

Otimização Max-Min em Redes CF-mMIMO com Antenas Fluidas usando PSO

Antônio L. S. Aguiar e Yuri C. B. Silva

Resumo—Este artigo investiga redes CF-mMIMO com antenas fluidas e arquitetura centrada no usuário. Formulamos a maximização da taxa mínima no *uplink* com otimização conjunta de potências e posicionamento das antenas, resolvida por otimização alternada: bisseção para alocação de potência e PSO para busca contínua. Comparamos a busca exaustiva quantizada com a abordagem usando PSO, demonstrando a superioridade da otimização contínua na eliminação do erro de quantização. Resultados numéricos mostram ganhos expressivos de eficiência espectral e QoS, com benefício adicional do PSO com mais antenas por ponto de acesso.

Palavras-Chave—Antenas fluidas, Cell-Free MIMO massivo, otimização max-min, PSO, controle de potência.

Abstract—This paper investigates CF-mMIMO networks with fluid antennas and a user-centric architecture. We formulate max-min uplink rate optimization with joint power control and antenna port positioning, solved by alternating optimization: bisection for power allocation and PSO for continuous search. We compare quantized exhaustive search with the PSO approach, demonstrating the superiority of continuous optimization in eliminating quantization error. Numerical results show notable spectral-efficiency and QoS gains, with PSO benefits increasing as the number of antennas per access point increases.

Keywords—Fluid antennas, Cell-Free massive MIMO, max-min optimization, PSO, power control.

I. INTRODUÇÃO

As redes de comunicações de Sexta Geração (6G) demandam suporte a aplicações críticas como realidade estendida, sistemas autônomos e sensoriamento ubíquo. Neste contexto, o Sistema de Antenas Fluidas (do inglês, *Fluid Antenna Systems*) (FAS) emergiu como solução promissora ao viabilizar a reconfiguração dinâmica de posicionamento e morfologia de antenas. Em comparação aos sistemas convencionais de posições fixas, o FAS oferece maior diversidade espacial e comunicações com menor interferência, impulsionando tecnologias como antenas móveis e Múltiplas Entradas e Múltiplas Saídas (do inglês, *Multiple Input Multiple Output*) (MIMO) de posição flexível [1], [2], [3].

Nesta abordagem, têm-se antenas com controle flexível de posição com o uso de estruturas fluidas (condutoras ou dielétricas) controladas por *software* que podem alterar sua forma e posição para reconfigurar ganho, padrão de radiação, frequência de operação e outras características. Elas são capazes de explorar a diversidade espacial em um domínio prede-

finido, reconfigurando a localização dos elementos radiantes, resultando em melhorias substanciais de performance, visto que a estrutura pode ser ajustada para mitigar interferências e maximizar a eficiência do sistema [1], [4], [5].

Com isso, este artigo investiga o potencial do FAS para incrementar o desempenho de sistemas MIMO massivo sem células centrado no usuário (do inglês, *Cell-Free massive MIMO*) (CF-mMIMO). Na arquitetura CF-mMIMO, os grandes arranjos de antenas colocalizados típicos de implantações MIMO massivas multicelulares são substituídos por um vasto número de Pontos de Acesso (do inglês, *Access Points*) (APs) distribuídos. Estes APs, equipados com um número limitado de antenas, servem conjuntamente múltiplos usuários no mesmo recurso de tempo-frequência. Consequentemente, cada usuário é atendido por um *cluster* de APs vizinhos, caracterizando a abordagem centrada no usuário (*user-centric*). Extensivamente investigado na última década, o CF-mMIMO consolidou-se como uma tecnologia promissora para redes 6G, destacando-se pela capacidade de fornecer desempenho uniforme aos usuários em comparação ao MIMO massivo celular [6], [7], [4], [8].

Assim como o trabalho em [4], este artigo considera um esquema de otimização para sistemas CF-mMIMO com antenas fluidas baseado em otimização alternada. Entretanto, diferentemente de [4], que quantiza as posições das portas da antena e resolve o posicionamento por Busca Exaustiva (BE), aqui adotamos uma abordagem contínua para o posicionamento utilizando Otimização por Enxame de Partículas (do inglês, *Particle Swarm Optimization*) (PSO). O PSO explora o domínio contínuo das posições das antenas, eliminando o erro de quantização associado ao *grid* fixo e aumentando a capacidade de escapar de ótimos locais em funções objetivo altamente não convexas. Adicionalmente, empregou-se uma estratégia de *Warm Start* (inicialização quente), onde a melhor solução encontrada pelo método discreto é inserida na população inicial do PSO, enquanto o subproblema de controle de potência no *uplink* é resolvido por bisseção dentro da rotina de otimização alternada. Essa combinação, bisseção para potência com o PSO para posicionamento proporciona ganhos expressivos em eficiência espectral e Qualidade de Serviço (do inglês, *Quality of Service*) (QoS) com tempo computacional significativamente menor que uma busca exaustiva sobre um *grid* quantizado.

Este estudo visa, portanto, analisar o desempenho de sistemas CF-mMIMO usando o FAS com a aplicação do PSO, com isso, o restante deste artigo está organizado da seguinte forma: a Seção II detalha o modelo do sistema adotado. Em seguida, a Seção III aborda o processamento do sinal no *uplink*

e define as métricas de desempenho utilizadas. A formulação e a resolução do problema de otimização são apresentadas na Seção IV, seguidas pela análise dos resultados numéricos na Seção V. Por fim, a Seção VI apresenta as conclusões e considerações finais.

II. MODELAGEM DO SISTEMA COM ANTENAS FLUIDAS

Na modelagem do sistema com Antenas Fluidas, adotamos uma abordagem centrada no usuário, conforme [6], na qual se considera que cada usuário é servido por um número limitado de APs, priorizando aqueles que apresentam menor perda de percurso. Desse modo, para a implementação de CF-mMIMO, assumimos a existência de M APs, cada um equipado com N antenas fluidas, que atendem simultaneamente K usuários móveis de antena única no mesmo recurso tempo-frequência. Os APs são interligados a uma Unidade Central de Processamento (do inglês, *Central Processing Unit*) (CPU) por enlaces de *fronthaul* com capacidade infinita, na qual é realizada a decodificação dos dados de *uplink*.

De acordo com as abordagens apresentadas em [9], [4], consideramos que cada AP é equipado com um Arranjo Linear Uniforme (do inglês, *Uniform Linear Array*) (ULA) composto por N antenas. O comprimento total da ULA é dado por $L\lambda$, em que λ representa o comprimento de onda associado à frequência do sinal transmitido. Adicionalmente, estabelecemos uma distância mínima $d_{\min} = \lambda/2$ entre antenas adjacentes, de modo a evitar interferências mútuas.

No que tange à modelagem do canal, assume-se um cenário Sem Linha de Visada (do inglês, *Non-Line of Sight*) (NLoS) que integra perda de percurso e desvanecimentos em larga e pequena escala [6]. O vetor de canal de *uplink* do k -ésimo usuário para o m -ésimo AP é expresso por:

$$\mathbf{h}_{k,m}(\mathbf{x}_m) = \sqrt{\beta_{k,m}} \mathbf{f}_{k,m}(\mathbf{x}_m). \quad (1)$$

A Eq. (1) decompõe-se em dois termos essenciais: o escalar $\beta_{k,m}$, que agrega os efeitos de perda de percurso e sombreamento, e o vetor $\mathbf{f}_{k,m}(\mathbf{x}_m)$, responsável pelo desvanecimento em pequena escala. Este último é modelado como uma variável aleatória complexa com distribuição $\mathcal{CN}(\mathbf{0}, \mathbf{R}_{k,m}(\mathbf{x}_m))$, cujos detalhes podem ser consultados em [10], [11].

Já o parâmetro $\mathbf{x}_m$ da equação denota o vetor que contém as posições das N antenas fluidas do m -ésimo AP ao longo da ULA. Assim, definimos que os elementos radiantes podem “deslizar” dentro de uma faixa previamente estabelecida de comprimento $Qd_{\min}$, sendo Q um número inteiro. Cada entrada de $\mathbf{x}_m$ assume o valor da posição da antena, preservando a separação mínima $d_{\min}$ entre antenas adjacentes. Assim, $\mathbf{x}_m$ representa, de forma compacta, a configuração posicional instantânea das antenas no AP m [4].

A Fig. 1 ilustra a ULA com as posições das antenas representadas por quadrados vermelhos, ficando evidente que o valor de Q é um parâmetro crucial que afeta a flexibilidade do sistema, o tamanho da ULA e a complexidade da otimização. Desse modo, considerando a arquitetura descrita, o n -ésimo componente do vetor $\mathbf{x}_m$, indicado por $\mathbf{x}_m(n)$, deve satisfazer:

$$\mathbf{x}_m(n) \in [(n-1)(Q+1)d_{\min}, (n(Q+1)-1)d_{\min}], \quad \forall n = 1, \dots, N. \quad (2)$$




Fig. 1: Representação de uma ULA onde a região de deslocamento dos elementos das antenas são espaçados por $d_{\min}$. Os quadrados em vermelho representam as posições reais das antenas.

III. PROCESSAMENTO DO SINAL E MÉTRICAS DE DESEMPENHO

Para o processamento no enlace de *uplink* assumimos informação do estado do canal (do inglês, *channel state information*) (CSI) perfeita. Com isso, o sinal recebido em cada AP é a soma das contribuições de todos os usuários, cada uma atenuada pelo respectivo vetor de canal que depende da posição das antenas fluidas e acrescida de ruído térmico.

Cada AP aplica localmente um vetor de combinação para extrair a contribuição de um usuário, essas contribuições são então encaminhadas à CPU, que as soma para formar a estimativa do símbolo do usuário. Com estas informações podemos extrair expressões, que são utilizadas neste trabalho e que aparecem nas equações abaixo, contudo, as referências [7] e [4] apresentam de forma mais detalhada as deduções que conduzem às Eqs. (3) e (4) que representam a Razão Sinal-Interferência mais Ruído (do inglês, *Signal to Interference plus Noise Ratio*) (SINR) do k -ésimo usuário.

Dessa forma, para um vetor de combinação $\mathbf{w}_{k,m}$ genérico, temos que a SINR, γ_k , do k -ésimo usuário é dada pela Eq. (3). Já para o caso específico de razão máxima (do inglês, *maximum ratio*) (MR) utilizado neste trabalho, ou seja, assumindo $\mathbf{w}_{k,m} = \mathbf{h}_{k,m}(\mathbf{x}_m) / \|\mathbf{h}_{k,m}(\mathbf{x}_m)\|$, a SINR, γ_k^{MR} , do k -ésimo usuário é representada pela Eq. (4). Nessas expressões, p_k representa a potência de transmissão do usuário k . σ_z^2 é a variância do ruído térmico (assumida independente de m). $\mathcal{M}_k$ é o conjunto que reúne os APs que atendem o usuário k , onde $M_a = |\mathcal{M}_k|$ que corresponde à quantidade desses APs e $\mathbf{w}_{k,m}$ corresponde ao vetor de combinação aplicado no AP m para extrair o sinal do k -ésimo usuário.

$$\gamma_k = \frac{p_k \left| \sum_{m \in \mathcal{M}_k} \mathbf{w}_{k,m}^H \mathbf{h}_{k,m}(\mathbf{x}_m) \right|^2}{\sum_{j \neq k} p_j \left| \sum_{m \in \mathcal{M}_k} \mathbf{w}_{k,m}^H \mathbf{h}_{j,m}(\mathbf{x}_m) \right|^2 + \sigma_z^2 \sum_{m \in \mathcal{M}_k} \|\mathbf{w}_{k,m}\|^2}, \quad (3)$$

$$\gamma_k^{MR} = \frac{p_k \left| \sum_{m \in \mathcal{M}_k} \|\mathbf{h}_{k,m}(\mathbf{x}_m)\| \right|^2}{\sum_{j \neq k} p_j \left| \sum_{m \in \mathcal{M}_k} \frac{\mathbf{h}_{k,m}^H(\mathbf{x}_m) \mathbf{h}_{j,m}(\mathbf{x}_m)}{\|\mathbf{h}_{k,m}(\mathbf{x}_m)\|} \right|^2 + \sigma_z^2 |\mathcal{M}_k|}. \quad (4)$$

Observa-se que tanto a SINR geral, γ_k , quanto a versão com MR, γ_k^{MR} , dependem das posições das antenas ($\mathbf{x}_m$) nos APs

que compõem para gerar o canal, bem como das potências de transmissão dos usuários. Em particular, a potência desejada p_k atua diretamente no termo útil da SINR, enquanto as potências dos demais usuários p_j influenciam o nível de interferência multiusuário. Assim, as alterações nas antenas dos APs fora de $\mathcal{M}_k$ não geram impacto direto, ou seja, a SINR de um usuário específico (k) só se altera se mudarmos a posição das antenas fluidas nos APs que realmente estão atendendo esse usuário. Se mudarmos a posição das antenas de um AP que está fora desse grupo de atendimento, a SINR do usuário k não sofrerá nenhuma influência, ao passo que o gerenciamento de potência pode melhorar o equilíbrio entre sinal, interferência e ruído, elevando a QoS do sistema.

Diante disso, adota-se a eficiência espectral e a taxa de transmissão como métricas de desempenho, que são definidas pelas equações a seguir, respectivamente:

$$SE_k = \log_2(1 + \gamma_k^{MR}), \quad (5a)$$

$$R_k = B \cdot SE_k, \quad (5b)$$

onde B representa a largura de banda do canal. Logo, a taxa de transmissão é um indicador-chave de desempenho, onde um valor elevado demonstra a capacidade da rede de entregar grandes quantidades de dados, sendo fundamental para viabilizar as aplicações de alta velocidade e baixa latência esperadas para as redes 6G.

IV. OTIMIZAÇÃO DO SISTEMA

Para o problema proposto, desejamos determinar as potências de transmissão no *uplink* e as posições das antenas em todos os APs, de modo que a eficiência espectral mínima entre os usuários seja maximizada. Para isso, temos:

$$\max_{\mathbf{X}, \mathbf{p}} \min_{k=1, \dots, K} \log_2(1 + \gamma_k^{MR}) \quad (6a)$$

$$\text{s.a. } 0 \leq p_k \leq P_{\max, k}, \quad \forall k = 1, \dots, K, \quad (6b)$$

$$\mathbf{x}_m(n) \in [(n-1)(Q+1)d_{\min}, (n(Q+1)-1)d_{\min}], \\ \forall m = 1, \dots, M, \quad \forall n = 1, \dots, N, \quad (6c)$$

onde (6a) representa a função objetivo, que busca maximizar a eficiência espectral mínima entre os usuários. Sujeito às restrições apresentadas em (6b) e (6c), onde (6b) indica as restrições de potência de transmissão dos usuários, enquanto (6c) representa as restrições de posicionamento das antenas, descritas na seção II.

Como a função logarítmica é monotonicamente crescente, (6a) equivale a maximizar diretamente a SINR mínima. Entretanto, a função objetivo não é conjuntamente convexa em $(\mathbf{X}, \mathbf{p})$ como já enfatizado por [4]. Assim aplicamos a Otimização Alternada (OA), ou seja, maximizamos iterativamente em relação a $\mathbf{p}$ para $\mathbf{X}$ fixo, e em relação a $\mathbf{X}$ para $\mathbf{p}$ fixo.

A maximização em relação a $\mathbf{p}$ é um clássico desafio de otimização em redes de comunicação sem fio. O objetivo é encontrar a alocação de potência ideal para que a pior conexão do sistema (o usuário com o sinal mais fraco) tenha sua qualidade maximizada, garantindo justiça (*fairness*) para todos [12]. Por isso introduzimos a variável auxiliar t , obtendo um subproblema que pode ser resolvido aplicando o método da

bisseção e o problema passa a ser (7a), sujeito às restrições lineares (7b) e (7c) [13].

$$\max_{\mathbf{p}} t \quad (7a)$$

$$\text{s.a. } 0 \leq p_k \leq P_{\max, k}, \quad \forall k = 1, \dots, K, \quad (7b)$$

$$\gamma_k^{MR} \geq t, \quad \forall k = 1, \dots, K. \quad (7c)$$

Referente à otimização em relação a $\mathbf{X}$, ou seja, em relação às posições das antenas, o problema é formulado como:

$$\max_{\mathbf{X}, \mathbf{p}} \min_{k=1, \dots, K} \gamma_k^{MR} \quad (8a)$$

$$\text{s.a. } \mathbf{x}_m(n) \in [(n-1)(Q+1)d_{\min}, (n(Q+1)-1)d_{\min}], \\ \forall m = 1, \dots, M, \quad \forall n = 1, \dots, N. \quad (8b)$$

Nessas condições, o problema pode ser solucionado de duas formas, a primeira por meio de uma BE, alternando-se as posições das antenas de um AP por vez até que haja convergência da função objetivo, para isso, as posições são quantizadas em Q posições possíveis, o que leva a uma complexidade por iteração dessa solução proporcional ao produto MNQ , sendo esta solução aplicada no trabalho [4]. Já a segunda abordagem é a proposta neste trabalho, onde aplicamos PSO.

Diferentemente da primeira abordagem, baseada em quantização, que restringe a busca a um conjunto discreto de posições pré-definidas, este trabalho propõe a aplicação da PSO para explorar o domínio espacial contínuo das antenas fluidas. A formulação via PSO permite mitigar o erro de quantização inerente ao *grid* fixo, possibilitando a busca por possíveis máximos globais de SINR que residem entre os pontos de amostragem discretos. Adicionalmente, empregou-se uma estratégia de *Warm Start* (inicialização quente), onde a melhor solução encontrada pelo método discreto é inserida na população inicial do PSO. Essa abordagem híbrida refina a solução grosseira da quantização, garantindo um ajuste fino da posição da antena para maximização da mínima SINR.

O PSO é uma meta-heurística estocástica inspirada no comportamento social de bandos de aves, sendo associadas como partículas. Este método é capaz de resolver problemas de otimização não lineares em domínios contínuos. Ao contrário da BE, o PSO permite que as variáveis de decisão assumam valores reais arbitrários, o que o torna particularmente adequado para o refinamento posicional do FAS. O PSO reúne vários atributos vantajosos, como a simplicidade de implementação e o uso de operadores matemáticos simples, o que resulta em menor demanda de memória e maior velocidade de processamento [14].

Na abordagem proposta, uma população de N_p partículas geradas aleatoriamente, respeitando a restrição (6c), navega pelo espaço de busca D -dimensional (onde $D = M \times N$). Cada partícula i é representada por seu vetor de posição $\mathbf{x}_i^{(t)}$, que denota uma configuração completa das posições das antenas na iteração t , e por um vetor de velocidade $\mathbf{v}_i^{(t)}$, que dita a direção e intensidade do movimento.

A atualização das partículas a cada iteração t é governada por dois componentes principais: a “memória” da melhor posição encontrada pela própria partícula ($\mathbf{p}_{best, i}$) e a melhor posição encontrada por todo o enxame ($\mathbf{g}_{best}$) [15]. As

equações canônicas de movimento são dadas por:

$$\mathbf{v}_i^{(t+1)} = w \cdot \mathbf{v}_i^{(t)} + c_1 r_1 (\mathbf{p}_{best,i} - \mathbf{x}_i^{(t)}) + c_2 r_2 (\mathbf{g}_{best} - \mathbf{x}_i^{(t)}) \quad (9)$$

$$\mathbf{x}_i^{(t+1)} = \mathbf{x}_i^{(t)} + \mathbf{v}_i^{(t+1)} \quad (10)$$

Onde os parâmetros-base do algoritmo são definidos como:

- **w (Peso de Inércia):** controla a influência da velocidade anterior, equilibrando a capacidade de exploração global e o refinamento local;
- **c_1 (Coef. Cognitivo):** pondera a atração da partícula em direção à sua própria melhor experiência histórica ($\mathbf{p}_{best}$);
- **c_2 (Coef. Social):** pondera a atração em direção à melhor solução global do enxame ($\mathbf{g}_{best}$);
- **r_1, r_2 :** Variáveis aleatórias uniformemente distribuídas no intervalo $[0, 1]$, introduzindo estocasticidade para evitar aprisionamento em ótimos locais.

Com isso, $\mathbf{x}_i$ representa o vetor de posição, que define a configuração espacial exata das antenas ao longo da estrutura da ULA. Para cada elemento radiante, este valor é uma coordenada real dentro de um domínio contínuo, permitindo que a antena se mova para qualquer ponto que maximize a eficiência do sistema. Já o vetor $\mathbf{v}_i$ atua como o motor de busca, representando o deslocamento que direciona o ajuste das posições a cada iteração. Ele dita a intensidade e o sentido do movimento das antenas, sendo influenciado pela inércia do movimento anterior, pela melhor experiência individual da partícula e pelo sucesso global de todo o enxame. Desse modo, enquanto $\mathbf{x}_i$ representa a localização instantânea das antenas na ULA, $\mathbf{v}_i$ determina o deslocamento necessário para explorar o espaço de busca e otimizar o desempenho da rede.

A principal vantagem do PSO frente à BE reside na sua independência em relação a Q , o que assegura maior eficiência em buscas refinadas (valores elevados de Q). Diferentemente da BE, que se torna computacionalmente inviável com o aumento de Q , o tempo de execução do PSO não é impactado por essa variável. Adicionalmente, estabeleceu-se um critério de parada por estagnação: o algoritmo é interrompido caso a melhor solução não sofra atualizações por ϵ iterações consecutivas. A função de aptidão para cada posição $\mathbf{x}_i$ é definida pela maximização da SINR mínima, e os parâmetros adotados empiricamente estão detalhados na Tabela I.

TABELA I
Configuração dos Parâmetros do PSO.

Parâmetro	Var.	Valor	Descrição
Tam. do Enxame	N_p	20	Número de vetores candidatos
Máx. de Iterações	T_{max}	100	Critério de parada temporal
Coef. de Inércia	w	0,7	Equil., exploração/exploração
Coef. de Aceleração	c_1, c_2	1,5	Atração cognitiva e social
Estagnação	ϵ	5	Critério de parada

V. RESULTADOS NUMÉRICOS

Nesta seção, apresentamos resultados numéricos para demonstrar a eficácia da otimização da posição das antenas e do controle de potência. Consideramos uma área de cobertura de 1 km^2 com a configuração micro urbana descrita em [16], [4]. Os parâmetros adotados para todos os usuários são: $P_{max} =$

23 dBm, $\sigma_z^2 = N_0 B$, $N_0 = 174 \text{ dBm/Hz}$ e $B = 20 \text{ MHz}$, para o cenário com $K = 10$, $M = 30$ e $M_a = 5$.

A Fig. 2a apresenta o desempenho comparativo de diferentes estratégias de otimização por meio das curvas de Função de Distribuição Cumulativa (do inglês, *Cumulative Distribution Function*) (CDF) da taxa alcançável por usuário. A análise engloba o controle de potência, contrastando a distribuição uniforme ($p_k = P_{max}$) com o método da Bissecção. Além disso, examina-se o impacto do posicionamento das antenas no FAS utilizando os algoritmos BE e PSO. Para uma comparação justa, o cenário de “Ant. Fixas” adota uma ULA com o mesmo comprimento da antena fluida, mantendo posições aleatórias inalteradas durante o processo. Os resultados demonstram que a otimização da potência no *uplink* é fundamental para garantir a QoS, enquanto o ajuste dinâmico das posições no FAS proporciona ganhos adicionais, reforçando seu potencial em elevar a eficiência espectral.

A Fig. 2b apresenta a comparação do Tempo Computacional (TC)¹ para diferentes valores de Q nas otimizações via BE e PSO. Observa-se que, no BE, o aumento de Q provoca um acréscimo significativo no TC, enquanto o PSO mantém o tempo de processamento praticamente constante. Adicionalmente, os resultados mostram que o PSO sem a estratégia de *Warm Start* mantém um TC estável e similar ao caso com a estratégia, reiterando a independência de Q do PSO.

Já a Fig. 2c mostra o efeito do número de antenas N por AP na otimização. O gráfico indica que o aumento do número de antenas por AP N também contribui para uma melhoria na taxa mínima entre os usuários, isso ocorre porque um número maior de antenas por AP permite uma maior diversidade espacial, o que pode melhorar a eficiência espectral e a qualidade do serviço para os usuários, sendo um resultado já esperado. Destacando-se aqui a simulação com a otimização usando o PSO, onde o aumento de N tem um impacto mais significativo na melhoria da taxa entre os usuários, em comparação com a otimização usando a BE.

Por fim, a análise dos percentis da Tabela II confirma o impacto do controle de potência na equidade $\max - \min$. Com Pot. Uniforme, há forte disparidade de taxas (P90 em 82,77 e P10 entre 71 e 72), cenário em que a BE oferece apenas um ganho marginal no limite inferior (71,98). A otimização de potência mitiga essa assimetria ao redistribuir recursos, elevando o P10 para a faixa de 76. Sob esse regime, o PSO supera a BE em todos os percentis analisados.

TABELA II
Análise dos percentis das taxas.

	Pot. Uniforme		Pot. Otimizada	
	Ant. BE	Ant. PSO	Ant. BE	Ant. PSO
P10	71,98	71,00	76,6	76,99
P50	79,19	79,26	78,05	78,45
P90	82,73	82,77	79,16	79,36

¹As medições de tempo da simulação, implementada em Python, foram obtidas utilizando plataforma de *hardware* com processador 13th Gen Intel(R) Core(TM) i7-13620H (2.40 GHz) e 16 GB de memória RAM.




Fig. 2: Resultado da aplicação da otimização para o cenário com $K = 10$, $M = 30$ e $M_a = 5$ com 10^2 experimentos.

VI. CONCLUSÕES

Este trabalho apresentou uma investigação sobre a aplicação de sistemas de antenas fluidas em redes CF-mMIMO, demonstrando o potencial desta tecnologia como habilitadora para as futuras redes 6G. Os resultados numéricos comprovam que a reconfigurabilidade espacial proporcionada pelo FAS introduz novos graus de liberdade na camada física, permitindo mitigação adaptativa de interferências e exploração eficiente da diversidade espacial. O método PSO apresentou melhor desempenho observado sob os cenários simulados em relação à BE, especialmente em cenários com maior número de antenas por APs, onde a otimização no domínio contínuo elimina o erro de quantização inerente às abordagens discretas.

Ademais, verificou-se que a combinação de controle de potência e posicionamento dinâmico de antenas proporciona ganhos substanciais na QoS no critério max-min, assegurando equidade entre os usuários e elevando significativamente as taxas mínimas alcançáveis. A análise gráfica revelou comportamentos importantes do sistema: a otimização de potência conduz a uma convergência assintótica do desempenho se comparado com o caso com potência uniforme e embora com custo computacional crescente, o incremento do número de antenas N por APs potencializa os ganhos de diversidade espacial, sendo este efeito mais pronunciado quando combinado com otimização contínua via PSO.

Como trabalhos futuros, vislumbra-se a extensão deste modelo para cenários operando em frequências de ondas milimétricas (mmWave), o que exige a superação de desafios inerentes à alta perda de propagação e à sensibilidade a bloqueios. Nesse contexto, a integração do FAS com técnicas de *beamforming* analógico e digital (híbrido), em redes CF-mMIMO surge como uma solução estratégica em arquiteturas distribuídas. Adicionalmente, dada a natureza combinatória e a alta dimensionalidade desses sistemas, torna-se essencial explorar algoritmos de baixa complexidade, como abordagens baseadas na Teoria de Pareamento (*Matching-Theoretic Approach*), as quais permitem modelar as interações entre feixes, usuários e APs como um problema de atribuição estável.

REFERÊNCIAS

- [1] W. K. New, K.-K. Wong, H. Xu, C. Wang, F. R. Ghadi, J. Zhang, J. Rao, R. Murch, P. Ramírez-Espinosa, D. Morales-Jimenez, C.-B.

- Chae, and K.-F. Tong, "A tutorial on fluid antenna system for 6G networks: Encompassing communication theory, optimization methods and hardware designs," *IEEE Communications Surveys & Tutorials*, vol. 27, pp. 2325–2377, Aug. 2025.
- [2] W. K. New, K.-K. Wong, C. Wang, C.-B. Chae, R. Murch, H. Jafarkhani, and Y. Hao, "Fluid antenna systems: Redefining reconfigurable wireless communications," *IEEE Journal on Selected Areas in Communications*, pp. 1–1, 2025.
- [3] W. K. New, K.-K. Wong, H. Xu, K.-F. Tong, and C.-B. Chae, "Fluid antenna system: New insights on outage probability and diversity gain," *IEEE Transactions on Wireless Communications*, vol. 23, pp. 128–140, Jan. 2024.
- [4] M. Olyaei and S. Buzzi, "User-centric cell-free massive MIMO with access points empowered by fluid antennas," in *Proc. IEEE 25th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC)*, pp. 666–670, Sept. 2024.
- [5] C. Skouroumounis and I. Krikidis, "Fluid antenna with linear MMSE channel estimation for large-scale cellular networks," *IEEE Transactions on Communications*, vol. 71, pp. 1112–1125, Feb. 2023.
- [6] S. Buzzi and C. D'Andrea, "Cell-free massive MIMO: User-centric approach," *IEEE Wireless Communications Letters*, vol. 6, pp. 706–709, Dec. 2017.
- [7] Ö. T. Demir, E. Björnso, and L. Sanguinetti, "Foundations of user-centric cell-free massive MIMO," *Foundations and Trends® in Signal Processing*, vol. 14, pp. 162–472, Jan. 2021.
- [8] R. P. Antonioli, I. M. Braga, G. Fodor, Y. C. B. Silva, A. L. F. de Almeida, and W. C. Freitas, "On the energy efficiency of cell-free systems with limited fronthauls: Is coherent transmission always the best alternative?," *IEEE Transactions on Wireless Communications*, vol. 21, no. 10, pp. 8729–8743, Oct. 2022.
- [9] G. Hu, Q. Wu, K. Xu, J. Ouyang, J. Si, Y. Cai, and N. Al-Dhahir, "Fluid antennas-enabled multiuser uplink: A low-complexity gradient descent for total transmit power minimization," *IEEE Communications Letters*, vol. 28, no. 3, pp. 602–606, 2024.
- [10] M. R. Akdeniz, Y. Liu, M. K. Samimi, S. Sun, S. Rangan, T. S. Rappaport, and E. Erkip, "Millimeter wave channel modeling and cellular capacity evaluation," *IEEE Journal on Selected Areas in Communications*, vol. 32, pp. 1164–1179, June 2014.
- [11] E. Björnson, J. Hoydis, and L. Sanguinetti, "Massive MIMO networks: Spectral, energy, and hardware efficiency," *Foundations and Trends® in Signal Processing*, vol. 11, no. 3–4, pp. 154–655, 2017.
- [12] M. Hong and Z.-Q. Luo, *Signal Processing and Optimal Resource Allocation for the Interference Channel*, pp. 409–469. Elsevier, 2014.
- [13] S. P. Boyd, *Convex optimization*. Cambridge: Cambridge University Press, version 29 ed., 2023. first published 2004.
- [14] A. L. S. Aguiar, F. B. C. Sousa, and Y. V. L. de Melo, "Optical distribution network design using PSO," *IEEE Communications Letters*, vol. 27, pp. 239–242, Jan. 2023.
- [15] J. Kennedy and R. Eberhart, "Particle swarm optimization," in *Proc. of ICNN'95 - International Conference on Neural Networks*, vol. 4, pp. 1942–1948, 1995.
- [16] 3GPP, "Further advancements for E-UTRA physical layer aspects," Technical Report TR 36.814 v9.2.0, 3rd Generation Partnership Project (3GPP), Mar. 2017.