

Otimização de eficiência energética em redes RSMA 6G utilizando meta-heurística

Reyso C. Teixeira, Matheus Pantoja, Albert dos Santos, Ermínio Augusto Ramos da Paixão, Diego Cardoso.

Resumo— Diante da evolução para o 6G, a eficiência energética das redes móveis torna-se um elemento essencial devido ao crescente aumento da demanda por dados. Este estudo aborda o problema da alocação eficiente de potência em redes RSMA (Rate Splitting Multiple Access), propondo uma solução baseada na meta-heurística PSO (Particle Swarm Optimization). A proposta visa otimizar a alocação de potência *downlink* aos usuários da rede, resultando em melhorias significativas na eficiência energética e redução do número de bloqueios na rede. Os resultados demonstram a eficácia da combinação RSMA e PSO para redes 6G, aprimorando o aumento da eficiência e sustentabilidade das comunicações móveis.

Palavras-Chave— Rate Splitting Multiple Access, Eficiência Energética, Alocação de potência, Otimização por Enxame de Partículas.

Abstract— Given the evolution towards 6G, energy efficiency in mobile networks becomes an essential element due to the increasing demand for data. This study addresses the problem of efficient power allocation in RSMA (Rate Splitting Multiple Access) networks, proposing a solution based on the PSO (Particle Swarm Optimization) metaheuristic. The proposed method aims to optimize downlink power allocation to network users, resulting in significant improvements in energy efficiency and reduction in network outages. The results demonstrate the effectiveness of combining RSMA and PSO for 6G networks, enhancing the efficiency and sustainability of mobile communications.

Keywords— Rate Splitting Multiple Access, Energy Efficiency, Power allocation, Particle Swarm Optimization.

I. INTRODUÇÃO

A transição para a rede 6G representa um avanço significativo na conectividade. O uso de dados móveis deve aumentar de 21 GB em 2023 para 56 GB em 2029 [5], exigindo redes mais eficientes energeticamente. Para a sustentabilidade da infraestrutura de comunicação, é crucial projetar redes com estratégias de otimização de energia, tecnologias de transmissão eficientes e algoritmos inteligentes que maximizem a transmissão de informações com o menor consumo de energia.

A natureza das transmissões nas redes móveis de próxima geração exigem técnicas que garantam o uso eficiente dos recursos. Os modelos de acesso múltiplo permitem que os usuários compartilhem recursos de forma organizada. Nesse contexto, o RSMA (Rate Splitting Multiple Access) se destaca como uma solução promissora para otimizar a Eficiência Espectral (SE) e energética em sistemas de comunicação sem fio [4]. O RSMA surge como uma solução eficaz para lidar com os desafios de conectividade massiva e alta confiabilidade

Reyso C. Teixeira, Matheus Pantoja, Albert dos Santos, Ermínio Augusto Ramos da Paixão, Diego Cardoso, Instituto de Tecnologia (ITEC), Universidade Federal do Pará (UFPA), Belém, PA, Brasil, email: [reyso.teixeira, matheus.pantoja, albert.santos, erminio.paixao]@itec.ufpa.br; diego@ufpa.br.

esperados no 6G, dividindo as mensagens dos usuários em partes privadas e comuns. Isso resulta em maior taxa ergódica e menor número de SICs (Successive Interference Cancellation), reduzindo a complexidade [3].

A alocação de potência é um desafio de significativa complexidade, uma vez que demanda a determinação precisa da quantidade de potência destinada a cada usuário para assegurar uma comunicação eficaz. Este problema é caracterizado como um desafio de otimização combinatória de alta complexidade, frequentemente classificado como NP-difícil [15]. Em contextos dinâmicos, a busca pela solução ótima pode demandar um tempo computacional proibitivo, tornando-a impraticável. Portanto, é necessário adotar abordagens que ofereçam soluções aproximadas dentro de intervalos de tempo viáveis, equilibrando a eficácia e a eficiência computacional.

Assim, este trabalho consiste em otimizar a performance de redes RSMA 6G visando a melhor alocação de potência de *downlink* aos usuários conectados, considerando aspectos de Eficiência Energética (EE) de forma a atender a maior quantidade de usuários possível. Para tal abordagem, foi utilizado uma metaheurística tradicional e bastante referenciada na literatura por sua menor complexidade e rápida convergência, conhecido como PSO (Particle Swarm Optimization). A aplicação de técnicas de otimização bioinspiradas, como o PSO, pode promover significativos ganhos em termos de EE e desempenho geral da rede, ajustando dinamicamente a alocação de recursos para atender às demandas variáveis do ambiente 6G.

II. TRABALHOS CORRELATOS

No âmbito da EE e técnicas de acesso múltiplo em sistemas de comunicação sem fio, pesquisas recentes têm focado na EE em redes RSMA. [8] destacam as limitações dos métodos de acesso Space-Division Multiple Access (SDMA) e Non-Orthogonal Multiple Access (NOMA) em comparação ao RSMA, abordando um sistema multi-antena e utilizando o método de otimização Successive Convex Approximation (SCA) para maximizar a EE e a SE por meio de transmissões direcionais. O estudo conclui que o RSMA é mais eficiente energeticamente em vários cenários de implantação e condições de tráfego. [16] investigam o *trade-off* entre SE e EE em um sistema de comunicação *downlink* multi-antena e multiusuário, também empregando o algoritmo SCA. Os resultados mostram que o RSMA equilibra efetivamente SE e EE, oferecendo desempenho superior ou igual ao SDMA e NOMA. Esses estudos revelam que o RSMA possui vantagens significativas em EE e SE comparado às técnicas tradicionais

de acesso múltiplo. [8] demonstram a EE do RSMA em diferentes condições de canal, enquanto [16] evidenciam o equilíbrio eficaz entre SE e EE proporcionado pelo RSMA, tornando-o uma técnica promissora para a nova geração de sistemas de comunicação sem fio.

Em [13] é abordado a alocação de potência em sistemas MIMO, essencial para aprimorar a EE e a qualidade do serviço. Investigando a transmissão *downlink* em uma rede celular homogênea com canais interferentes (IMAC), os autores comparam nove algoritmos metaheurísticos, como a Colônia de Abelhas Artificiais (ABC) e o PSO. As metaheurísticas mostraram-se eficazes na alocação de potência, superando técnicas convencionais como programação convexa e métodos de gradiente na maximização da taxa de sum-rate SINR, com o PSO alcançou uma melhoria de 10% a 15% na taxa de sum-rate SINR e convergiu para soluções ótimas em aproximadamente 50 iterações, comparado a até 100 iterações necessárias por métodos tradicionais.

Desta forma, percebe-se que a estratégia do RSMA para lidar com a interferência destaca-se entre as técnicas de acesso múltiplo, assim como o uso de meta-heurísticas é promissor no problema de alocação de potência, motivo pelo qual ambos foram objeto de pesquisa neste trabalho.

III. MATERIAIS E MÉTODOS

Nesta seção serão apresentados o cenário adotado bem como são delineadas as suposições e considerações formuladas durante a criação do modelo analítico.

A. Modelo do Sistema

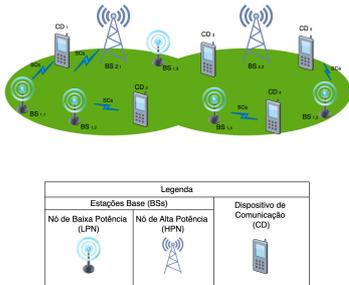


Fig. 1. Rede sem fio considerada com duas camadas de BSs.

O cenário apresentado na figura [1], consiste em uma rede RSMA 6G com M Estação Base (BS) de única antena e K camadas, com $M = [BS_{1,1}, BS_{1,2}, BS_{2,3}, BS_{2,4}, \dots, BS_{K,M}]$. As camadas podem ser do tipo LPN (Low-Power Nodes) ou HPN (High-Power Nodes) sendo $K = [1,2]$ o número de camadas presentes. Cada camada possui uma potência de transmissão máxima p_k^{Max} . A largura de banda W do sistema é dividida igualmente entre as S subportadoras (SC). Ou seja, a largura de banda B_s de cada SC corresponde a $B_s = \frac{W}{S}$. Além disso, é considerado que há U CDs (Communication Devices), com uma única antena, dispostos aleatoriamente no cenário.

De acordo com [12], no RSMA as mensagens do transmissor são divididas em duas categorias: mensagens comuns

e mensagens privadas. Na parte comum, as mensagens destinadas a todos os usuários são agrupadas em um fluxo comum, decodificável por todos os usuários. Ao decodificar as mensagens comuns, as mensagens privadas de todos os usuários são tratadas como ruído. Na parte privada, cada usuário pode decodificar e recuperar apenas suas próprias mensagens privadas. Antes da decodificação das mensagens privadas, a SIC é aplicada para eliminar as mensagens comuns. Posteriormente, cada usuário decodifica suas mensagens privadas individuais, tratando as mensagens privadas dos outros usuários como ruído. Assim, a estratégia do RSMA para lidar com a interferência envolve a decodificação parcial da interferência, enquanto o restante é considerado ruído.

Para um par de usuários em um sistema RSMA, a Relação sinal-ruído (SINR) de cada usuário é calculada considerando a potência de transmissão, o ganho de canal, a potência do ruído e o cancelamento de interferência gerado pela SIC. A SINR (γ) da parte comum da mensagem do CD u (sobrescrito c) e da parte privada (sobrescrito p) é calculada de acordo com as Equações 1 e 2 [9]:

$$\gamma_{m,u,s}^{k,c} = \frac{p_{m,u,s}^{k,c} G_{m,u,s}^{k,c}}{\beta I_{INI}^{k,m,u,s} + I_{ICI}^{k,m,u,s} + \alpha^2} \quad (1)$$

$$\gamma_{m,u,s}^{k,p} = \frac{p_{m,u,s}^{k,p} G_{m,u,s}^{k,p}}{I_{INI}^{k,m,u,s} + I_{ICI}^{k,m,u,s} + \alpha^2} \quad (2)$$

sendo que $p_{m,u,s}^{k,c}$ representa a potência de transmissão da mensagem comum do CD u , alocado na BS m com camada k , subportadora s e ganho $G_{m,u,s}^{k,h}$. Além disso, $I_{INI}^{k,m,u,s}$ representa a interferência intra-cluster (INI), $I_{ICI}^{k,m,u,s}$ é a interferência inter-cluster, α^2 é a potência do ruído e β é o fator para simular a SIC e varia no intervalo de $[0,1]$ sendo que $\beta = 0$ é chamado de SIC perfeito e implica em cancelar toda a interferência INI.

A $I_{INI}^{k,m,u,s}$ é a interferência recebida de outros usuários dentro do mesmo cluster, calculada de acordo com a Equação 3:

$$I_{INI}^{k,m,u,s} = \sum_{u'=1, u' \neq u}^U p_{m,u',s}^k G_{m,u',s}^k \quad (3)$$

Essa soma envolve as potências de transmissão de todos os outros usuários no cluster ($p_{m,u',s}^k$), exceto o usuário em análise (u), multiplicadas pelos seus respectivos ganhos de canal até o usuário em análise ($G_{m,u',s}^k$). Da mesma forma, a interferência inter-cluster ($I_{ICI}^{k,m,u,s}$) inclui a interferência de todos os usuários em outros clusters, e é dada pela Equação 4:

$$I_{ICI}^{k,m,u,s} = \sum_{k=1}^K \sum_{m'=1, m' \neq m}^M \sum_{u'=1, u' \neq u}^U p_{m',u'}^k G_{m',u}^k \quad (4)$$

Aqui, o cálculo envolve a soma das potências de transmissão ($p_{m',u'}^k$) de usuários em diferentes clusters (m') e diferentes subportadoras, mas ainda impactando o usuário atual (u), e multiplicadas pelos ganhos de canal desses usuários em relação ao usuário atual ($G_{m',u}^k$). Importante destacar que $I_{ICI}^{k,m,u,s}$ gerada por usuários diferentes do usuário u são oriundas de BS diferentes de m .

A capacidade do canal para um usuário, seja ele com maior ou menor ganho de canal dentro de um cluster, é determinada pela Equação 5 [10]:

$$R_k = B_s \log_2(1 + \gamma_{total}) \quad (5)$$

Onde R_k representa a taxa de transmissão de dados para o CD, refletindo a taxa máxima de transmissão de dados sob as condições atuais do canal, B_s é a largura de banda do subcanal, indicando a quantidade de espectro disponível para a transmissão, e a γ_{total} é a relação sinal-ruído mais interferência calculada nas Equações 1 e 2 e que incorpora a qualidade do sinal diante do ruído e da interferência no canal.

B. Modelo Proposto

A Figura 2 apresenta o fluxograma do PSO adotado neste trabalho, o qual será descrito na subseção C. Abaixo, são explicadas as duas variáveis que a função objetivo busca otimizar, são elas EE e Probabilidade de bloqueio (OP).

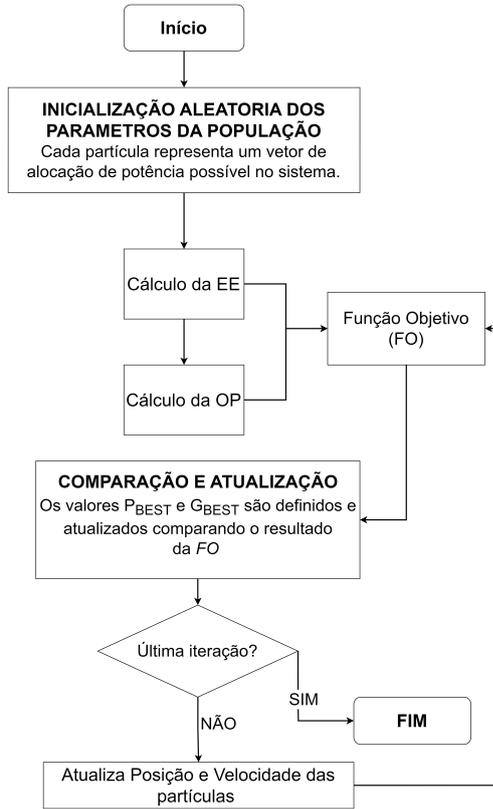


Fig. 2. Fluxograma geral do PSO

1) Eficiência Energética Total do Sistema

A EE é uma medida da quantidade de dados transmitidos por unidade de energia consumida. Portanto, a EE total do sistema é calculada considerando a taxa de dados transmitida e a potência consumida.

A EE total do sistema é dada pela equação:

$$EE = \frac{\sum_{k=1}^K R_k}{P_c + \sum_{k=1}^K p_k + p_{k,c}} \quad (6)$$

sendo que R_k , é a taxa de transmissão do usuário k , p_k é a potência atribuída à parte privada da mensagem do usuário k , $p_{k,c}$ é a potência atribuída à parte comum da mensagem do usuário k e P_c é o consumo fixo de energia para operar a BS.

2) Probabilidade de Bloqueio

A OP quantifica a proporção de CDs que não atingem a taxa de dados mínima θ_{min} . É considerado bloqueado se sua taxa de dados $R_{m,u,s}^k$ for menor que θ_{min} . A OP total é calculada pela fórmula:

$$OP_{total} = \frac{\sum_{u=1}^U \rho_u}{U} \quad (7)$$

onde ρ_u é 1 se o CD u está bloqueado e 0 caso contrário, e U é o número total de CDs.

3) Problema de Otimização

Com base nas equações anteriores apresentadas, é possível formular matematicamente o problema de maximização de EE total e mitigação da OP em uma rede RSMA 6G como uma otimização com dois objetivos:

$$\max_{p_{m,s,u}^k} EE \quad (8)$$

$$\min_{p_{m,s,u}^k} OP \quad (9)$$

Sujeito a :

$$\sum_{u=1}^U \sum_{s=1}^S p_{m,s,u}^k \leq p_k^{max}, \forall k, m \quad (10)$$

$$p_{m,u,s}^k > 0, \forall k, m, u, s \quad (11)$$

Sendo que (10) representa a restrição de potência total da BS e (11) indica que a potência atribuída aos usuários deve ser positiva.

C. Etapas de Otimização

O PSO é um algoritmo de otimização baseado em população motivado pelo comportamento coletivo inteligente de alguns animais, como bandos de pássaros ou cardumes de peixes [14]. Esta meta-heurística é bastante referenciada na literatura em problemas de otimização devido a sua simplicidade de implementação em comparação com outros algoritmos bioinspirados, pois requer menos parâmetros de ajuste e utiliza operações aritméticas básicas para atualizar as posições das partículas. Além disso, tende a convergir mais rapidamente, aproveitando a cooperação entre partículas para explorar eficazmente o espaço de busca.

O algoritmo inicia com uma população de soluções candidatas em posições aleatórias, cada partícula representando uma possível alocação de potência para os usuários da rede. A Função Objetivo (FO) do PSO considera o cálculo da EE e da OP. O objetivo é maximizar a EE enquanto minimiza a OP, considerando a alocação de potência e as taxas de transmissão entre os dispositivos. Esta função é então avaliada para cada partícula na população, utilizando a abordagem da soma ponderada, um método clássico que converte problemas multiobjetivos em um problema mono-objetivo ao atribuir um peso a cada FO normalizada e somando-os [16]. A Equação 12 representa a FO, implementada de modo que a OP tem maior

prioridade que a EE. As normalizações das variáveis $NormEE$ e $NormOP$ são necessárias para garantir que elas tenham o mesmo intervalo de valores, permitindo uma combinação na FO.

$$FO = 0.2 \times NormEE + 0.8 \times NormOP \quad (12)$$

Durante as iterações do algoritmo, as partículas são atualizadas com base na avaliação da FO. Então é gerado um vetor que representa os níveis de potência atribuídos a cada CD da rede. Cada CD recebe apenas uma SC. Esse vetor, contendo todos os níveis de potência do sistema, representa uma partícula do PSO. Ao passo que o valor da FO é computado, o PSO realiza a comparação deste valor com os valores obtidos das demais iterações, P_{best} (melhor solução individual) e G_{best} (melhor solução global) encontrados até o momento. Esse processo de comparação e atualização se estende ao longo das iterações definidas para o algoritmo. Ao realizar o número máximo de iterações, o algoritmo encerra sua busca e a melhor solução encontrada até então é apresentada como resultado final.

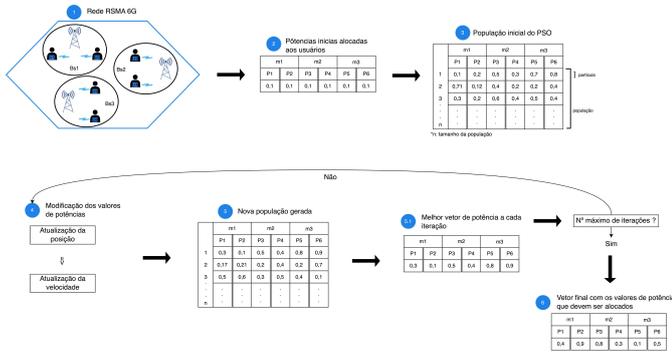


Fig. 3. Etapas de otimização do PSO utilizado.

A Figura 3 exemplifica o processo da otimização da alocação de potência dos usuários utilizando o PSO aplicado ao modelo de rede proposto. A etapa 1 ilustra a rede RSMA 6G que está sendo analisada com a disposição das BSs e dos usuários. Na etapa 2, são alocadas potências iniciais para os usuários conectados, nota-se que estes valores são iguais para todos os usuários.

Em seguida, na etapa 3 inicia-se a execução do PSO com a formação aleatória de uma população inicial. Cada partícula da população representa uma solução candidata contendo um vetor com as potências que devem ser alocadas para cada usuário. A população possui tamanho igual a n , sendo n o número máximo de partículas.

Na etapa 4 ocorrem os processos do PSO chamados de atualização da posição e velocidade das partículas, que consiste em alterar os valores de potência para gerar novas partículas. Com isso, é gerada uma nova população, como ilustrado na etapa 5. O PSO possui um número máximo de iterações sendo que em cada iteração uma nova população é gerada.

A cada iteração, é realizada uma avaliação para identificar a partícula que possui o vetor de potências resultando na maior EE e na menor OP, sendo esta considerada a melhor da iteração corrente (etapa 5.1). Posteriormente, ao considerar todas as iterações, a partícula que apresentou o vetor de

potências que resultou na maior FO global é selecionada como a solução final. Esses valores de potência são então alocados aos respectivos usuários (etapa 6).

Desenvolvido utilizando MATLAB, o PSO possui parâmetros que configuram a forma como a busca pelas soluções foi realizada. Estes parâmetros do PSO estão dispostos na Tabela [1]

TABELA I
PARÂMETROS DE SIMULAÇÃO DO PSO.

População (n)	30
Coefficiente de inércia (w)	1
Constante de aceleração cognitiva (c1)	1.4962 [11]
Constante de aceleração social (c2)	1.4962 [11]
Coefficiente de amortecimento da inércia (wdamp)	0.99
Iterações	70

IV. RESULTADOS

Foi avaliada a eficiência de alocação de potência de transmissão do PSO em comparação com o ERPA (Equal RB Power Allocation) [2], método que aloca potências iguais para os CDs. Foram implementados cenários com diferentes quantidades de CDs dispostos aleatoriamente em um área de 1 km². As BSs, do tipo HPN e LPN, foram posicionadas de acordo com a Figura 4.

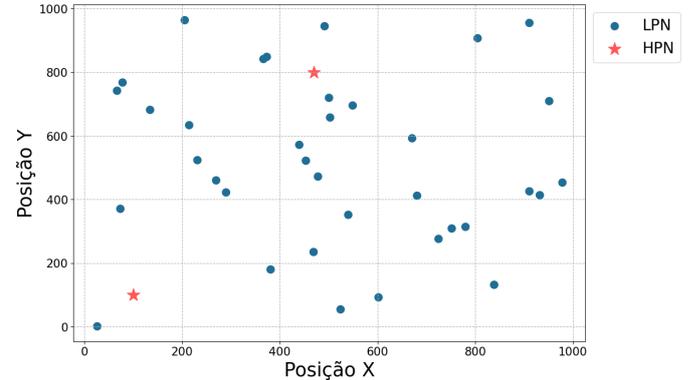


Fig. 4. Disposição das LPN e HPN.

Em relação à configuração da rede, o modelo de perda de caminho, que determina a atenuação do sinal à medida que se propaga pelo ambiente, foi considerado como $34.53 + 35 \log_{10}(d)$ (d é a distância entre o CD e a BS a qual ele está conectado) [6]. A potência do ruído é $\sigma^2 = -20dBm$ [16]. A tabela II apresenta os demais parâmetros do cenário.

TABELA II
PARÂMETROS DO CENÁRIO

Parâmetros	Valor
Largura de banda do sistema (W) [1]	3 GHz
Número de HPNs	2
Número de LPNs	16
Potência de transmissão total LPN/HPN (P_{max})	1 W / 10 W
Número de CDs (U)	100-500
Taxa mínima dos CDs (θ_{min})	1.2 Mbps
Consumo de potência de circuito (P_c) [7]	0.001 W

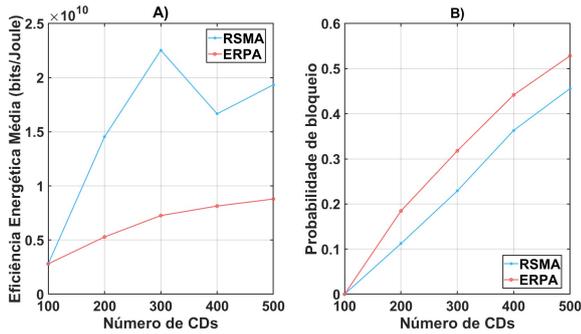


Fig. 5. Avaliação de desempenho dos modelos quando aumenta-se o número de CDs. (A) EE média, (B) OP média.

A Figura 5 apresenta uma comparação de desempenho dos modelos PSO e ERPA à medida que o número de CDs aumenta. Especificamente, a Figura 5.A) mostra EE média do PSO, medida em bits por joules, enquanto a Figura 5.B) exibe a porcentagem de OP média.

Diante da Figura 5.A, o maior ganho em EE foi observado no cenário com 300 CDs, onde o modelo PSO obteve um aumento significativo de 210% em relação ao método ERPA. Este ganho demonstra a superioridade de técnicas de alocações de potência mais eficientes. Isso proporciona uma redução do consumo de energia, sendo crucial para sustentabilidade das redes 6G. Além disso, a EE aprimorada contribui para a redução da pegada de carbono das operadoras de rede, alinhando-se com metas globais de sustentabilidade.

Na Figura 5.B), é observado que para um cenário com 100 CDs, ambos os modelos conseguem satisfazer a taxa mínima exigida pelos CDs. Esse resultado é atribuído à pequena quantidade de CDs em relação à disponibilidade de recursos na rede. Entretanto, ao aumentar o número de CDs para 200, o PSO demonstrou a maior redução da OP, aproximadamente 39% menor em comparação ao ERPA. Essa tendência foi mantida para 300 e 400 CDs, onde o PSO resultou em reduções de OP de 27.9% e 17.7%, respectivamente, em relação ao ERPA.

A diminuição da OP implica que menos dispositivos enfrentarão falhas de conexão, garantindo uma experiência de usuário mais estável e confiável. As operadoras de rede, ao implementarem o PSO para alocação de recursos, podem reduzir os custos operacionais associados ao consumo de energia e gerenciar um número maior de dispositivos sem comprometer a qualidade do serviço. Os usuários finais também se beneficiam de conexões mais estáveis, ou seja, com menor risco de desconexão e melhor qualidade de serviço, especialmente em ambientes densamente povoados.

V. CONCLUSÃO

Este estudo apresentou uma análise da aplicação do algoritmo PSO para a otimização da EE em redes RSMA 6G. Os resultados demonstram que o PSO supera significativamente o método ERPA em termos de EE e OP. O maior ganho observado foi de 210% na EE em um cenário com 300 CDs, evidenciando a capacidade do PSO de melhorar a alocação de potência e, consequentemente, o desempenho da rede.

Os benefícios de uma maior EE são significativos. Para as operadoras de rede, a implementação do PSO para alocação de recursos pode resultar em uma redução substancial nos custos operacionais devido ao menor consumo de energia. Além disso, a capacidade de gerenciar um número maior de dispositivos sem comprometer a qualidade do serviço é uma vantagem competitiva importante. Para os usuários finais, uma maior EE se traduz em conexões com menor risco de desconexão e melhor qualidade de serviço.

Em trabalhos futuros, pretende-se explorar um agrupamento de algoritmos de otimização para obter soluções ainda mais aprimoradas e compará-las com outros métodos mais complexos, tendo em vista que o ERPA é uma abordagem trivial de alocação de potência.

AGRADECIMENTOS

Este trabalho foi parcialmente apoiado pela Fapespa e ISACI.

REFERÊNCIAS

- [1] AKHTAR, M. W., HASSAN, S. A., GHAFFAR, R., JUNG, H., GARG, S., AND HOSSAIN, M. S. The shift to 6g communications: Vision and requirements. *Human-centric Computing and Information Sciences* 10 (2020), 1–27.
- [2] AL-ABBASI, Z. Q., AND SO, D. K. Resource allocation in non-orthogonal and hybrid multiple access system with proportional rate constraint. *IEEE Transactions on Wireless Communications* 16, 10 (2017), 6309–6320.
- [3] CLERCKX, B., MAO, Y., SCHÖBER, R., JORSWIECK, E., LOVE, D. J., YUAN, J., HANZO, L., LI, G. Y., LARSSON, E. G., AND CAIRE, G. Is noma efficient in multi-antenna networks? a critical look at next generation multiple access techniques, 2021.
- [4] DIZDAR, O., MAO, Y., HAN, W., AND CLERCKX, B. *Rate-Splitting Multiple Access: A New Frontier for the PHY Layer of 6G*. 2020.
- [5] ERICSSON. Ericsson mobility report november 2023. Technical report, Ericsson, Nov. 2023.
- [6] HASHEMI, R., BEYRANVAND, H., MILI, M. R., KHALILI, A., TABASSUM, H., AND NG, D. W. K. Energy efficiency maximization in the uplink delta-oma networks. *IEEE Transactions on Vehicular Technology* 70, 9 (2021), 9566–9571.
- [7] LIU, Z., HOU, G., YUAN, Y., CHAN, K. Y., MA, K., AND GUAN, X. Robust resource allocation in two-tier noma heterogeneous networks toward 5g. *Computer Networks* 176 (2020), 107299.
- [8] MAO, Y., CLERCKX, B., AND LI, V. O. Energy efficiency of rate-splitting multiple access, and performance benefits over sdma and noma. In *2018 15th International Symposium on Wireless Communication Systems (ISWCS)* (2018), IEEE, pp. 1–5.
- [9] MOUNI, N. S., KUMAR, A., AND UPADHYAY, P. K. Adaptive user pairing for noma systems with imperfect sic. *IEEE Wireless Communications Letters* 10, 7 (2021), 1547–1551.
- [10] SHANNON, C. E. A mathematical theory of communication. *The Bell system technical journal* 27, 3 (1948), 379–423.
- [11] SHAQARIN, T., AND NOACK, B. R. A fast-converging particle swarm optimization through targeted, position-mutated, elitism (psotpm). *International Journal of Computational Intelligence Systems* 16, 1 (2023), 6.
- [12] SHENG, X. Effective capacity of rate-splitting multiple access with channel estimation errors. *Physical Communication* 64 (2024), 102331.
- [13] SUN, Q., WU, H., AND PETROSIAN, O. Optimal power allocation based on metaheuristic algorithms in wireless network. *Mathematics* 10, 18 (2022), 3336.
- [14] WANG, D., TAN, D., AND LIU, L. Particle swarm optimization algorithm: an overview. *Soft Computing* 22, 2 (2018), 387–408.
- [15] ZHANG, Y., KANG, C., MA, T., TENG, Y., AND GUO, D. Power allocation in multi-cell networks using deep reinforcement learning. In *2018 IEEE 88th Vehicular Technology Conference (VTC-Fall)* (2018), IEEE, pp. 1–6.
- [16] ZHOU, G., MAO, Y., AND CLERCKX, B. Rate-splitting multiple access for multi-antenna downlink communication systems: Spectral and energy efficiency tradeoff. *IEEE Transactions on Wireless Communications* 21, 7 (2021), 4816–4828.