

# Estimação de canal usando RIS híbrida e OMP com refinamentos sucessivos

Luiz H. O. Martiniano, David W. M. Guerra, Taufik Abrão e Cristiano M. Panazio

**Resumo**— Superfícies Inteligentes Reconfiguráveis (RIS - *Reconfigurable Intelligent Surface*) são uma solução promissora para aumentar a taxa e a cobertura em sistemas 6G. O uso de elementos ativos na RIS, gerando uma RIS híbrida, permite reduzir o comprimento das sequências piloto e a complexidade da estimação de canal. Neste contexto, propõe-se utilizar sucessivas rotações em uma técnica baseada no algoritmo *Orthogonal Matching Pursuit* (OMP), que resolve a estimação do canal tratando-o como um problema do tipo amostragem compressiva (CS - *Compressive Sensing*). Simulações mostram que a técnica proposta alcança desempenho igual ou superior com menor complexidade em relação a outras abordagens.

**Palavras-Chave**— RIS híbrida, amostragem compressiva, estimação de canal, OMP

**Abstract**— Reconfigurable Intelligent Surfaces (RIS) are a promising solution for increasing the data rate and coverage in 6G systems. The use of active elements in a RIS (hybrid RIS) allows for reducing the length of pilot sequences and the complexity of channel estimation. In this context, it is proposed to use successive rotations in a technique based on the *Orthogonal Matching Pursuit* (OMP) algorithm, which performs channel estimation by treating it as a compressive sensing (CS) problem. Simulations show that the proposed technique achieves equal or superior performance with lower complexity compared to other approaches.

**Keywords**— Hybrid RIS, compressive sensing, channel estimation, OMP

## I. INTRODUÇÃO

As superfícies inteligentes reconfiguráveis (RIS - *Reconfigurable Intelligent Surface*), com seus múltiplos elementos que permitem alterar as fases e amplitudes dos sinais refletidos, são capazes de melhorar consideravelmente a cobertura e a capacidade do sistema, atendendo aos requisitos de sistemas móveis de sexta geração [1]–[4]. No entanto, os possíveis ganhos dependem da qualidade da estimação do canal (CE - *Channel Estimation*), em que a RIS impõe alguns desafios adicionais: o elevado número de coeficientes a serem estimados, dado que esse número é proporcional ao número de elementos da RIS, e a necessidade de estimar tanto o canal entre a RIS e a estação rádio-base (BS - *Base Station*) quanto o canal entre a RIS e o usuário (UE - *User Equipment*). Uma possível solução, que impacta na eficiência espectral e energética do sistema, é o uso de sequências piloto mais longas [1], [5].

Para mitigar esse desafio, foi proposto o uso de uma RIS híbrida [6], na qual alguns elementos ativos não apenas refletem,

mas também recebem sinais, permitindo a estimação direta do canal e a separação das componentes UE-RIS e BS-RIS, reduzindo a complexidade computacional e a sobrecarga de sinalização. Além disso, como a CE pode ser modelada como um problema esparso, técnicas de CS podem ser aplicadas para recuperar todos os coeficientes do canal [1], [7].

As técnicas de CE baseadas em CS requerem um dicionário construído a partir de um *grid* quantizado de ângulos de azimute e elevação. Para garantir um bom desempenho, é fundamental que esses ângulos estejam o mais próximos possível dos verdadeiros ângulos do canal [8], o que demanda um dicionário extenso e implica em alta complexidade computacional. Visando reduzir essa complexidade, [9] propôs uma abordagem baseada em perturbações controladas e otimização por gradiente descendente. No entanto, essa técnica ainda apresenta elevada complexidade e exige um ajuste criterioso de múltiplos parâmetros. Já [10] realiza uma rotação de fase nas soluções obtidas pelo dicionário original, de modo a reduzir a discrepância entre a resposta encontrada e o valor verdadeiro. Isto permite manter ou mesmo melhorar o desempenho, trabalhando com um menor dicionário e, portanto, diminuindo significativamente a complexidade computacional da CE.

A contribuição do presente artigo é uma técnica que aprimora o método proposto em [10] através do uso de múltiplas etapas de rotação e eliminação de operações desnecessárias, o que permite reduzir ainda mais a complexidade, mantendo ou mesmo melhorando o desempenho. Os resultados obtidos são corroborados por simulações.

O restante do artigo está organizado da seguinte forma: a Seção 2 apresenta o modelo do sistema; a Seção 3 detalha a estimativa do canal utilizando uma RIS híbrida e CS; a Seção 4 descreve a técnica proposta; a Seção 5 traz as simulações e análises dos resultados; por fim, a Seção 6 apresenta as conclusões.

## II. MODELO DE SISTEMA

Considera-se uma RIS híbrida estruturada como um arranjo planar uniforme com  $N_{RIS} = N_{RIS,h} \times N_{RIS,v}$  elementos, em que  $N_{RIS,h}$  e  $N_{RIS,v}$  são as quantidades de elementos nas direções horizontal e vertical, respectivamente. Dentre esses elementos,  $N_{ativ}$  operam ativamente na recepção dos sinais piloto da BS e dos UEs, e, posteriormente, atuam como elementos passivos, ajustando fase e atenuação do sinal refletido.

Uma das vantagens do uso de elementos ativos é permitir a estimação separada dos canais UE-RIS e BS-RIS. Como o canal BS-RIS é quase estático comparado ao UE-RIS, devido à mobilidade do UE, este estudo foca na estimação do canal UE-RIS. Além disso, assume-se a ausência de enlace direto entre BS e UE, destacando a estimação na RIS híbrida.

Luiz H. O. Martiniano e Cristiano M. Panazio, Universidade de São Paulo (USP), São Paulo, SP, Brasil, e-mails: {luizmartiniano,cpanazio}@usp.br

David. W. M. Guerra, Universidade Federal de Pernambuco (UFPE), Recife, PE, Brasil, e-mail: davidwmgueira@gmail.com

Taufik Abrão, Universidade Estadual de Londrina (UEL), Londrina, PR, Brasil, e-mail: taufik@uel.br

Este trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), código de financiamento 001, e apoio parcial do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), por meio dos processos 314618/2023-6 e 442945/2023-0.

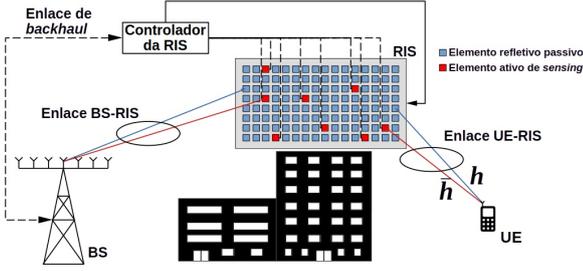


Fig. 1: Modelo de sistema utilizando RIS

Considera-se o uso de sequências pilotos ortogonais no sistema e que não há contaminação destas. Assim, o caso de múltiplos usuários com múltiplas antenas pode ser reduzido, sem perda da generalidade, ao caso de um único usuário equipado com  $N_{UE} = 1$  antena. O modelo do sistema está representado na Figura 1.

O modelo de canal geométrico de banda estreita e esparso, utilizado em transmissões com ondas milimétricas, é empregado para descrever o canal UE-RIS [3], [11]

$$\mathbf{h} = \sqrt{\frac{N_{RIS}}{L}} \sum_{l=0}^{L-1} \alpha_l \mathbf{a}(\nu_l, \xi_l), \quad (1)$$

em que  $\alpha_l \sim \mathcal{CN}(0, 1)$  é o ganho complexo do  $l$ -ésimo caminho,  $L$  é o número de caminhos entre a RIS e o UE, e  $\mathbf{a}(\nu_l, \xi_l) \in \mathbb{C}^{N_{RIS} \times 1}$  representa o vetor de direção do sinal incidente na RIS. As coordenadas no domínio virtual, cujo detalhamento é apresentado na Seção III, são definidas como  $\nu_l = \sin(\phi_l) \sin(\theta_l)$  e  $\xi_l = \cos(\theta_l)$ , em que  $\phi_l \in [-\frac{\pi}{2}, \frac{\pi}{2}]$  e  $\theta_l \in [0, \pi]$  representam, respectivamente, os ângulos de azimute e elevação da direção de chegada (*Angle of Arrival* - AoA) do sinal em relação à RIS.

O vetor de direção  $\mathbf{a}(\nu_l, \xi_l)$  é dado por [12]:

$$\mathbf{a}(\nu_l, \xi_l) = \mathbf{a}_h(\nu_l) \otimes \mathbf{a}_v(\xi_l), \quad (2)$$

em que  $\otimes$  representa o produto de Kronecker e

$$\mathbf{a}_h(\nu_l) = \frac{1}{\sqrt{N_{RIS,h}}} [e^{j2\pi \frac{d}{\lambda} \nu_l \mathbf{m}_h}]^T, \quad \mathbf{a}_v(\xi_l) = \frac{1}{\sqrt{N_{RIS,v}}} [e^{j2\pi \frac{d}{\lambda} \xi_l \mathbf{m}_v}]^T \quad (3)$$

em que  $\lambda$  é o comprimento de onda do sinal,  $d$  denota o espaçamento dos elementos vizinhos da RIS,  $\mathbf{m}_h = [0 \ 1 \ \dots \ (N_{RIS,h} - 1)]$  e  $\mathbf{m}_v = [0 \ 1 \ \dots \ (N_{RIS,v} - 1)]$ .

O sinal recebido pelos elementos ativos da RIS, quando o UE transmite o sinal piloto, é dado por:

$$\mathbf{Y}_{\text{ativ}} = \mathbf{W}\mathbf{h}\mathbf{s} + \mathbf{N}_{\text{ativ}} \quad (4)$$

em que  $\mathbf{W} \in \mathbb{Z}^{N_{\text{ativ}} \times N_{RIS}}$  seleciona os elementos ativos, colocando um único elemento 1 em cada linha na coluna correspondente ao índice do respectivo elemento ativo e 0 nos demais elementos da matriz,  $\mathbf{h} \in \mathbb{C}^{N_{RIS} \times 1}$  é o canal entre a RIS e o UE,  $\mathbf{s} \in \mathbb{C}^{1 \times \tau_p}$  é o piloto transmitido, sendo  $\tau_p$  o comprimento do piloto e  $\mathbf{N}_{\text{ativ}} \in \mathbb{C}^{N_{\text{ativ}} \times \tau_p}$  é a matriz de ruído branco gaussiano nos elementos ativos em que a  $k$ -ésima coluna é dada por  $\mathbf{n}_k \sim \mathcal{CN}(0, \sigma_n^2 \mathbf{I}_{N_{\text{ativ}}})$ .

A estimativa do canal  $\mathbf{h}$  passa pela estimativa do canal nos elementos ativos,  $\hat{\mathbf{h}}$ . Isto pode ser feito através do uso do sinal piloto e estimação por mínimos quadrados. Fazendo, sem perda da generalidade, que  $\mathbf{s}\mathbf{s}^H = \mathbf{I}$ , tem-se então que

$$\hat{\mathbf{h}} = (\mathbf{s}\mathbf{Y}_{\text{ativ}}^H)^H = \mathbf{W}\mathbf{h} + \hat{\mathbf{n}}, \quad (5)$$

sendo  $\hat{\mathbf{n}} \sim \mathcal{CN}(0, \sigma_n^2 \mathbf{I}_{N_{\text{ativ}}})$ .

### III. ESTIMATIVA DO CANAL POR AMOSTRAGEM COMPRESSIVA

Para estimar  $\mathbf{h}$  a partir de  $\hat{\mathbf{h}}$  através de CS, o espaço contínuo dos ângulos de chegada (AoA) é discretizado em um *grid* finito. De acordo com [9], os principais métodos de discretização angular incluem a amostragem uniforme nos domínios virtual e físico. No presente artigo, optou-se pela amostragem uniforme no domínio virtual, discretizando  $\nu$  e  $\xi$  no intervalo  $[-1, 1)$  para reduzir a coerência do dicionário e garantir maior ortogonalidade entre os vetores [9], [10], [12].

Assim, sabendo que a RIS é um arranjo planar uniforme, define-se o dicionário de possíveis vetores resposta como:

$$\begin{aligned} \Psi &= \Psi_{Az} \otimes \Psi_{El} \\ &= [\mathbf{a}(\nu(0)), \dots, \mathbf{a}(\nu(N_{Az} - 1))] \otimes [\mathbf{a}(\xi(0)), \dots, \mathbf{a}(\xi(N_{El} - 1))] \\ &= [\mathbf{a}(\nu(0), \xi(0)), \dots, \mathbf{a}(\nu(0), \xi(N_{El} - 1)), \dots, \\ &\quad \mathbf{a}(\nu(N_{Az} - 1), \xi(N_{El} - 1))] \end{aligned} \quad (6)$$

em que os parâmetros de discretização são dados por:

$$\nu(p) = -1 + \frac{2p}{N_{Az}}, \quad p = 0, 1, \dots, N_{Az} - 1, \quad (7)$$

$$\xi(q) = -1 + \frac{2q}{N_{El}}, \quad q = 0, 1, \dots, N_{El} - 1. \quad (8)$$

Aqui,  $\mathbf{a}(\nu(p))$  e  $\mathbf{a}(\xi(q))$  representam vetores de direção definidos pelos parâmetros  $\nu(p)$  e  $\xi(q)$ , onde  $N_{Az}$  e  $N_{El}$  correspondem ao número de pontos do dicionário nos eixos de azimute e elevação, respectivamente. Dessa forma,  $\Psi$  possui dimensão  $N_{RIS} \times N_{Az} N_{El}$ , formando o dicionário de recepção com base nesse *grid*.

Em seguida, reescreve-se o canal  $\mathbf{h}$ , eq. (1), no domínio virtual angular como

$$\mathbf{h} = \Psi \tilde{\mathbf{h}} + \mathbf{q}_e \quad (9)$$

em que  $\tilde{\mathbf{h}}$ , que possui dimensão  $N_{Az} N_{El} \times 1$ , denota a formulação esparsa do canal UE-RIS e contém ganhos associados a alguns dos vetores que compõem o dicionário  $\Psi$  e  $\mathbf{q}_e$  representa o vetor de erro de quantização.

Supondo um número suficientemente grande de pontos no *grid*, existem  $L$  pares  $(\nu(p), \xi(q))$  que correspondem diretamente aos  $L$  pares reais  $(\nu_l, \xi_l)$ , com os  $L$  elementos não nulos de  $\tilde{\mathbf{h}}$  representando os ganhos desses trajetos. Assim, o problema é esparso, viabilizando a aplicação de CS.

Deste modo, substituindo (9) em (5), tem-se:

$$\hat{\mathbf{h}} = \mathbf{W}[\Psi \tilde{\mathbf{h}} + \mathbf{q}_e] + \hat{\mathbf{n}} = \Upsilon \tilde{\mathbf{h}} + \mathbf{n}_E, \quad (10)$$

em que  $\Upsilon = \mathbf{W}\Psi$ , que é a matriz de amostragem, e  $\mathbf{n}_E = \mathbf{W}\mathbf{q}_e + \hat{\mathbf{n}}$  expressa o ruído efetivo.

Logo, para obter  $\tilde{\mathbf{h}}$  e depois obter  $\mathbf{h} \approx \Psi \tilde{\mathbf{h}}$ , deve-se resolver o seguinte problema combinatório não-convexo:

$$\min \|\tilde{\mathbf{h}}\|_0 \quad \text{tal que} \quad \|\Upsilon \tilde{\mathbf{h}} - \hat{\mathbf{h}}\|_2 \leq \epsilon \quad (11)$$

em que  $\epsilon$  é um certo valor de tolerância.

Embora o problema em questão seja complexo, sua solução ótima pode ser aproximada por algoritmos como o *Orthogonal*

*Matching Pursuit* (OMP) [13]. No entanto, a qualidade da estimativa obtida pelo OMP depende consideravelmente do tamanho do dicionário, o que pode acarretar alta complexidade computacional. Para mitigar esse problema, [10] propõe a técnica *OMP-Phase Rotation* (PR), que refina a estimativa inicial do OMP, permitindo o uso de menores dicionários e, conseqüentemente, menor complexidade, sem comprometer o desempenho. Neste artigo, essa abordagem é aprimorada por meio de refinamentos angulares sucessivos, possibilitando uma redução adicional da complexidade.

#### IV. OMP COM REFINAMENTOS SUCESSIVOS

Enquanto o OMP-PR realiza uma única grande etapa de refino em torno do suporte dado pelo OMP, através de diversas rotações em um *grid* mais compacto obtido em uma menor faixa de ângulos que a do dicionário completo, a técnica aqui proposta, denominada *OMP-Successive Refinements* (SR), faz isto em  $N_{rot}$  rotações sucessivas, reduzindo gradualmente a faixa de ângulos, a distância entre os pontos do *grid* e buscando, em cada etapa, o melhor suporte. Isto permite uma busca mais eficiente que atinge o mesmo desempenho do OMP-PR, mas com uma menor complexidade, pois alguns cálculos desnecessários não são realizados. A técnica OMP-SR está descrita no Algoritmo 1 e é detalhada a seguir.

**Algoritmo 1:** OMP-SR em que  $\odot$ ,  $(\cdot)^H$  e  $(\cdot)^\dagger$  são, respectivamente, o produto de Hadamard, operador transposto-conjugado e pseudo-inversa.

---

**Entrada:**  $\hat{\mathbf{h}}, \mathbf{W}_2, \Psi, N_{ativ}, N_{rot}, \mathbf{R}^{[1]}, \mathbf{R}^{[2]}, \dots, \mathbf{R}^{[N_{rot}]}, I_{max}, \sigma^2$

1 **Inicialize:**  $\mathbf{r} = \hat{\mathbf{h}}, k = 1, \epsilon = 2\sigma^2, \Upsilon^{[0]} = \mathbf{W}\Psi, \mathbf{R}_{eq}^{[t]} = \mathbf{W}\mathbf{R}^{[t]}$ ,  
 $\Lambda = [], \mathcal{T} = \{ \}, \mathcal{R}_1 = \mathcal{R}_2 = \dots = \mathcal{R}_{N_{rot}} = \{ \}$

2 **enquanto**  $(\epsilon \geq \sigma^2 \ \& \ k \leq I_{max})$  **faça**

3      $\mathbf{g} = (\Upsilon^{[0]})^H \mathbf{r}$

4      $j = \text{argmax}|\mathbf{g}|$

5      $\mathcal{T} = \mathcal{T} \cup j$

6     **para**  $t = 1$  **até**  $N_{rot}$  **faça**

7          $\Upsilon^{[t]} = \Upsilon^{[t-1]}(:, j) \odot \mathbf{R}_{eq}^{[t]}$

8          $\mathbf{g} = (\Upsilon^{[t]})^H \mathbf{r}$

9          $j = \text{argmax}|\mathbf{g}|$

10          $\mathcal{R}^{[t]} = \mathcal{R}^{[t]} \cup j$

11     **fim**

12      $\Lambda = [\Lambda; \Upsilon^{[N_{rot}]}(:, j)]$

13      $\hat{\mathbf{h}} = \Lambda^\dagger \hat{\mathbf{h}}$

14      $\mathbf{r} = \hat{\mathbf{h}} - \Lambda \hat{\mathbf{h}}$

15      $\epsilon = \frac{1}{N_{ativ}} \|\mathbf{r}\|_2^2$

16      $k := k + 1$

17 **fim**

---

**Saída:**  $\hat{\mathbf{h}} = [\Psi(:, \mathcal{T}) \odot \mathbf{R}^{[1]}(:, \mathcal{R}^{[1]}) \odot \dots \odot \mathbf{R}^{[N_{rot}]}(:, \mathcal{R}^{[N_{rot}]})]^\dagger \hat{\mathbf{h}}$

---

Após a seleção preliminar do índice do melhor suporte (linhas 3-5), que corresponde ao algoritmo OMP, inicia-se uma série de  $N_{rot}$  refinamentos sucessivos em torno deste (linhas 6-11). Em cada estágio de refinamento, é utilizada uma matriz de rotação dada por  $\mathbf{R}^{[t]} = \Delta\Psi_{Az,t} \otimes \Delta\Psi_{El,t}$

$$= [\mathbf{a}(\Delta\nu(0)), \dots, \mathbf{a}(\Delta\nu(N_{Az} - 1))] \otimes [\mathbf{a}(\Delta\xi(0)), \dots, \mathbf{a}(\Delta\xi(N_{El} - 1))] \quad (12)$$

$$= [\mathbf{a}(\Delta\nu(t, 0), \Delta\xi(t, 0)), \dots, \mathbf{a}(\Delta\nu(t, 0), \Delta\xi(t, P - 1)), \dots, \mathbf{a}(\Delta\nu(t, P - 1), \Delta\xi(t, P - 1))]$$

em que  $\mathbf{a}(\Delta\nu(t, l))$  e  $\mathbf{a}(\Delta\xi(t, l))$  são os vetores de direção de azimute e elevação uniformemente espaçados do  $t$ -ésimo estágio de rotação. Assim, considerando o menor espaçamento

obtido nas equações (7) e (8) como sendo, respectivamente,  $\frac{2}{N_{Az}}$  e  $\frac{2}{N_{El}}$ , o intervalo nas sucessivas rotações é dado por:

$$\Delta\nu(t) = \frac{1}{\rho^{t-1}} \left[ \frac{-1}{N_{Az}} + \frac{2l}{N_{Az}(P-1)} \right], \quad l=0, 1, \dots, (P-1) \quad (13)$$

$$\Delta\xi(t) = \frac{1}{\rho^{t-1}} \left[ \frac{-1}{N_{El}} + \frac{2l}{N_{El}(P-1)} \right], \quad l=0, 1, \dots, (P-1) \quad (14)$$

em que  $\rho = \left[ \frac{|P-3|+(P-3)}{2} + 2 \right]$  define o intervalo dos ângulos considerados no  $t$ -ésimo estágio,  $P$  é a quantidade de pontos (ângulos) por dimensão (azimute e elevação) em cada um dos  $t$  estágios de rotação de fase e  $t=1, \dots, N_{rot}$ . Note que a cada estágio, os intervalos e os ângulos considerados serão cada vez menores e que as rotações são cumulativas. Contudo, a rotação deve ser aplicada somente aos elementos ativos da RIS, de modo que as rotações são realizadas pelas matrizes equivalentes  $\mathbf{R}_{eq}^{[t]} = \mathbf{W}\mathbf{R}^{[t]}$ .

Esse conjunto de rotações é aplicado ao melhor suporte da matriz de amostragem do estágio  $t-1$ , formando assim uma nova matriz de amostragem (linha 7). Em seguida, busca-se o índice do melhor suporte para esta nova matriz de amostragem e o processo é repetido até alcançar o estágio  $N_{rot}$ .

Na linha 12, a matriz  $\Lambda$  armazena o resultado final da busca pelo melhor suporte da  $k$ -ésima iteração e calcula-se os respectivos ganhos para a representação esparsa do canal (linha 13). O resíduo é atualizado (linha 14) e sua norma, que é usada para condição de parada, é calculada em seguida (linha 15). Uma nova iteração se inicia até que alguma das condições de parada seja alcançada, quando então é calculado na saída do algoritmo o canal estimado,  $\hat{\mathbf{h}}$ , com base na representação esparsa, dicionário original e rotações utilizadas para os refinamentos.

Note ainda que o OMP-PR é um caso particular do OMP-SR, em que  $N_{rot} = 1$ .

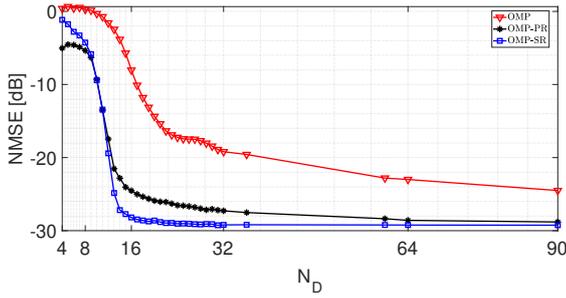
#### V. SIMULAÇÕES E RESULTADOS

Nesta seção, o desempenho das técnicas em termos de *Normalised Mean Square Error* NMSE =  $\frac{\|\hat{\mathbf{h}} - \mathbf{h}\|^2}{\|\mathbf{h}\|^2}$ , é obtido por simulações de Monte Carlo, utilizando  $10^4$  realizações, número de pontos do dicionário por dimensão  $N_D = N_{Az} = N_{El}$  e as faixas dos possíveis ângulos de elevação e azimute são as mesmas de  $180^\circ$ . Em cada realização, os  $N_{ativ}$  elementos ativos foram selecionados aleatoriamente.

TABELA I: Parâmetros do sistema usados nas simulações

Parâmetro	Valor
Número de elementos RIS, $N_{RIS}$	256
Número de elementos ativos RIS, $N_{ativ}$	64
Número de rotações na matriz $\mathbf{R}^{[t]}$	$P_{SR,rot} = 4$ $P_{PR,rot} = 256$
Número de rotações, $N_{rot}$ (OMP-SR)	8
Frequência da portadora, $f_c$	28 GHz
Espaçamento entre elementos, $d$	$\lambda/2$
Número máximo de iterações, $I_{max}$	10
Ângulos de azimute, $\phi_l$	$\mathcal{U}(-\pi/2, \pi/2)$
Ângulos de elevação, $\theta_l$	$\mathcal{U}(0, \pi)$
Número de palavras por dimensão no dicionário ( $N_D = N_{Az} = N_{El}$ )	20 ou 32

Com relação às rotações, para o OMP-PR foi adotada a configuração descrita em [10], com 16 pontos por dimensão


 Fig. 2: NMSE por  $N_D$ , com  $L = 2$  e  $SNR = 30$ .

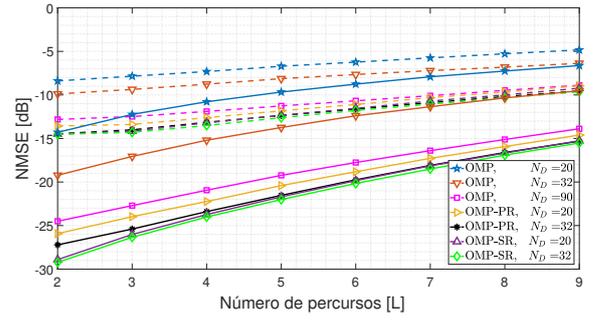
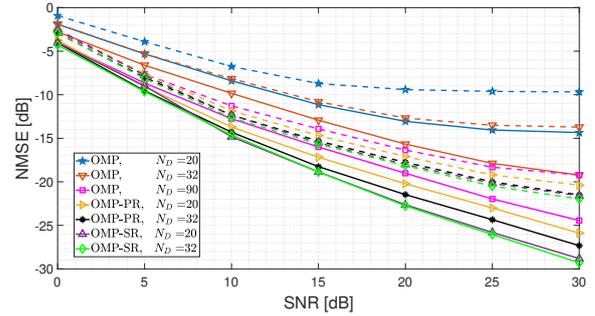
(azimute e elevação), totalizando  $P_{PR,rot} = 256$  combinações na criação de  $\mathbf{R}^{[1]}$ , que possui dimensão  $N_{ativ} \times P_{PR,rot}$ . Dado que em cada estágio de rotação o OMP-SR se beneficia ao utilizar um melhor suporte, é natural tentar maximizar o número de estágios. Nesse sentido e com a ideia de minimizar o custo por estágio de rotação, adotou-se  $P = 2$  pontos por dimensão, resultando em  $P_{SR,rot} = 4$  combinações e matrizes  $\mathbf{R}_{eq}^{[t]}$  de dimensão  $N_{ativ} \times P_{SR,rot}$ . Assim, de modo a manter uma comparação justa com o OMP-PR, adotamos  $N_{rot} = 8$ , pois são considerados  $P \cdot N_{rot} = 16$  ângulos por dimensão no OMP-SR, que é o mesmo valor adotado no OMP-PR. Note que ainda assim o OMP-SR calcula os suportes para apenas  $P_{SR,rot} N_{rot} = 32$  pontos, ao invés dos 256 do OMP-PR, reduzindo o custo computacional.

#### A. Análise do Desempenho

A Figura 2 ilustra a influência do número de pontos do *grid* do dicionário nas simulações para  $L = 2$  percursos e  $SNR = 30$  dB, com  $N_D$  variando de 4 a 90. Observa-se que a NMSE reduz com o aumento de  $N_D$  até um limite específico para cada técnica. O OMP-SR apresenta o melhor desempenho, atingindo a menor NMSE com cerca de  $N_D = 20$ , além do qual não há melhorias significativas. Também adotaremos  $N_D = 32$ , que representa comportamento equivalente para o OMP-PR. Por fim, note que mesmo com  $N_D = 90$ , o OMP ainda não atinge o mesmo desempenho alcançado pelo OMP-SR, com  $N_D = 20$  e do OMP-PR, com  $N_D = 32$ .

Já a Figura 3 mostra o desempenho das técnicas para  $SNR$  de 10 dB (linha tracejada) e 30 dB (linha contínua), com  $L$  variando de 2 a 9. O OMP-SR, com  $N_D = 20$ , oferece o melhor custo-benefício, atingindo desempenho praticamente igual ao de  $N_D = 32$ , mas com menor complexidade. Já o OMP-PR só se aproxima ou iguala o desempenho do OMP-SR com  $N_D = 20$  quando é utilizado  $N_D = 32$ , ou para valores mais elevados de  $L$ . Para  $N_D = 20$ , o OMP-PR fica de 1 a 3 dB aquém do OMP-SR. Além disso, OMP-PR e OMP-SR superam largamente o OMP convencional, mesmo quando este utiliza  $N_D = 90$ , acarretando complexidade muito superior a ambos como será visto a seguir.

Por fim, a Figura 4 apresenta os resultados de NMSE para  $L = 2$  e 5, com  $SNR$  variando de 0 a 30 dB. Observa-se um comportamento semelhante ao da Figura 3, onde o OMP-SR com  $N_D = 20$  se destaca como a técnica que melhor concilia complexidade e desempenho, obtendo uma vantagem superior a 3 dB em relação ao OMP-PR no caso com  $L = 2$ .


 Fig. 3: NMSE para  $L$  variando de 2 a 9 percursos com  $SNR = 10$  dB (tracejado) e  $SNR = 30$  dB (linha contínua)

 Fig. 4: NMSE para  $SNR$  variando de 0 a 30 dB, com  $L = 2$  (linha contínua) e  $L = 5$  (tracejada).

#### B. Análise da Complexidade Computacional

A complexidade computacional é analisada em termos do número de operações de ponto flutuante (FLOPS). É assumido que multiplicações e somas reais ou complexas possuem o mesmo custo computacional e que operadores de transposição, Hermitiano, conjugado e parte real não demandam FLOPS.

No caso do OMP-SR, a operação  $\mathbf{R}^{[1]}(:, \mathcal{R}^{[1]}) \odot \dots \odot \mathbf{R}^{[N_{rot}]}(:, \mathcal{R}^{[N_{rot}]})$  pode ser pré-calculada, trocando complexidade por memória. Para os parâmetros escolhidos, faz-se necessário aproximadamente 200 MB de memória, algo factível para qualquer sistema atual.

Os valores de FLOPS foram calculados com base em [10] e [14] e estão disponíveis na Tabela II. Foi definido que  $S_F$  é o número de iterações até que a condição de parada seja alcançada.

Para realizar a comparação do número de FLOPS entre as técnicas, é apresentado na Figura 5 o número médio de iterações até que a condição de parada seja alcançada ( $S_F$ ) em função da  $SNR$  para  $L = 2$  e  $L = 5$ . Note que devido às flutuações de potências dos coeficientes do canal e pela presença do ruído, o número médio de iterações até a parada pode ficar abaixo de  $L$ . Por outro lado, quando a  $SNR$

 TABELA II: Número de flops para  $k = 1$  até  $S_F$  iterações dos algoritmos de CE.

Algoritmo	Número de operações
OMP	$S_F \cdot [N_D^2 (2 \cdot N_{ativ} + 1) + 2] + 2N_{ativ} \sum_{k=1}^{S_F} (k^2 + k + 1) - \frac{2}{3} \sum_{k=1}^{S_F} (k^3) + N_{ativ} (2S_F - 1)$
OMP-PR	$OMP + S_F [(3N_{ativ} + 1)P_{PR,rot} + N_{ativ}]$
OMP-SR	$OMP + S_F [(3N_{ativ} + 1)N_{rot}P_{SR,rot} + N_{ativ}]$

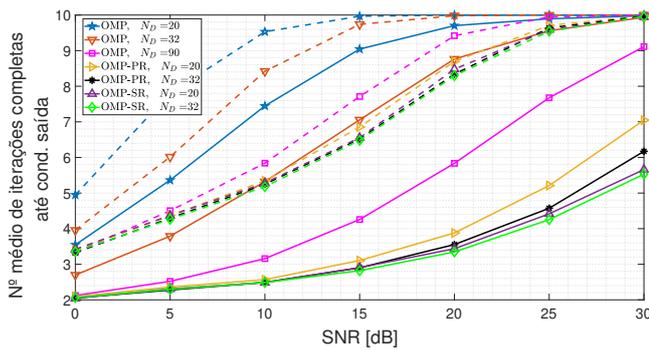


Fig. 5: Número médio de iterações completas dos algoritmos por SNR para  $L = 2$  percursos (linha contínua) e  $L = 5$  percursos (linha tracejada)

umenta, devido à finitude dos dicionários, o algoritmo tende a realizar mais iterações, se aproximando do número máximo  $I_{max} = 10$ . Fica claro também que tanto o OMP-PR como o OMP-SR alcançam a condição de parada muito antes do OMP, mesmo quando este usa  $N_D = 90$  que ainda assim resulta em desempenho inferior aos demais.

Assim, os valores de  $S_F$ , obtidos na Fig. 5, foram usados para cálculo dos FLOPS de cada técnica (Tabela II), gerando as Figuras 6a e 6b para  $L = 2$  e  $L = 5$ , respectivamente. Na primeira, percebe-se que o OMP possui, na maior parte dos casos, a maior complexidade média, apesar de ter a menor complexidade por iteração. A única exceção é para alta SNR e  $N_D = 32$ , quando o OMP-PR passa a ter maior complexidade. Já no segundo caso, com  $L = 5$ , o OMP passa a ter menor complexidade que o OMP-PR para médias SNRs e que o OMP-SR para altas SNRs. Contudo, é preciso lembrar que o desempenho do OMP em todas as condições é bem inferior ao OMP-PR e OMP-SR. Quando se usa  $N_D = 90$  no OMP para ter um desempenho mais próximo do OMP-PR e SR, a complexidade do OMP passa a ser de praticamente uma ordem de grandeza acima de ambos.

Já em relação ao OMP-PR e o OMP-SR, este apresenta redução de complexidade entre 23%, quando  $N_D = 32$ , a até 50%, quando  $N_D = 20$ . Todavia, é importante lembrar que o OMP-SR, com  $N_D = 20$ , apresenta praticamente o mesmo desempenho do OMP-PR, com  $N_D = 32$ . Neste caso, a redução da complexidade gira em torno de 66% a 74%, demonstrando a expressiva redução da complexidade da técnica proposta.

## VI. CONCLUSÕES

Este artigo propõe o algoritmo denominado OMP-SR para estimação de canal utilizando amostragem compressiva e uma RIS híbrida, na qual alguns elementos são capazes de demodular o sinal recebido. A técnica proposta inova sobre a técnica OMP-PR ao utilizar diversos estágios de rotações com sucessivos refinamentos da solução obtida em cada um destes. Isto permite um uso mais efetivo das rotações, propiciando melhor desempenho e menor complexidade. Diversas simulações comparam ambas as técnicas com um mesmo número de rotações. Os resultados permitem mostrar o ganho de desempenho, particularmente quando se utiliza menores dicionários.

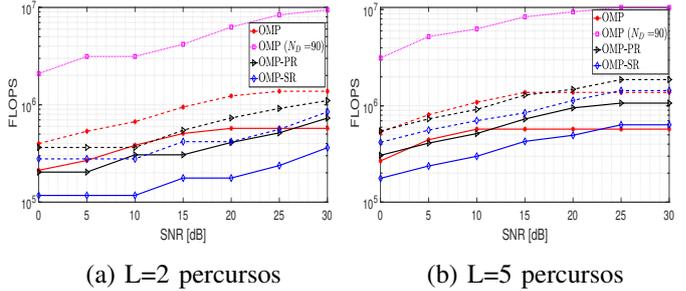


Fig. 6: FLOPS por SNR para  $N_D = 20$  (linha contínua),  $N_D = 32$  (tracejado) e OMP com  $N_D = 90$  (pontilhado)

Já a avaliação da complexidade para um mesmo tamanho de dicionário mostra que a técnica proposta é 23% a 50% mais eficiente que o OMP-PR. Contudo, o OMP-SR consegue alcançar o mesmo desempenho do OMP-PR utilizando um menor dicionário e, neste caso, a redução da complexidade chega a ser de até 74%, demonstrando a efetividade da técnica proposta.

## REFERÊNCIAS

- [1] A. Taha, M. Alrabeiah, and A. Alkhateeb, "Enabling large intelligent surfaces with compressive sensing and deep learning," *IEEE Access*, vol. 9, pp. 44 304–44 321, 2021.
- [2] Y. Han, W. Tang, X. Li, M. Matthaiou, and S. Jin, "CSI acquisition in RIS-assisted mobile communication systems," *National Science Review*, vol. 10, no. 8, p. nwad127, 05 2023.
- [3] P. Wang, J. Fang, H. Duan, and H. Li, "Compressed channel estimation for intelligent reflecting surface-assisted millimeter wave systems," *IEEE Signal Processing Letters*, vol. 27, pp. 905–909, 2020.
- [4] Y. Liu, X. Liu, X. Mu, T. Hou, J. Xu, M. Di Renzo, and N. Al-Dhahir, "Reconfigurable intelligent surfaces: Principles and opportunities," *IEEE Comm. Surveys & Tutorials*, vol. 23, no. 3, pp. 1546–1577, 2021.
- [5] D. W. Marques Guerra and T. Abrão, "RIS-aided system channel estimation using NN," in *Symp. on Internet of Things, 2022*, pp. 1–4.
- [6] G. C. Alexandropoulos and E. Vlachos, "A hardware architecture for reconfigurable intelligent surfaces with minimal active elements for explicit channel estimation," in *IEEE Int. Conf. on Acoustics, Speech and Signal Proc. (ICASSP)*, 2020, pp. 9175–9179.
- [7] S. Liu, Z. Gao, J. Zhang, M. D. Renzo, and M.-S. Alouini, "Deep denoising neural network assisted compressive channel estimation for mmWave intelligent reflecting surfaces," *IEEE Transactions on Vehicular Technology*, vol. 69, no. 8, pp. 9223–9228, 2020.
- [8] X. Wei, D. Shen, and L. Dai, "Channel estimation for RIS assisted wireless communications—part ii: An improved solution based on double-structured sparsity," *IEEE Communications Letters*, vol. 25, no. 5, pp. 1403–1407, 2021.
- [9] C. K. Anjinappa, A. C. Gürbüz, Y. Yapici, and I. Güvenç, "Off-grid aware channel and covariance estimation in mmwave networks," *IEEE Transactions on Communications*, vol. 68, no. 6, pp. 3908–3921, 2020.
- [10] D. W. M. Guerra, T. Abrão, and E. Hossain, "Channel estimation in RIS-aided mmWave wireless systems using matching pursuit with phase rotation," *IEEE Trans. on Wireless Communications*, pp. 1–1, 2024.
- [11] A. Alkhateeb, O. El Ayach, G. Leus, and R. W. Heath, "Channel estimation and hybrid precoding for millimeter wave cellular systems," *IEEE Journal of Selected Topics in Signal Processing*, vol. 8, no. 5, pp. 831–846, 2014.
- [12] Y. You, Y. Xue, L. Zhang, X. You, and C. Zhang, "Channel estimation for ris assisted millimeter wave systems via OMP with optimization," *IEEE Transactions on Vehicular Technology*, vol. 72, no. 12, pp. 16 783–16 787, 2023.
- [13] J. Tropp, "Greed is good: algorithmic results for sparse approximation," *IEEE Trans. on Inf. Theory*, vol. 50, no. 10, pp. 2231–2242, 2004.
- [14] L. Trefethen and D. Bau, *Numerical Linear Algebra*. Society for Industrial and Applied Mathematics, 1997.