

# Otimização de Redes de Comunicações Sem Fio com RSMA e STAR-RIS

Victoria Dala Pegorara Souto<sup>1</sup> Richard Demo Souza<sup>2</sup> Bartolomeu F. Uchôa-Filho<sup>3</sup>

**Resumo**— Este artigo considera um sistema de comunicação sem fio assistido por uma Superfície Inteligente Reconfigurável de Transmissão e Reflexão Simultânea (STAR-RIS, do inglês *Simultaneous Transmission and Reflection Reconfigurable Intelligent Surface*) considerando a Técnica de Acesso Múltiplo de Divisão de Taxa (RSMA, do inglês *Rate Splitting Multiple Access*). STAR-RIS é uma nova tecnologia que, diferente da RIS tradicional, é capaz não só de refletir, mas também de transmitir o sinal incidente. No entanto, devido ao grande número de elementos na STAR-RIS, a aquisição precisa da Informação do Estado do Canal (CSI, do inglês *Channel State Information*) demanda uma sobrecarga considerável de treinamento, o que é limitante em cenários práticos. Portanto, neste trabalho, é proposta uma nova solução baseada na técnica de Otimização por Enxame de Partículas (PSO, do inglês *Particle Swarm Optimization*) para maximizar a taxa total (*sum-rate*) do sistema a partir da otimização conjunta do vetor de alocação de taxa, do vetor de *beamforming* na estação base (BS, do inglês *Base Station*) e dos coeficientes de transmissão e reflexão da STAR-RIS sem conhecimento do CSI. Os resultados mostram que a nova solução supera os sistemas de acesso múltiplo ortogonal (OMA) e não ortogonal (NOMA) assistidos por STAR-RIS.

**Palavras-Chave**— STAR-RIS, RSMA, Beamforming, Otimização por Enxame de Partículas.

**Abstract**— This article considers a wireless communication system assisted by a Simultaneous Transmission and Reflection Reconfigurable Intelligent Surface (STAR-RIS) considering the Rate Division Multiple Access technique (RSMA). STAR-RIS is a novel technology that, unlike traditional RIS, is capable of not only reflecting but also transmitting the incident signal. However, due to the large number of elements at the STAR-RIS, the accurate acquisition of Channel State Information (CSI) requires considerable training overhead, which is limiting in practical scenarios. Therefore, in this work, a novel solution based on the Particle Swarm Optimization (PSO) technique is proposed to maximize the achievable sum-rate of the system by jointly optimizing the rate allocation vector, the *beamforming* vector at the BS, and the transmission and reflection coefficients of the STAR-RIS without any knowledge of the CSI. The results show that the proposed solution outperforms orthogonal (OMA) and non-orthogonal (NOMA) multiple access techniques assisted by STAR-RIS.

**Keywords**— STAR-RIS, RSMA, Beamforming, Particle Swarm Optimization.

## I. INTRODUÇÃO

Superfícies Inteligentes Reconfiguráveis (RIS) são consideradas uma tecnologia chave para atender requisitos da Sexta Geração (6G) de Sistemas Comunicação Sem Fio [1]. Mais

especificamente, RIS é uma metasuperfície bidimensional (2D) equipada com um grande número de elementos os quais são capazes de refletir o sinal incidente para uma dada direção a partir do controle inteligente da amplitude e fase de cada elemento [1]. Apesar das suas vantagens, as RISs apenas refletem o sinal incidente e, conseqüentemente, têm sua cobertura limitada em 180°, o que limita a flexibilidade e o desempenho da rede [1].

Para mitigar este problema, recentemente, um novo conceito de RIS denominado RIS de Transmissão e Reflexão Simultânea (STAR-RIS, do inglês *Simultaneous Transmission and Reflection RIS*) foi desenvolvido [2]. A STAR-RIS, diferentemente da RIS tradicional, tem a capacidade de transmitir e refletir simultaneamente o sinal incidente, a partir do controle dos coeficientes de transmissão e reflexão de cada elemento da STAR-RIS. Isto proporciona um grau extra de liberdade e melhora o desempenho do sistema. Ademais, a STAR-RIS é projetada considerando metamateriais transparentes, o que permite que usuários posicionados em ambos os lados da STAR-RIS sejam atendidos, garantindo uma cobertura de 360° e aumentando a flexibilidade e o desempenho da rede [2].

Outra tecnologia promissora para satisfazer os requisitos das Redes 6G é a técnica de acesso múltiplo de divisão de taxa (RSMA, do inglês *Rate Splitting Multiple Access*) [3]. Diferentemente das técnicas convencionais de acesso múltiplo ortogonal (OMA, do inglês *Orthogonal Multiple Access*), o RSMA permite o compartilhamento efetivo de recursos da rede para atender múltiplos usuários no mesmo bloco de recursos, onde o cancelamento de interferência sucessivo (SIC, do inglês *Successive Interference Cancellation*) é aplicado [4]. Mais especificamente, o RSMA permite que múltiplos usuários acessem o mesmo bloco de recursos e divide a taxa de cada usuário em várias mensagens não-ortogonais. A divisão da taxa dos usuários permite a alocação eficiente de recursos e, portanto, proporciona maior eficiência espectral em comparação com esquemas de acesso múltiplo não ortogonal (NOMA, do inglês *Non-Orthogonal Multiple Access*) clássicos [3], [4].

Motivados pelas vantagens previamente apresentadas, recentemente, alguns trabalhos estudaram a integração de STAR-RIS e RSMA em sistemas de comunicações sem fio [5]–[9]. Mais especificamente, em [5], os autores investigaram um sistema de *downlink* multiusuário assistido por STAR-RIS e RSMA. Neste trabalho foi proposto um novo algoritmo de *deep reinforcement learning* baseado em otimização de política proximal para maximizar a taxa total (*sum-rate*) da rede. Em [6], a probabilidade de interrupção e a capacidade da rede foram avaliadas em canais de desvanecimento Rician espacialmente correlacionados. Em [7], a taxa soma de *uplink*

<sup>1</sup> National Institute of Telecommunications, Santa Rita do Sapucaí, MG, Brazil.

<sup>2</sup> Federal University of Santa Catarina, Florianópolis, SC, Brazil.

<sup>3</sup> Aeronautics Institute of Technology, São José dos Campos, SP, Brazil.

victoria.souto@inatel.br, richard.demo@ufsc.br, bartolomeu@ita.br




Fig. 1: Modelo do sistema.

foi maximizada a partir da otimização conjunta dos coeficientes de transmissão e recepção da STAR-RIS, da alocação de energia e da ordem de decodificação. Por fim, em [8] foram definidas as expressões analíticas de forma fechada da probabilidade de interrupção para cada usuário para diferentes modos de operação da STAR-RIS, considerando um sistema de comunicação multiusuário de *downlink*.

Motivados pelas vantagens da integração de STAR-RISs e RSMA nas Redes 6G, este trabalho propõe um novo método baseado na técnica de Otimização por Enxame de Partícula (PSO, do inglês *Particle Swarm Optimization*) para projetar conjuntamente o vetor de *beamforming* na BS, os coeficientes de reflexão e transmissão dos elementos da STAR-RIS e a alocação de taxa comum dos usuários sem considerar conhecimento explícito da CSI na BS. Nosso objetivo é maximizar a taxa total (*sum-rate*) e, ao mesmo tempo, atender ao requisito de taxa mínima alcançável para cada usuário e de taxa mínima alocada para a mensagem de fluxo comum do RSMA. Diferente dos trabalhos citados anteriormente, neste artigo não consideramos a estimativa explícita do CSI [5]–[8]. Além disso, a solução proposta não depende de dados para treinamento e apresenta baixa complexidade computacional. A principal contribuição deste trabalho é mostrar que é possível atingir um desempenho próximo ao ótimo, sem a necessidade de aquisição do CSI.

## II. MODELO DO SISTEMA

Neste trabalho consideramos um sistema de comunicação sem fio assistido por uma STAR-RIS conforme ilustrado na Figura 1. Mais especificamente, consideramos uma BS equipada com uma arranjo linear uniforme (ULA, do inglês *Uniform Linear Array*) com  $N$  antenas assistida por uma STAR-RIS equipada com  $M$  elementos e  $K = 2$  usuários de antena única posicionados em ambos os lados da STAR-RIS, ou seja, um usuário no plano de transmissão ( $UE_t$ ) e um usuário no plano de reflexão ( $UE_r$ ). Neste trabalho, assumimos mobilidade limitada ou muito limitada, de modo que os canais mudam lentamente. Além disso, visando obter o ganho máximo de *beamforming* e reduzir a complexidade de *hardware* da STAR-RIS, consideramos que a STAR-RIS opera no modo *Energy Splitting* (ES) no qual cada elemento da STAR-RIS opera simultaneamente nos modos de transmissão e reflexão, dividindo a energia do sinal entre os sinais transmitidos e refletidos [10].

Além disso, consideramos a técnica RSMA. A ideia básica do RSMA é dividir a mensagem transmitida ao  $k$ -ésimo usuário em duas partes, uma parte comum  $s_{c_k}$  e uma parte privada  $s_{p_k}$  para  $k \in \{r, t\}$  em que  $r$  denota o índice do usuário no plano de reflexão ( $UE_r$ ) e  $t$  o índice do usuário no plano de transmissão ( $UE_t$ ) [3]. O processo de combinação de  $s_{c_k}$  e  $s_{p_k}$  é realizado empregando um *codebook compartilhado* para gerar um único fluxo denotado como  $s_c$  e um *codebook privado* conhecido apenas pela BS e pelo  $k$ -ésimo usuário para gerar um fluxo  $s_k$ , respectivamente. Logo, através do RSMA, a BS é capaz de transmitir simultaneamente um fluxo de mensagem comum e  $K$  fluxos de mensagens privadas [3], [4]. Portanto, o sinal transmitido pela BS é dado por

$$\mathbf{x} = \mathbf{w}_c s_c + \sum_{k \in \{r, t\}} \mathbf{w}_k s_k, \quad (1)$$

em que  $\mathbf{w}_c$  e  $\mathbf{w}_k$  denotam o vetor de *beamforming* na BS para os fluxos de mensagem  $s_c$  e  $s_k$ , respectivamente. O sinal recebido pelo  $k$ -ésimo usuário é dado por

$$\begin{aligned} y_k &= \mathbf{C}_k \mathbf{x} + n_k = \underbrace{\mathbf{C}_k \mathbf{w}_c s_c}_{\text{Sinal Desejado Comum}} + \underbrace{\mathbf{C}_k \mathbf{w}_k s_k}_{\text{Sinal Desejado Privado}} \\ &+ \underbrace{\sum_{i \in \{r, t\}, i \neq k} \mathbf{C}_k \mathbf{w}_i s_i}_{\text{Interferência}} + \underbrace{n_k}_{\text{Ruído}}, \quad (2) \end{aligned}$$

em que  $k \in \{r, t\}$ ,  $\mathbf{C}_k$  denota o ganho de canal do  $k$ -ésimo usuário. Vale ressaltar que  $\mathbf{C}_k$  varia para dispositivos no plano de transmissão e recepção pois, conforme ilustrado na Figura 1, diferentemente do link direto entre a BS e  $UE_t$  no plano de transmissão, o link direto entre a BS e  $UE_r$  no plano de reflexão não está bloqueado. Portanto,  $\mathbf{C}_r = [\mathbf{G}\Theta_r \mathbf{h}_r^H + \mathbf{h}_D]$  para o dispositivo no plano de recepção e  $\mathbf{C}_t = [\mathbf{G}\Theta_t \mathbf{h}_t^H]$  para o dispositivo no plano de transmissão. Ademais,  $\mathbf{G} \in \mathbb{C}^{N \times M}$  denota a matriz do canal entre a BS e a STAR-RIS,  $\mathbf{h}_k \in \mathbb{C}^{1 \times M}$  é o vetor de canal entre a STAR-RIS e o  $UE_k$ ,  $\mathbf{h}_D \in \mathbb{C}^{1 \times N}$  é o vetor de canal entre a BS e o  $UE_r$  e  $n_k$  denota o ruído aditivo Gaussiano branco no  $k$ -ésimo usuário com potência  $\sigma^2$ . Além disso,  $\Theta_k = \text{diag}(\sqrt{\beta_1^k} e^{j\theta_1^k}, \dots, \sqrt{\beta_M^k} e^{j\theta_M^k})$  em que  $k \in \{r, t\}$  denota os índices que representam o plano de transmissão e reflexão,  $\theta^k = [\theta_1^k, \dots, \theta_M^k]$  denota o vetor de mudança de fase transmitido/refletido com  $\theta_m^k \in [0, 2\pi)$  para  $m = 1, \dots, M$  e  $\sqrt{\beta_m^k} \in [0, 1]$  é o coeficiente de amplitude. As mudanças de fase para o modo de reflexão e transmissão (ou seja,  $\theta_m^r$  e  $\theta_m^t$ ) podem ser definidas independentemente. Porém, os coeficientes de amplitude precisam obedecer à lei da conservação de energia, ou seja,  $\beta_m^t + \beta_m^r = 1 \forall m$ , consequentemente,  $\beta_m^t$  e  $\beta_m^r$  são acoplados e não podem ser otimizados independentemente [10].

Após receber  $y_k$  no  $k$ -ésimo usuário, o fluxo comum é decodificado utilizando o *codebook compartilhado*. Logo, a máxima taxa de dados para a decodificação de  $s_c$  de usuários no plano de reflexão e transmissão é dada por

$$r_k = \log_2 \left( 1 + \frac{|\mathbf{C}_k \mathbf{w}_c|^2}{\sum_{i \in \{r, t\}} |\mathbf{C}_k \mathbf{w}_i|^2 + \sigma_k^2} \right), \quad (3)$$

em que  $\mathbf{C}_k = \mathbf{C}_r = [\mathbf{G}\Theta_r \mathbf{h}_r^H + \mathbf{h}_D]$  para o dispositivo no plano

de recepção ( $UE_r$ ) e  $\mathbf{C}_k = \mathbf{C}_t = [\mathbf{G}\Theta, \mathbf{h}_t^H]$  para o dispositivo no plano de transmissão ( $UE_t$ ).

Para garantir que cada usuário decodifique o fluxo comum com sucesso deve-se garantir que  $\sum_{k \in \{r,t\}} a_k \leq \min_{k \in \{r,t\}} r_k$  em que  $a_k$  denota a parte da taxa comum alocada ao  $k$ -ésimo usuário. Por fim, após decodificar  $s_c$ , remove-se a interferência introduzida por  $s_c$  com auxílio do SIC. Após isso, cada usuário decodifica  $s_k$  de forma independente, tratando as demais mensagens privadas como interferência. Portanto, a taxa de dados para a decodificação de  $s_k$  para o  $k$ -ésimo usuário em que  $k \in \{r, t\}$  é dada por

$$R_k = \log_2 \left( 1 + \frac{|\mathbf{C}_k \mathbf{w}_k|^2}{\sum_{i \in \{r,t\}, i \neq k} |\mathbf{C}_k \mathbf{w}_i|^2 + \sigma_k^2} \right), \quad (4)$$

Por fim, a taxa de dados total do sistema é dada por

$$R_T = \sum_{k \in \{r,t\}} (a_k + R_k). \quad (5)$$

### A. Problema de Otimização Proposto

O principal objetivo deste artigo é maximizar a taxa total (*sum-rate*) do sistema enquanto satisfaz as restrições de taxa mínima do usuário e de taxa de fluxo comum dos usuários, sem conhecimento do CSI na BS. Para o problema proposto, considera-se a otimização conjunta do vetor de *beamforming* na BS ( $\mathbf{W} = [\mathbf{w}_r, \mathbf{w}_t]$ ), dos coeficientes de reflexão/transmissão de cada elemento da STAR-RIS ( $\Phi = [\Theta_r, \Theta_t]$ ) e do vetor de alocação de taxa para a decodificação da mensagem comum ( $\mathbf{a} = [a_r, a_t]$ ). Portanto, o problema de otimização proposto pode ser formulado como

$$\begin{aligned} & \text{Maximize}_{\mathbf{W}, \Phi, \mathbf{a}} && R_T \\ & \text{Subject to} && a_k + R_k \geq \gamma_k, \\ & && \sum_{k \in \{r,t\}} a_k \leq \min_{k \in \{r,t\}} r_k, \quad a_k \geq 0 \\ & && \|\mathbf{w}_k\|^2 \leq P_T, \\ & && \beta_m^t + \beta_m^r = 1 \\ & && 0 \leq \theta_m^k \leq 2\pi, \\ & && \forall m, \quad m \in \{1, \dots, M\}, \quad \forall k \in \{r, t\}, \end{aligned} \quad (6)$$

onde  $\gamma_k$  é a restrição de taxa mínima para cada usuário e  $P_T$  denota a potência de transmissão da BS. Como este problema de otimização é não convexo, não existe um método padrão para resolvê-lo. Portanto, neste artigo, propomos uma nova solução baseada na técnica PSO.

## III. SOLUÇÃO PROPOSTA

Neste trabalho foi proposta uma solução baseada em PSO. PSO é um método de otimização estocástico o qual pode ser utilizado para resolver problemas complexos das mais diversas áreas da engenharia [11]. Portanto, baseados nas vantagens do PSO, propomos uma nova abordagem baseada em PSO para resolver (6). Para uma melhor compreensão do leitor, o método proposto é apresentado no Algoritmo 1 e os passos do método proposto são descritos a seguir.

1. Gere aleatoriamente  $L$  partículas, ou seja,  $(\mathbf{W}_l, \Phi_l, \mathbf{a}_l)$ , em que  $l = 1, \dots, L$  que denota as “posições” das

partículas. Uma “partícula” pode ser definida como uma possível solução para o problema de otimização.

2. Compute a aptidão de cada partícula, ou seja, compute  $R_T$ .
3. Atualize  $p_{\text{best}}$  e  $g_{\text{best}}$  a partir da aptidão calculada na etapa anterior:  $p_{\text{best}}$  é a melhor aptidão obtida para cada partícula até a iteração atual, e  $g_{\text{best}}$  é a melhor aptidão obtida para todas as partículas até a iteração atual.
4. Atualize a velocidade de cada partícula de acordo com,

$$\mathbf{v}_i^g = \omega \mathbf{v}_i^g + \ell_1 \text{rand}() (p_{\text{best}_i}^g - \mathbf{x}_i^g) + \ell_2 \text{rand}() (g_{\text{best}}^g - \mathbf{x}_i^g), \quad (7)$$

em que  $g \in \{1, \dots, N_{\text{it}}\}$  é a iteração atual da partícula  $i \in \{1, \dots, L\}$  onde  $L$  é o número de partículas no enxame e  $N_{\text{it}}$  denota o número total de iterações.  $\mathbf{v}_i^g$  e  $\mathbf{x}_i^g$  denotam a velocidade e a posição da partícula  $i$  na iteração  $g$ , respectivamente,  $\ell_1$  e  $\ell_2$  são os fatores de aprendizagem das partículas, enquanto a função  $\text{rand}()$  retorna um número aleatório entre 0 e 1 com distribuição uniforme [11]. Além disso,  $\omega$  é o fator de inércia definido como  $\omega = \omega_{\text{max}} - \frac{(\omega_{\text{max}} - \omega_{\text{min}})g}{N_{\text{it}}}$ , em que  $\omega_{\text{max}}$  e  $\omega_{\text{min}}$  são o máximo e o mínimo de  $\omega$  [11].

4. Atualize a posição de cada partícula de acordo com,

$$\mathbf{x}_i^{g+1} = \mathbf{x}_i^g + \mathbf{v}_i^{g+1} \quad (8)$$

5. Verifique se o critério de parada foi atendido. Nesse caso, retorne a partícula mais apta ( $\mathbf{W}_{\text{best}}, \Phi_{\text{best}}, \mathbf{a}_{\text{best}}$ ). Caso contrário, volte para a Etapa 2.

---

### Algoritmo 1: Método proposto baseado em PSO.

---

**Entrada:** Parâmetros do Sistema:  $N, M$

Parâmetros PSO:  $L, N_{\text{it}}, \ell_1, \ell_2, \omega_{\text{min}}, \omega_{\text{max}}$

**Saída** :  $\mathbf{W}_{\text{best}}, \Phi_{\text{best}}, \mathbf{a}_{\text{best}}$

- 1 Inicialize a posição  $\mathbf{x}_{\text{BS}} = \mathbf{W}$ ,  $\mathbf{x}_{\text{SR}} = \Phi$  e  $\mathbf{x}_a = \mathbf{a}$ ;
  - 2 Inicialize a velocidade  $\mathbf{v}_{\text{BS}}, \mathbf{v}_{\text{SR}}$  e  $\mathbf{v}_a$ ;
  - 3  $\mathbf{x}_i = (\mathbf{x}_{\text{BS}_i}, \mathbf{x}_{\text{SR}_i}, \mathbf{x}_{a_i})$ ;
  - 4  $\mathbf{v}_i = (\mathbf{v}_{\text{BS}_i}, \mathbf{v}_{\text{SR}_i}, \mathbf{v}_{a_i})$ ;
  - 5 Determine  $g_{\text{best}}$  e  $p_{\text{best}}$ .
  - 6 **for**  $g = 1 : N_{\text{it}}$  **do**
  - 7     **for**  $i = 1 : L$  **do**
  - 8         Atualize  $\mathbf{v}_i^g$  de acordo com (7).
  - 9         Atualize  $\mathbf{x}_i^g$  de acordo com (8).
  - 10         Atualize  $p_{\text{best}}$
  - 11     **end**
  - 12     Atualize  $g_{\text{best}} = \mathbf{x}_{\text{best}}$
  - 13 **end**
  - 14  $\mathbf{W}_{\text{best}} = g_{\text{best}}, \Phi_{\text{best}} = g_{\text{best}}, \mathbf{a}_{\text{best}} = g_{\text{best}}$
  - 15 **return**  $\mathbf{W}_{\text{best}}, \Phi_{\text{best}}, \mathbf{a}_{\text{best}}$
- 

Neste trabalho, os principais parâmetros utilizados no Algoritmo 1 são:  $N_{\text{it}} = 1000, L = 10, \ell_1 = \ell_2 = 1, \omega_{\text{min}} = 0, 2,$  e  $\omega_{\text{max}} = 0, 9$ . Esses parâmetros foram selecionados após extensas simulações. Em nosso método proposto, os pares de vetores de *beamforming* na BS e STAR-RIS a serem testados são definidos na BS, enquanto o *beamforming* na STAR-RIS é enviado pela BS para o controlador mostrado na Figura 1. Então, para cada par de *beamforming*, o *feedback* da SINR

(do inglês, *Signal-to-Interference-plus-Noise Ratio*) no usuário é recebido na BS/STAR-RIS, e o par de *beamforming* atual é avaliado com base em  $R_T$ . Este processo é realizado para todos os pares de *beamforming*. Portanto, observe que os canais BS/STAR-RIS/UE não são explicitamente estimados.

#### IV. RESULTADOS E DISCUSSÕES

Todas as curvas nesta seção são geradas a partir da média de  $10^3$  realizações independentes de canal. Ademais, consideramos que  $d_G$  é a distância horizontal entre a BS e a STAR-RIS,  $d_v$  é a distância vertical, e  $d_r$  e  $d_t$  denotam a distância horizontal entre a STAR-RIS e o UE<sub>r</sub> e o UE<sub>t</sub>, respectivamente. Portanto,  $d_{St} = \sqrt{d_t^2 + d_v^2}$ ,  $d_{Sr} = \sqrt{d_r^2 + d_v^2}$ ,  $d_{Br} = \sqrt{(d_G - d_r)^2 + d_v^2}$ , e  $d_{Bt} = \sqrt{(d_G + d_t)^2 + d_v^2}$  são a distância entre a STAR-RIS e o UE<sub>t</sub>, a STAR-RIS e o UE<sub>r</sub>, a BS e UE<sub>r</sub>, e a BS e UE<sub>t</sub>, respectivamente. Além disso, assumimos o desvanecimento Rice e a perda de percurso logarítmica para todos os canais, os quais são definidos por

$$\mathbf{h} = \sqrt{C_0 \left(\frac{d_j}{d_0}\right)^{-\alpha_j}} \left( \sqrt{\frac{\kappa_j}{1 + \kappa_j}} \mathbf{h}^{\text{LoS}} + \sqrt{\frac{1}{1 + \kappa_j}} \mathbf{h}^{\text{NLoS}} \right), \quad (9)$$

em que  $j \in \{G, \text{St}, \text{Sr}, \text{Br}, \text{Bt}\}$ , ou seja,  $d_j$  denota a distância entre os elementos da rede. Vale ressaltar que todos os vetores/matrizes de canal ( $\mathbf{G}$ ,  $\mathbf{h}_r$ ,  $\mathbf{h}_t$  e  $\mathbf{h}_D$ ) são gerados de acordo com (9). Além disso,  $C_0$  é a perda de percurso na distância de referência  $d_0$ ,  $\alpha_j$  é o expoente de perda de percurso dos links do canal,  $\mathbf{h}^{\text{LoS}}$  denotam os componentes LoS do canal,  $\mathbf{h}^{\text{NLoS}}$  denota o desvanecimento de Rayleigh e  $\kappa_j$  é fator Rice.

Os resultados apresentados nesta seção, caso não especificado, consideram os seguintes parâmetros de simulação:  $K = 2$ ,  $N = 10$ ,  $M = 60$ ,  $\kappa_G = 2$ ,  $\kappa_d = 2,8$ ,  $\kappa_{Br} = 2$ ,  $\kappa_{Bt} = 2$ ,  $\alpha = \alpha_G = \alpha_d = \alpha_{Bt} = \alpha_{Br} = 2,8$ ,  $\gamma_k = 5$  bps/Hz,  $d_0 = 1$  m,  $C_0 = -30$  dBm,  $\sigma^2 = -80$  dBm,  $d_G = 70$  m,  $d_v = 2$  m,  $d_t = 20$  m e  $d_r = 50$  m.

Além disso, os resultados obtidos pela solução proposta descrita na Seção III, *PSO - STAR-RIS (RSMA)*, foram comparados com os seguintes *benchmarks*: (i) *PSO - STAR-RIS (NOMA/OMA)*, no qual considera-se as técnicas NOMA e OMA, respectivamente. Mais especificamente, para NOMA é realizada otimização do *beamforming* na BS, controle dos elementos da STAR-RIS e alocação de potência. Para OMA, considera-se apenas a otimização da alocação de recursos para cada usuário; (ii) *Sem STAR-RIS (RSMA)*, no qual considera-se um cenário sem STAR-RIS onde o *beamforming* na BS é projetado considerando conhecimento perfeito do CSI na BS e alocação de taxa ótima para os usuários.

##### A. Análise da Influência de $M$ e $N$

Para ilustrar o impacto do número de elementos na STAR-RIS, a Figura 2 apresenta a taxa total para diferentes valores de  $M$ . A partir dos resultados, pode-se verificar que o uso de RSMA aumenta a taxa total para todos os valores de  $M$ . Porém, também pode-se avaliar que para  $M$  alto, o desempenho da abordagem OMA aumenta consideravelmente quando comparado as abordagens RSMA e NOMA, isso pode ser explicado devido ao fato de que, quando  $M$  aumenta, a complexidade do problema de otimização em (6) aumenta e

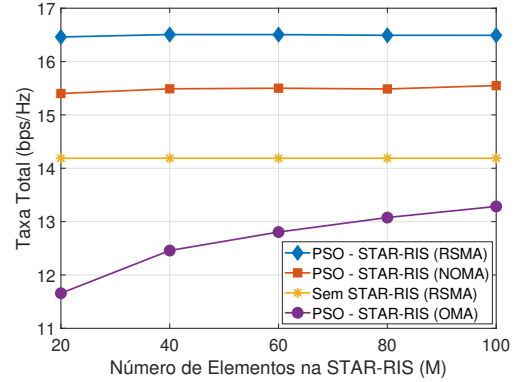


Fig. 2: Análise da Taxa total vs  $M$ .

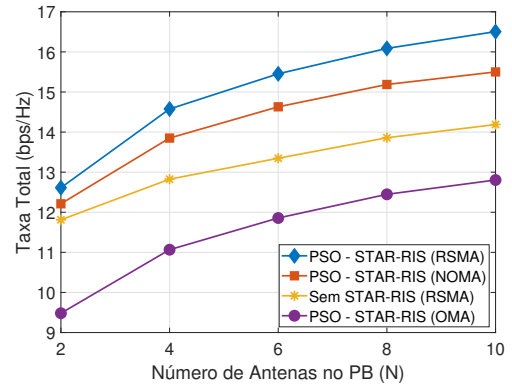


Fig. 3: Análise da Taxa total vs  $N$ .

o desempenho do PSO diminui, resultando em um ganho de desempenho menor. Além disso, a combinação dos ganhos de desempenho da STAR-RIS em conjunto com a otimização da alocação de recursos permitem um maior ganho de desempenho para a abordagem OMA. Por fim, verifica-se que “PSO - STAR-RIS (RSMA)” pode alcançar um desempenho consideravelmente superior ao obtido com a solução “Sem STAR-RIS (RSMA)” mesmo sem considerar qualquer estimativa explícita de CSI.

Ademais, a Figura 3 apresenta a análise da taxa total para diferentes números de antenas na BS ( $N$ ). A partir dos resultados obtidos pode-se observar que aumentar  $N$  aumenta a taxa total à medida que o ganho de *beamforming* aumenta. Além disso, pode-se notar também que a abordagem RSMA apresenta um desempenho superior ao NOMA e OMA, o que demonstra a importância de considerar a técnica RSMA para alcançar uma maior taxa de dados nas futuras redes de comunicações sem fio. Além disso, avaliando a Figura 3, pode-se concluir que a implantação da STAR-RIS é essencial para garantir uma maior taxa de dados do sistema.

##### B. Análise da Influência de $d_G$

A Figura 4 ilustra a taxa total para diferentes valores de  $d_G$ . Nesta análise, quando  $d_G$  é reduzido, consequentemente,  $d_r$  diminui e  $d_t$  aumenta, ou seja, a STAR-RIS está mais próxima da BS e do UE<sub>r</sub> e mais distante do UE<sub>t</sub>. Portanto, através da Figura 4, pode-se observar que quando o RSMA é considerado, o desempenho da solução proposta “PSO - STAR-RIS

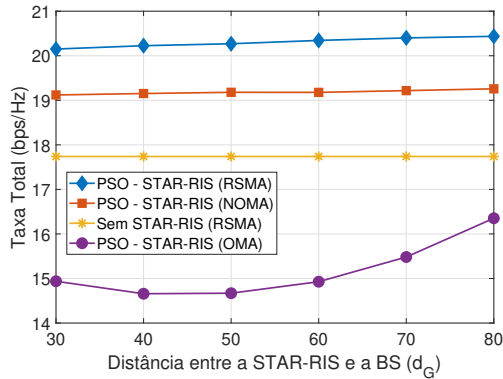
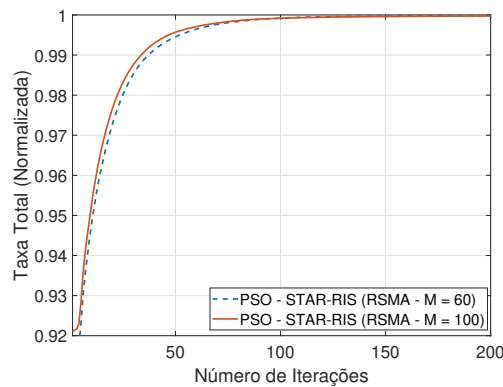

 Fig. 4: Análise da Taxa total vs  $d_G$ .


Fig. 5: Análise da sobrecarga de treinamento.

(RSMA)” é quase constante, pois a otimização da alocação de taxa pode suavizar o efeito de distância. Entretanto, isso não é totalmente verdade quando se considera a técnica OMA, como pode ser visto na Figura 4. Neste caso, a posição da STAR-RIS em relação ao  $UE_r$  e  $UE_t$  influencia o desempenho do sistema. Isto demonstra que, diferentemente do RSMA, quando são consideradas técnicas OMA, é necessário otimizar a posição da STAR-RIS para maximizar o desempenho do sistema.

### C. Análise da Sobrecarga de Treinamento

Para finalizar, como propomos projetar o *beamforming* na BS e na STAR-RIS sem aquisição explícita do CSI, é necessário considerar a quantidade de *feedback* do usuário, que é dado por  $N_{it}L$ . É importante que a quantidade de *feedback* não seja maior que o número de pilotos que seriam necessários para estimar o canal explicitamente, isto é,  $N_{it}L < (2MN + 2)$  [12]. Portanto, para comprovar a eficiência do método proposto, a Figura 5 ilustra a convergência da solução proposta para  $N = 10$  e  $M \in \{100, 60\}$ . A partir dos resultados obtidos é possível observar que a solução proposta atinge um desempenho razoável com uma quantidade de *feedback* do usuário menor do que o número de pilotos necessários para estimar o canal, mais especificamente,  $N_{it}L \sim 1000$  e  $(2MN + 2) = 1202$  para  $M = 60$ , e  $N_{it}L \sim 1000$  e  $(2MN + 2) = 2002$  para  $M = 100$ .

## V. CONCLUSÕES

Neste trabalho foi proposto um método baseado em PSO para maximizar a taxa total do sistema, otimizando con-

juntamente o vetor de *beamforming* na BS, os coeficientes de transmissão e reflexão dos elementos da STAR-RIS e a alocação de taxa para os usuários. Através dos resultados obtidos verificou-se que a solução proposta atinge um desempenho razoável sem a necessidade de estimativa explícita de CSI, reduzindo custos e consumo de energia. Como trabalhos futuros, pretendemos estender o cenário proposto considerando um número maior de usuários, possivelmente com múltiplas antenas, bem como investigar o impacto da implantação da STAR-RIS considerando diferentes modos de operação.

## AGRADECIMENTOS

Este trabalho foi parcialmente financiado pelo projeto XGM-AFCCT-2024-4-1-1, apoiado pelo xGMobile-EMBRAPII-Inatel Centro de Competências em Redes 5G e 6G, com recursos do programa PPI IoT/Manufatura 4.0 do MCTI número 052/2023, assinado com a EMBRAPII. Adicionalmente, este trabalho foi parcialmente financiado pela RNP, com recursos do MCTIC, nº 01245.020548/2021-07, no âmbito do projeto Brasil 6G do Centro de Referência em Radiocomunicações (CRR) do Inatel, pela FAPEMIG no âmbito dos projetos nº APQ-05305-23, APQ-04523-23 e RED-00194-23, e pelo CNPq (402378/2021-0, 305021/2021-4).

## REFERÊNCIAS

- [1] Q. Wu, S. Zhang, B. Zheng, C. You, and R. Zhang, “Intelligent Reflecting Surface-Aided Wireless Communications: A Tutorial,” *IEEE Transactions on Communications*, vol. 69, no. 5, pp. 3313–3351, 2021.
- [2] Y. Liu, X. Mu, J. Xu, R. Schober, Y. Hao, H. V. Poor, and L. Hanzo, “STAR: Simultaneous Transmission and Reflection for 360° Coverage by Intelligent Surfaces,” *IEEE Wireless Communications*, vol. 28, no. 6, pp. 102–109, 2021.
- [3] B. Rimoldi and R. Urbanke, “A rate-splitting approach to the gaussian multiple-access channel,” *IEEE Transactions on Information Theory*, vol. 42, no. 2, pp. 364–375, 1996.
- [4] B. Clerckx, H. Joudeh, C. Hao, M. Dai, and B. Rassouli, “Rate splitting for mimo wireless networks: a promising phy-layer strategy for 5g evolution,” *IEEE Communications Magazine*, vol. 54, no. 5, pp. 98–105, 2016.
- [5] C. Meng, K. Xiong, W. Chen, B. Gao, P. Fan, and K. B. Letaief, “Sum-Rate Maximization in STAR-RIS-Assisted RSMA Networks: A PPO-Based Algorithm,” *IEEE Internet of Things Journal*, vol. 11, no. 4, pp. 5667–5680, 2024.
- [6] S. Dhok and P. K. Sharma, “Rate-Splitting Multiple Access With STAR RIS Over Spatially-Correlated Channels,” *IEEE Transactions on Communications*, vol. 70, no. 10, pp. 6410–6424, 2022.
- [7] M. Katwe, K. Singh, B. Clerckx, and C.-P. Li, “Improved Spectral Efficiency in STAR-RIS Aided Uplink Communication Using Rate Splitting Multiple Access,” *IEEE Transactions on Wireless Communications*, vol. 22, no. 8, pp. 5365–5382, 2023.
- [8] F. Karim, S. K. Singh, K. Singh, S. Prakriya, and C.-P. Li, “Performance Analysis for RSMA-Empowered STAR-RIS-Aided Downlink Communications,” in *2023 IEEE 34th Annual International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC)*, 2023, pp. 1–6.
- [9] M. Amiri, E. Vaezpour, S. Javadi, M. R. Mili, H. Yanikomeroglu, and M. Bennis, “Resource Allocation in STAR-RIS-Aided SWIPT with RSMA via Meta-Learning,” 2024.
- [10] Y. Liu, X. Mu, J. Xu, R. Schober, Y. Hao, H. V. Poor, and L. Hanzo, “STAR: Simultaneous Transmission and Reflection for 360° Coverage by Intelligent Surfaces,” *IEEE Wireless Communications*, vol. 28, no. 6, pp. 102–109, 2021.
- [11] J. Kennedy and R. Eberhart, “Particle swarm optimization,” in *Proceedings of ICNN’95 - International Conference on Neural Networks*, vol. 4, Nov 1995, pp. 1942–1948 vol.4.
- [12] C. Wu, C. You, Y. Liu, X. Gu, and Y. Cai, “Channel Estimation for STAR-RIS-Aided Wireless Communication,” *IEEE Communications Letters*, vol. 26, no. 3, pp. 652–656, 2022.