}(\mathbf{a}(\vartheta_{l_2}^{r,k}, \psi_{l_2}^{r,k})) = \\ \mathbf{a}(\vartheta_{l_1}^{G_t} + \vartheta_{l_2}^{r,k}, \psi_{l_1}^{G_t} + \psi_{l_2}^{r,k})^T \end{aligned} \quad (34)$$

将式(33)代入式(7)中, 可以将角域级联信道可以进一步表示为:

$$\tilde{\mathbf{H}}_k = \sqrt{\frac{MN}{L_G L_{r,k}}} \sum_{l_1=1}^{L_G} \sum_{l_2=1}^{L_{r,k}} \alpha_{l_1}^G \alpha_{l_2}^{r,k} U_M^H \mathbf{b}(\vartheta_{l_1}^{G_t}, \psi_{l_1}^{G_t}) \mathbf{a}(\vartheta_{l_1}^{G_t} + \vartheta_{l_2}^{r,k}, \psi_{l_1}^{G_t} + \psi_{l_2}^{r,k})^T U_N \quad (35)$$

令 $\tilde{\mathbf{b}}(\vartheta, \psi) = U_M^H \mathbf{b}(\vartheta, \psi)$ 表示 BS 在角域中稀疏化的归一化阵列响应矢量, $\tilde{\mathbf{a}}(\vartheta, \psi) = U_N^H \mathbf{a}(\vartheta, \psi)$ 表示 RIS 在角域中稀疏化的归一化阵列响应矢量, 此时角域级联信道可以进一步简化为:

$$\begin{aligned} \tilde{\mathbf{H}}_k = \sqrt{\frac{MN}{L_G L_{r,k}}} \sum_{l_1=1}^{L_G} \sum_{l_2=1}^{L_{r,k}} \alpha_{l_1}^G \alpha_{l_2}^{r,k} \\ \tilde{\mathbf{b}}(\vartheta_{l_1}^{G_t}, \psi_{l_1}^{G_t}) \tilde{\mathbf{a}}^T(\vartheta_{l_1}^{G_t} + \vartheta_{l_2}^{r,k}, \psi_{l_1}^{G_t} + \psi_{l_2}^{r,k}) \end{aligned} \quad (36)$$

根据上式, 每一条从 UE 到 RIS 再到 BS 的完整路径为角域级联信道 $\tilde{\mathbf{H}}_k$ 中的一个非零元素, 其中行索引由 $(\vartheta_{l_1}^{G_t}, \psi_{l_1}^{G_t})$ 决定, 列索引取决于 $(\vartheta_{l_1}^{G_t} + \vartheta_{l_2}^{r,k}, \psi_{l_1}^{G_t} + \psi_{l_2}^{r,k})$. 不同用户的角域级联信道 $\{\tilde{\mathbf{H}}_k\}_{k=1}^K$ 表现出双结构稀疏性. 首先, 对于不同的用户来说, RIS 到 BS 的信道 \mathbf{G} 为公用信道, 因此角域级联信道 $\{\tilde{\mathbf{H}}_k\}_{k=1}^K$ 的非零行所在的位置与用户无关, 即角域级联信道 $\{\tilde{\mathbf{H}}_k\}_{k=1}^K$ 的非零元素完全位于公共的 L_G 行上, 即 $\{\tilde{\mathbf{H}}_k\}_{k=1}^K$ 表现出行结构稀疏特性. Ω_r^K 表示级联信道 $\tilde{\mathbf{H}}_k$ 非零元素的行集, Ω_r 表示完全公共行支撑集, 故:

$$\Omega_r^1 = \Omega_r^2 = \dots = \Omega_r^K = \Omega_r \quad (37)$$

其次, 考虑到不同用户可能共享 RIS 和用户之间的一部分散射体, 这导致 RIS 与不同用户之间的信道 $\mathbf{h}_{r,k}$ 可能存在部分共同路径, 并展现出相同的角度特征. $\Omega_c^{l_1,k}$ 表示第 l_1 非零行的非零元素的列集, 则有:

$$\Omega_c^{l_1,1} \cap \Omega_c^{l_1,2} \cap \dots \cap \Omega_c^{l_1,K} = \Omega_c^{l_1, \text{Com}} \quad (38)$$

式中: $\Omega_c^{l_1, \text{Com}}$ 表示用于 $\{\tilde{\mathbf{H}}_k\}_{k=1}^K$ 的第 l_1 行的部分公共列支撑集, 其中 $l_1 = 1, 2, \dots, L_G$.

对于 DS-SWOMP 算法而言, 行稀疏度 L_G 、列稀疏度 $L_{r,k}$ 分别为 RIS-BS 以及 UE-RIS 第 k 个用户的传播路径数。RIS 与不同用户之间的信道 $\mathbf{h}_{r,k}$ 可能存在部分公共路径, 即为公共列稀疏度 L_c 。DS-OMP 算法中公共路径的数目是人为设置的, 但在实际应用当中, 公共路径的数目是不确定且易变的, 无法准确获取环境中公共路径的数目, 会导致算法实用性和准确性降低。此外, OMP 算法每次只能选择一个最相关的原子, 降低了该算法的实用性。而 SWOMP 算法能够在每次迭代中根据预定义的阈值从原子集中选择多个原子, 与 OMP 相比有巨大的优势, 可以保证更多相关性强的原子进入原子集中, 从而提高重构的精度, 但由于原子选择阈值是人为进行预设, 信道环境总是变化的, 如果原子选择阈值不能够自适应地进行调整, 原子支撑集没有很好地选择, 会大大降低重构的精度。

基于上述分析, 本文提出 IWOA-DS-SWOMP 算法, 引入原子门限阈值 α , 并使用 IWOA 对 α 进行优化, 使算法可以在稀疏先验未知的情况下进行自适应信道估计, 提高算法在不同信道条件下的适应性。表 2 为所提出 IWOA-DS-SWOMP 算法的具体流程。

表 2 IWOA-DS-SWOMP 级联信道估计算法
Tab.2 IWOA-DS-SWOMP cascade channel estimation algorithm

算法 2:IWOA-DS-SWOMP 级联信道估计算法
输入: 测量矩阵 $\tilde{\mathbf{Y}}_k$, 传感矩阵 $\hat{\mathbf{H}}$, 原子门限阈值 α , 行稀疏度 L_G , 列稀疏度 $L_{r,k}$
1. 初始化: 估计的级联信道 $\{\tilde{\mathbf{H}}_k\}_{k=1}^K$
2. 算法 3: 对公共非零行支撑集 $\hat{\Omega}_r$ 进行估计
3. 使用 IWOA 优化 α
4. 算法 4: 对部分公共列支撑集 $\hat{\Omega}_c^{l_r, \text{Com}}$ 进行估计
5. 算法 5: 对部分单独列支撑集 $\hat{\Omega}_c^{l_r, k}$ 进行估计
6. for $l_1 = 1, 2, \dots, L_G$ do
7. for $k = 1, 2, \dots, K$ do
8. 使用 LS 算法对角域稀疏信道矩阵 $\tilde{\mathbf{H}}_k$ 进行估计
9. end for
10. end for
11. 将角域稀疏矩阵转换到空间域中获得最终的级联信道矩阵:
$\hat{\mathbf{H}}_k = \mathbf{U}_M^H \hat{\mathbf{H}}_k \mathbf{U}_N, \forall k$
12. 得到估计的级联信道 $\hat{\mathbf{H}}_k$

IWOA-DS-SWOMP 算法由三个算法构成: 首先使用算法 3 对公共非零行支撑集进行估计, 其中 $\hat{\Omega}_r$ 由 L_G 个非零行的行索引组成, 然后使用 IWOA 对阈值 α 进行寻优, 将其代入算法 3 中对部分公共列支

撑集 $\hat{\Omega}_c^{l_r, \text{Com}}$ 进行估计; 然后使用算法 4 对部分单独列支撑集 $\hat{\Omega}_c^{l_r, k}$ 进行估计; 步骤 8 使用 LS 算法对角域稀疏信道矩阵 $\hat{\mathbf{H}}_k$ 进行估计, 最后通过步骤 11 将角域稀疏信道矩阵转换到空间域中来获得最终的级联信道矩阵 $\hat{\mathbf{H}}_k$ 。

算法 3 对公共非零行支撑集 $\hat{\Omega}_r$ 进行估计, 角域级联信道 $\hat{\mathbf{H}}_k$ 的非零行会导致 $\tilde{\mathbf{Y}}_k$ 所对应列具有较高的功率。因此, 首先通过步骤 3 计算 $\tilde{\mathbf{Y}}_k$ 每列的功率, 然后通过步骤 5 取前 L_G 行高功率的列索引更新至公共非零行支撑集 $\hat{\Omega}_r$ 中。表 3 为公共非零行支撑集估计算法的具体流程。

表 3 公共非零行支撑集估计算法

Tab.3 Common non-zero row support set estimation algorithm

算法 3: 公共非零行支撑集估计算法
输入: 测量矩阵 $\tilde{\mathbf{Y}}_k$, 行稀疏度 L_G
1. 初始化功率: $E = \mathbf{0}_{M \times 1}$
2. for $k = 1, 2, \dots, K$ do
3. 计算 $\tilde{\mathbf{Y}}_k$ 每列的功率: $E(m) = E(m) + \ \tilde{\mathbf{Y}}_k(:, m)\ _F^2$
4. end for
5. 从步骤 3 计算所得的功率中选取前 L_G 行来构成公共非零行支撑集: $\hat{\Omega}_r = \Gamma_r(E, L_G)$
6. 得到公共非零行支撑集 $\hat{\Omega}_r$

算法 4 对部分公共列支撑集进行估计, 在步骤 6 中, 计算感知矩阵 $\hat{\Theta}$ 与残差向量 \tilde{r}_k 之间的相关性, 在步骤 7 引入原子门限阈值 α , 使得在每次迭代中, 算法不只选择相关性最强的原子, 而是选择多个相关性强的原子构成支撑集, 进而提高算法的重构精度。在步骤 10 中使用 LS 算法对稀疏信号进行重构恢复, 去除非零元素对信号的影响, 通过步骤 11 更新残差向量 \tilde{r}_k ; 步骤 12 对所选原子的列索引的出现次数 $c^l(n^*)$ 进行统计, 出现次数越多, 说明所选原子的相关性越强。表 4 为部分公共列支撑集估计算法的具体流程。

算法 5 对单独列支撑集进行估计。首先将单独列支撑集 $\hat{\Omega}_c^{l_r, k}$ 初始化为由算法 4 得到的部分公共列支撑集 $\hat{\Omega}_c^{l_r, \text{Com}}$, 然后在步骤 6 和步骤 7 中, 基于部分公共列支撑集 $\hat{\Omega}_c^{l_r, \text{Com}}$ 初始化稀疏向量 $\hat{\mathbf{h}}_k$ 和残差向量 \tilde{r}_k , 最后遵循与算法 3 相同的思想来估计单独列支撑集。表 5 为部分单独列支撑集估计算法的具体流程。

2.4 算法复杂度分析

本文所提 IWOA-DS-SWOMP 算法的复杂度由

表 4 部分公共列支撑集估计算法

Tab.4 Partial common column support set estimation

algorithm

算法 4:部分公共列支撑集估计算法	
输入:	测量矩阵 \tilde{Y}_k , 传感矩阵 $\tilde{\Theta}$, 原子门限阈值 α , 行稀疏度 L_G , 列稀疏度 $L_{r,k}$, 公共非零行支撑集 $\hat{\Omega}_r$
1. 初始化第 l_1 条路径下每个用户的列支撑集以及列索引统计次数:	$\hat{\Omega}_c^{l_1,k} = \emptyset, \forall l_1, k, c_1^l = 0_{N \times 1}, \forall l_1$
2. for $l_1 = 1, 2, \dots, L_G$ do	
3. for $k = 1, 2, \dots, K$ do	
4. 选取第 l_1 个非零行构成有效测量向量, 同时初始化残差值: $\tilde{y}_k = \tilde{Y}_k(:, \hat{\Omega}_r(l_1)), \tilde{r}_k = \tilde{y}_k$	
5. for $l_2 = 1, 2, \dots, L_{r,k}$ do	
6. 计算感知矩阵和残差向量之间的相关性 $n^* = \arg \max_{n=1,2,\dots,N} \ \tilde{\Theta}^H(:, n) \tilde{r}_k\ _F^2$	
7. 选取原子: $J_s = \text{find}(n^* \geq \alpha * \max(n^*))$	
8. 构成有效原子支撑集: $\hat{\Omega}_c^{l_1,k} = \hat{\Omega}_c^{l_1,k} \cup J_s$	
9. 初始化信道矩阵: $\hat{h}_k = 0_{N \times 1}$	
10. 使用 LS 算法对稀疏信道矩阵进行重构恢复: $\hat{h}_k = (\hat{\Omega}_c^{l_1,k})^{-1} \tilde{y}_k$	
11. 更新残差: $\tilde{r}_k = \tilde{y}_k - \tilde{\Theta} \hat{h}_k$	
12. 统计列索引的出现次数: $c^l(n^*) = c^l(n^*) + 1$	
13. end for	
14. end for	
16. 选取前 R_c 个列索引构成公共列支撑集: $\hat{\Omega}_c^{l_1, \text{Com}} = \Gamma_r(c^l, R_c)$	
17. 得到部分公共列支撑集 $\hat{\Omega}_c^{l_1, \text{Com}}$	

IWOA 优化模块和 DS-SWOMP 共同决定算法。DS-SWOMP 算法复杂度可分解为以下部分: 在算法 2 中, 对每个用户的接收信号 $\tilde{Y}_k \in \mathbb{C}^{Q \times M}$ 进行能量的计算和累加, 其复杂度为 $O(QM)$; 在算法 3 中, 在对单用户的稀疏信号进行恢复和估计时的复杂度为 $O(NQL_{r,k}^3)$, 结合对每个用户 k 的每个非零行 l_1 都进行了估计, 迭代总次数为 $L_G K$, 所以算法 3 的总体复杂度为 $O(L_G K NQL_{r,k}^3)$; 与算法 3 思想相同, 算法 4 的复杂度为 $O(L_G K NQ(L_{r,k} - |R_c|)^3)$ 。综上, DS-SWOMP 算法总体的复杂度为 $O(K(QM + L_G NQL_{r,k}^3))$ 。

IWOA 的复杂度主要取决于鲸鱼个体数量 P 和最大迭代次数 I , 在每一次迭代中, IWOA 都需要运行一次 DS-SWOMP 算法以评估每个个体的适应度, 因此 WOA-DS-SWOMP 算法的总体复杂度为 $O(PIK(QM + L_G NQL_{r,k}^3))$ 。

仿真结果表明, DS-SWOMP 算法在保持与 DS-

表 5 部分单独列支撑集估计算法

Tab.5 Partial separate column support set estimation

algorithm

算法 5:部分单独列支撑集估计算法	
输入:	测量矩阵 \tilde{Y}_k , 传感矩阵 $\tilde{\Theta}$, 行稀疏度 L_G , 列稀疏度 $L_{r,k}$, 公共非零行支撑集 $\hat{\Omega}_r$, 部分公共列支撑集 $\hat{\Omega}_c^{l_1, \text{Com}}$
1. 初始化单独列支撑集: $\hat{\Omega}_c^{l_1,k} = \hat{\Omega}_c^{l_1, \text{Com}}, \forall l_1, k$	
2. for $l_1 = 1, 2, \dots, L_G$ do	
3. for $k = 1, 2, \dots, K$ do	
4. $\tilde{y}_k = \tilde{Y}_k(:, \hat{\Omega}_r(l_1))$	
5. $\hat{h}_k = 0_{N \times 1}$	
6. $\hat{h}_k = (\hat{\Omega}_c^{l_1,k}(:, :)) = \tilde{\Theta}^H(:, \hat{\Omega}_c^{l_1,k}) \tilde{y}_k$	
7. $\tilde{r}_k = \tilde{y}_k - \tilde{\Theta} \hat{h}_k$	
8. for $l_2 = 1, 2, \dots, L_{r,k} - \text{length}(R_c)$ do	
9. $n^* = \arg \max_{n=1,2,\dots,N} \ \tilde{\Theta}^H(:, n) \tilde{r}_k\ _F^2$	
10. $\hat{\Omega}_c^{l_1,k} = \hat{\Omega}_c^{l_1,k} \cup n^*$	
11. $\hat{h}_k = 0_{N \times 1}$	
12. $\hat{h}_k = (\hat{\Omega}_c^{l_1,k}) = \tilde{\Theta}^H(:, \hat{\Omega}_c^{l_1,k}) \tilde{y}_k$	
13. $\tilde{r}_k = \tilde{y}_k - \tilde{\Theta} \hat{h}_k$	
14. end for	
15. end for	
16. end for	
19. 得到单独列支撑集 $\hat{\Omega}_c^{l_1,k}$	

OMP 相近复杂度的同时获得了更好的信道估计性能。尽管结合 IWOA 会增加算法的复杂度, 但其通过动态惯性权重与自适应阈值机制显著增强了算法对不同环境信道的鲁棒性, 获得更好的信道估计性能。此外, IWOA 采用的缓存机制可用历史最优解, 可以减少适应度函数的计算, 有效缓解了计算开销, 在实际应用中, IWOA-DS-OMP 算法的复杂度低于 $O(PIK(QM + L_G NQL_{r,k}^3))$ 。各算法的复杂度对比如表 6 所示。

表 6 算法复杂度对比

Tab. 6 Comparison of computational complexity

算法	复杂度
OMP	$O(NQ(L_G L_{r,k})^3)$
SWOMP	$O(NQ(L_G L_{r,k})^3)$
DS-OMP	$O(K(QM + L_G NQL_{r,k}^3))$
DS-SWOMP	$O(K(QM + L_G NQL_{r,k}^3))$
WOA-DS-SWOMP	$O(PIK(QM + L_G NQL_{r,k}^3))$
IWOA-DS-SWOMP	$\leq O(PIK(QM + L_G NQL_{r,k}^3))$

3 仿真分析

仿真参数设置如表7所示。

本文采用归一化均方根误差作为衡量标准，单位为dB，公式如下所示：

$$\text{NMSE} = 10 \lg \left(\frac{\sum_{k=1}^K \|\mathbf{H}_k - \hat{\mathbf{H}}_k\|_2^2}{\sum_{k=1}^K \|\mathbf{H}_k\|_2^2} \right) \quad (39)$$

图2所示为WOA和IWOA在不同导频开销Q下算法的收敛性对比图，设置适应度函数值为目标函数值。在Q较低时，由于系统观测数据不足，信道估计精度受限，相比于传统的WOA，IWOA能够更好地寻找最优解显著提升性能，其收敛速度以及优化性能优于WOA。在Q较高时，系统观测信息变得充

表7 仿真参数

Tab. 7 Simulation parameter

仿真参数	取值
天线数量M	64
RIS反射元件数量N	256
用户数量K	16
行稀疏度L _G	5
列稀疏度L _{r,k}	8
RIS-BS距离d _{RB} /m	10
UE-RIS距离d _{UR} /m	100
鲸鱼个体数量P	5
最大迭代次数t _{max}	80
精英个体比例λ	0.3
维度dim	1

足，信道估计本身已接近最优解，IWOA带来的提升空间有限。但总体来说，在所有Q下，IWOA在收敛性和寻优效果上均优于WOA。

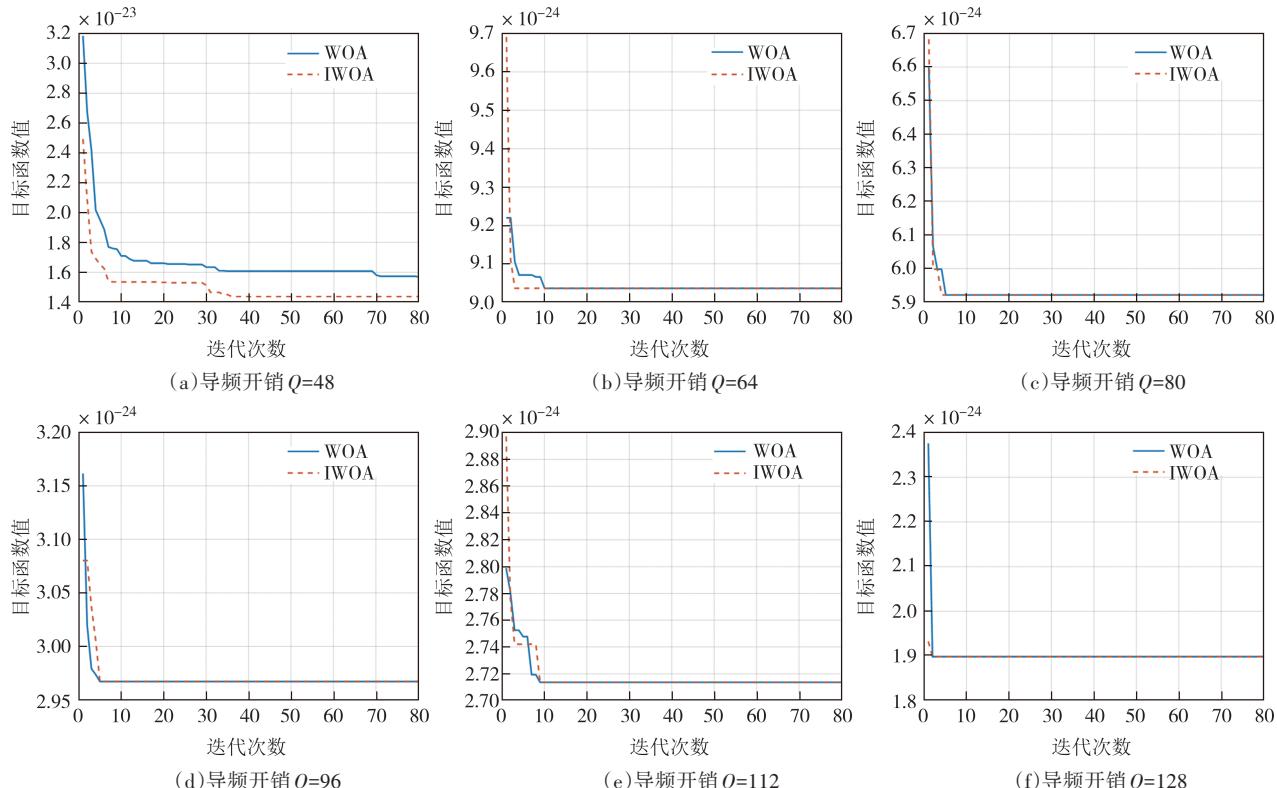


图2 不同导频开销下算法收敛对比图

Fig.2 Comparison diagram of algorithm convergence under different pilot overheads

图3所示为WOA-DS-SWOMP和IWOA-DS-SWOMP在不同导频开销Q下的算法运行时间对比图。随着Q增加，信道估计中矩阵运算涉及更高维度的数据，计算复杂度及运算时间上升。所提算法引入了缓存机制，在一定程度上可以减少适应度函数的计算，进而减少运算时间的运行时间，所提算

法在所有Q下的运算时间均小于WOA-DS-SWOMP算法，总体运算时间降低了23.5%。图2~图3表明所提算法在获得更好信道估计性能的基础上，有效提升了运算效率。

为验证算法改进模块的有效性，通过图4消融实验对比不同方案性能。完整方案为IWOA-DS-

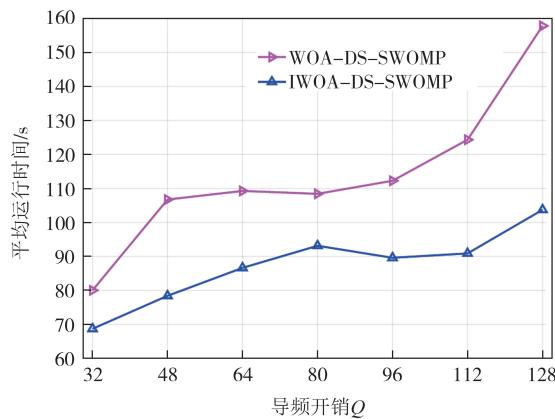


图 3 不同导频开销下的算法运行时间对比图

Fig.3 Comparison of algorithm running time under different pilot overhead

SWOMP, 其性能最优; 移除动态因子后的 WOA-DS-SWOMP 算法 NMSE 性能恶化, 验证了游动幅度因子 ε 和目标吸引力因子 γ 对全局搜索的促进作用; 固定阈值方案 DS-SWOMP 性能最差, 说明了自适应阈值优化对原子筛选的重要性.

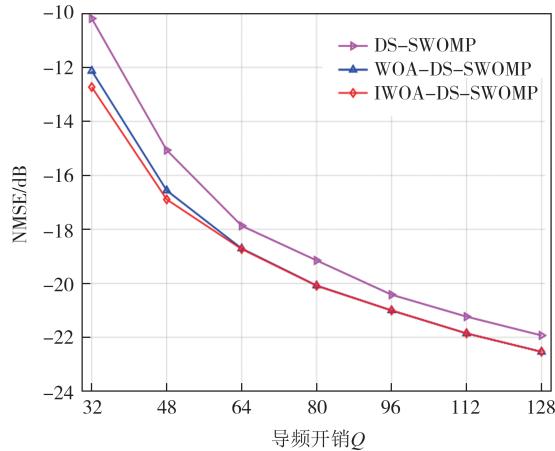


图 4 消融实验分析

Fig.4 Ablation study analysis

在 Q 较小时, 由于观测信息不足导致测量矩阵列相干性增强, 传统 WOA 因固定收敛因子与螺旋参数易陷入局部最优, 而 IWOA 通过 ε 和 γ 的协同调控, 在迭代初期强化全局探索以规避噪声干扰, 后期聚焦局部开发以提升收敛精度, 结合精英个体分组策略与缓存机制, 其 NMSE 性能较传统 WOA 降低; 当 Q 充足时, 测量矩阵正交性改善使得信道稀疏特征显化, 原子门限阈值敏感性降低, IWOA 的动态优化边际收益减弱, 但 IWOA 仍通过计算加速机制维持时间效率优势, 验证了其在复杂信道环境下的自适应性.

图 5 所示为所提方案在 SNR 为 0, 不同导频开销 Q 和不同原子门限阈值 α 下的 NMSE 性能. 在所有 Q 值下, NMSE 均随 α 呈现先降后升的趋势: α 过小时, 原子筛选过程会保留大量噪声主导的原子; α 过大时, 则会过度剔除有效原子, 特别是弱径分量, 这表明了存在使得估计误差最小的最优 α 阈值. 且在不同 Q 值下, 其对应最优的 α 是不同的: 当 Q 较低时, 信道投影能量易受噪声影响, 导致噪声与真实路径能量难以区分, 显著增强 NMSE 对 α 的敏感度; 随着 Q 增加, 导频序列的正交性增强, 原子能量分布呈现显著峰化特征, 真实路径对应的原子能量与噪声基底形成明显区分度, 使得 α 阈值能够在较宽范围内保持稳定的筛选能力.

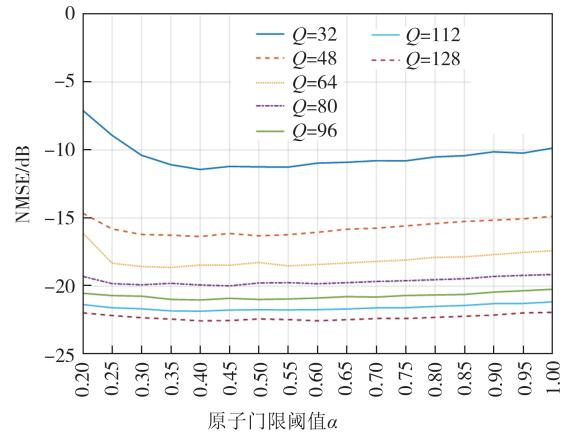


图 5 不同导频开销下的 NMSE

Fig.5 NMSE performance under different pilot overhead

在不同场景下信道的有效路径数及功率分布存在显著差异, 传统手动调参的方法难以实时适应信道的动态变化, 而 IWOA 可在高维参数空间中进行全局寻优, 有效克服了传统阈值选择中存在的经验依赖和场景失配问题.

图 6 所示为在 SNR 为 0, 不同导频开销 Q 下所提方案与 OMP 算法、SWOMP 算法、DS-OMP 算法 ($L_c = 6$)、DS-SWOMP 算法的 NMSE 对比. Q 的增加改善了测量矩阵的列相干性, 增强了原子与真实信道路径的匹配精度, 各算法性能均得到提升. 当 Q 为 128 时, 相比于传统 OMP 算法, 所提方案在 NMSE 性能上提升了约 4 dB; 相较于 SWOMP 算法, 提升了约 2 dB; 相较于 DS-OMP 算法提升了大约 1.5 dB. 这种显著优势源于所提算法在原子选择阶段, IWOA 动态调整阈值避免了 OMP/SWOMP 的贪婪迭代导致的误差累积.

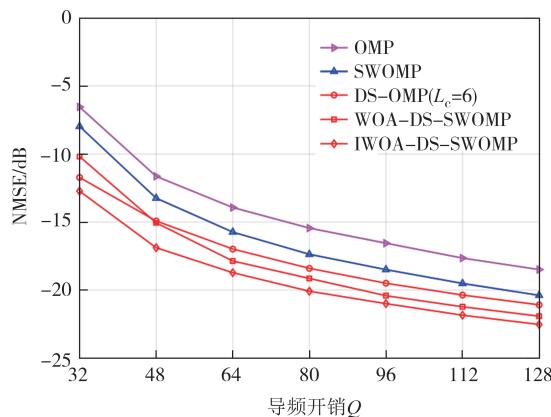


图 6 NMSE 随导频开销变化曲线

Fig.6 NMSE curve with pilot overhead

当 Q 较小时, DS-SWOMP 算法因固定阈值导致的噪声原子误选和弱径漏检, 性能劣于通过局部约束保持鲁棒性的 DS-OMP. 随着 Q 增大, DS-OMP 的固定约束会引入冗余的原子, 导致搜索方向偏移, 而 DS-SWOMP 的弱正交性通过单次迭代选择多个原子提升匹配精度. 所提算法通过 IWOA 自适应调整 DS-SWOMP 的阈值, 动态平衡原子筛选的灵敏度和特异性, 使其在所有 Q 值下均优于其他算法, 特别是在低导频时, 相比 DS-SWOMP 算法提升了约 2.5 dB, 验证了所提算法在非平稳信道环境中的泛化能力.

在图 7 中, 将所提方案的 NMSE 性能与 OMP 算法、SWOMP 算法、DS-OMP 算法 ($L_c = 6$) 在不同 SNR 下进行比较. 由图 6 可知, 不同算法的 NMSE 随着 SNR 的增大均呈现降低的趋势, 随着 SNR 的增大, 使得信道投影能量与噪声基底可区分度显著增强, 噪声影响逐渐变小, 各方案的 NMSE 性能都有所提升, 所提方案在不同 SNR 下的性能均优于其他算法. 所提方案在 SNR 较低时, IWOA 自动优化原子门限阈值, 放宽原子选择条件, 并通过残差能量检测补偿噪声干扰, 使其在低 SNR 下有效提升路径的捕获率; 在高 SNR 环境下, 噪声功率降低使得传统算法性能都有所提升, 但所提算法通过对列支撑集的动态扩展仍然保持性能优势.

图 8 所示为不同 RIS-BS 路径数目 L_G 对所提算法的影响. 随着导频开销 Q 的增加, 各 L_G 配置下的 NMSE 性能均呈现下降趋势, 而在相同的 Q 下, L_G 的取值越大则 NMSE 的性能越差. 当 RIS-BS 间仅有单

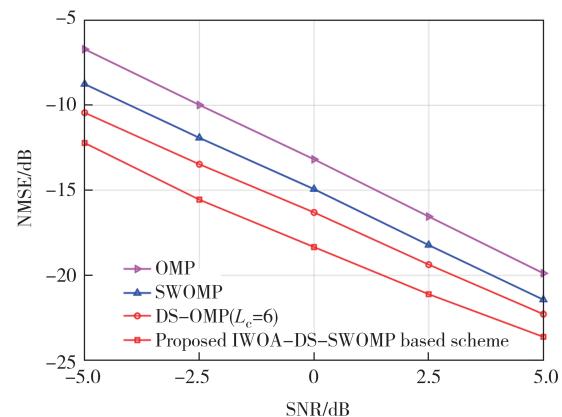


图 7 NMSE 随 SNR 变化曲线

Fig.7 NMSE curve with SNR

一路径时, 信道矩阵具备理想稀疏特性, 算法在原子选择阶段能精准捕捉唯一路径特征, 因此当 $L_G = 1$ 时, NMSE 始终最低, 且随 Q 的增加斜率逐渐稳定; 随着 L_G 的增加, 信道稀疏度降低, 需要更多的导频补偿稀疏性的损失, 同时原子相关性增强, 算法更难准确地选择原子, 导致信道估计算法性能下降.

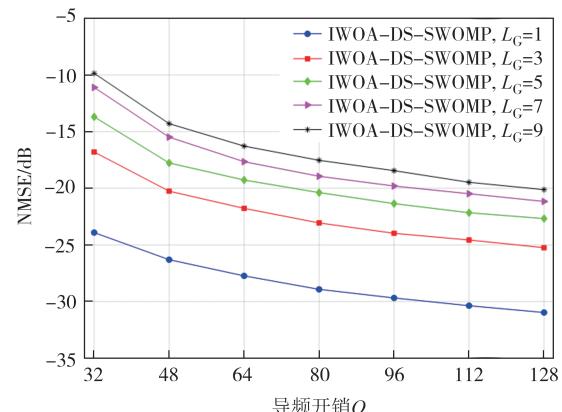


图 8 不同 RIS-BS 路径数目下算法性能对比

Fig.8 Algorithm performance comparison under different RIS-BS path counts

图 9 所示为不同 UE-RIS 路径数目 $L_{r,k}$ 对所提算法的影响. 由图 9 可知, 随着导频开销 Q 的增加, 各 $L_{r,k}$ 配置下的 NMSE 性能均呈现下降趋势, 而在相同的 Q 下, $L_{r,k}$ 的取值越大则 NMSE 的性能越差. 随着 $L_{r,k}$ 的增大, 信道矩阵的稀疏性降低, 导致支撑集选择不完整, 残差中残留显著的非零分量, 使得用户特有路径占比提高, 公共支撑集规模缩小, 公共列估计效率下降, 导致 NMSE 性能恶化, 算法需要更多的 Q 才能维持相同的性能.

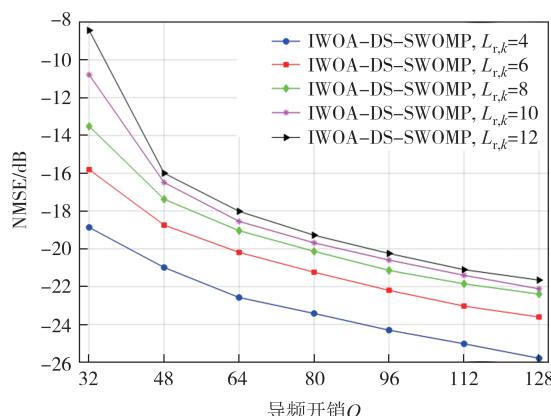


图 9 不同 UE-RIS 路径数目下算法性能对比
Fig.9 Algorithm performance comparison under different UE-RIS path counts

4 结论

本文针对 RIS 辅助多用户毫米波无线通信系统进行信道估计导频开销大、自适应能力差等关键问题, 提出了 IWOA-DS-SWOMP 算法。首先引入原子门限阈值, 采用 DS-SWOMP 算法选取多个强相关性的原子来构成原子支撑集, 同时应用 IWOA 对原子门限选择阈值进行优化。结果表明, 相比于传统的信道估计方案, 所提出的信道估计方案在导频开销、自适应能力方面表现出显著的优势, 能够有效提升信道估计的精度, 降低算法运行时间。

下一步工作将考虑:

- 1) 针对 RIS 辅助的多用户动态场景, 优化算法在动态场景中的自适应能力。
- 2) 针对不同 RIS 配置(如元素数目、位置、反射系数等), 分析算法在不同配置下的性能, 进而提出针对特定配置的自适应优化方案。

参考文献

- [1] 邵凯, 鲁奔, 王光宇. 可重构智能表面辅助通信系统时变级联信道估计[J]. 通信学报, 2024, 45(1):119–128.
- SHAO K, LU B, WANG G Y. Time-varying channel estimation in reconfigurable intelligent surface assisted communication system [J]. Journal on Communications, 2024, 45(1): 119–128. (in Chinese)
- [2] LONG R Z, LIANG Y C, PEI Y Y, et al. Active reconfigurable intelligent surface-aided wireless communications [J]. IEEE Transactions on Wireless Communications, 2021, 20(8): 4962–4975.
- [3] YANG S J, XIE C F, LYU W T, et al. Near-field channel estimation for extremely large-scale reconfigurable intelligent surface (XL-RIS)-aided wideband mmwave systems [J]. IEEE Journal on Selected Areas in Communications, 2024, 42(6): 1567–1582.
- [4] WIKSTRÖM G, PEISA J, RUGELAND P, et al. Challenges and technologies for 6G [C]//2020 2nd 6G Wireless Summit (6G SUMMIT). March 17–20, 2020, Levi, Finland. IEEE, 2020: 1–5.
- [5] ROSHDY R A, SALEM M A. A proposed channel estimation framework for reconfigurable-intelligent-surface-aided MIMO communication system [J]. IEEE Internet of Things Journal, 2023, 10(15): 13612–13621.
- [6] GUO J J, WEN C K, JIN S, et al. Overview of deep learning-based CSI feedback in massive MIMO systems [J]. IEEE Transactions on Communications, 2022, 70(12): 8017–8045.
- [7] 刘恒. RIS 辅助通信系统信道估计和波束设计研究[D]. 北京: 北京交通大学, 2022.
- LIU H. Research on channel estimation and beamforming design in RIS-assisted communication systems [D]. Beijing: Beijing Jiaotong University, 2022. (in Chinese)
- [8] HASAN A, MOTAKABBER S M A, ANWAR F, et al. A computationally efficient least squares channel estimation method for MIMO-OFDM systems [C]//2021 8th International Conference on Computer and Communication Engineering (ICCCE). June 22–23, 2021, Kuala Lumpur, Malaysia. IEEE, 2021: 331–334.
- [9] KUNDU N K, MCKAY M R. Channel estimation for reconfigurable intelligent surface aided MISO communications: from LMMSE to deep learning solutions [J]. IEEE Open Journal of the Communications Society, 2021, 2: 471–487.
- [10] HU Q, GAO F F, ZHANG H, et al. Deep learning for channel estimation: interpretation, performance, and comparison [J]. IEEE Transactions on Wireless Communications, 2021, 20(4): 2398–2412.
- [11] FENG H, XU Y T, ZHAO Y P. Deep learning-based joint channel estimation and CSI feedback for RIS-assisted communications [J]. IEEE Communications Letters, 2024, 28(8): 1860–1864.
- [12] AHMAD S, SHAKEEL I, MEHFUZ S, et al. Deep learning models for cloud, edge, fog, and IoT computing paradigms: survey, recent advances, and future directions [J]. Computer Science Review, 2023, 49: 100568.
- [13] ZHANG W G, LI H R, LI Y Q, et al. Application of deep

- learning algorithms in geotechnical engineering: a short critical review [J]. Artificial Intelligence Review, 2021, 54(8): 5633–5673.
- [14] SHI X, WANG J T, SONG J. Triple-structured compressive sensing-based channel estimation for RIS-aided MU-MIMO systems [J]. IEEE Transactions on Wireless Communications, 2022, 21(12): 11095–11109.
- [15] UWAECHIA A N, MAHYUDDIN N M. A review on sparse channel estimation in OFDM system using compressed sensing[J]. IETE Technical Review, 2017, 34(5): 514–531.
- [16] WU J L, LI Y, XIN L J. Joint channel estimation for RIS-assisted wireless communication system [C]//2022 IEEE Wireless Communications and Networking Conference (WCNC). April 10–13, 2022, Austin, TX, USA. IEEE, 2022:1087–1092.
- [17] CHEN J, LIANG Y C, CHENG H V, et al. Channel estimation for reconfigurable intelligent surface aided multi-user mmWave MIMO systems [J]. IEEE Transactions on Wireless Communications, 2023, 22(10): 6853–6869.
- [18] WEI X H, SHEN D C, DAI L L. Channel estimation for RIS assisted wireless communications: part II : an improved solution based on double-structured sparsity [J]. IEEE Communications Letters, 2021, 25(5): 1403–1407.
- [19] BLUMENSATH T, DAVIES M E. Stagewise weak gradient pursuits [J]. IEEE Transactions on Signal Processing, 2009, 57(11): 4333–4346.
- [20] NGUYEN T H P, TO T N, TRAN-THI D, et al. 5G channel estimation based on whale optimization algorithm [J]. Wireless Communications and Mobile Computing, 2023, 2023:5800673.
- [21] GAO X Y, DAI L L, ZHOU S D, et al. Wideband beamspace channel estimation for millimeter-wave MIMO systems relying on lens antenna arrays [J]. IEEE Transactions on Signal Processing, 2019, 67(18): 4809–4824.
- [22] LIU K, FENG H, YANG T, et al. Structured sparse channel estimation for 3D-MIMO systems[C]// 2016 IEEE 83rd Vehicular Technology Conference (VTC Spring). May 15–18, 2016, Nanjing, China. IEEE, 2016:1–6.
- [23] MIRJALILI S, LEWIS A. The whale optimization algorithm[J]. Advances in Engineering Software, 2016, 95: 51–67.