

Otimização Conjunta e Escalável para Open RAN: Associação UE/O-RU e Posicionamento de VNFs

Jonathas dos Santos, Fernanda de Castro Fernandes, Marcos Antônio de Sousa, Flávio Geraldo Coelho Rocha

Resumo—A O-RAN surge como uma arquitetura promissora para redes móveis escaláveis, porém, sua desagregação em VNFs impõe desafios significativos quanto à orquestração dessas unidades distribuídas. Este trabalho propõe uma estrutura unificada para otimização conjunta da associação UE/O-RU e do posicionamento de O-DU e O-CU, considerando requisitos de QoS de múltiplas fatias. O problema é inicialmente formulado como um modelo ILP e, em seguida, resolvido por uma abordagem baseada em aprendizado por reforço profundo. Os resultados indicam ganhos de até 20% na taxa de admissão de usuários, melhor equidade entre fatias e maior eficiência no uso de recursos, evidenciando robustez e aplicabilidade prática em cenários de larga escala.

Palavras-Chave—Open RAN, Admissão de usuários, Posicionamento, Fatias de rede, Otimização, Aprendizado por reforço profundo.

Abstract—O-RAN has emerged as a promising architecture for scalable mobile networks, however, its disaggregation into VNFs poses significant challenges in orchestrating these distributed units. This work proposes a unified framework for the joint optimization of UE/O-RU association and O-DU and O-CU placement, considering QoS requirements of multiple network slices. The problem is initially formulated as an ILP model and subsequently addressed using a deep reinforcement learning-based approach. The results indicate gains of up to 20% in user admission ratio, improved fairness among slices, and more efficient resource utilization, demonstrating robustness and practical applicability in large-scale scenarios.

Keywords—Open RAN, User Admission, Placement, Network Slicing, Optimization, Deep Reinforcement Learning.

I. INTRODUÇÃO

A evolução das redes móveis de quinta geração (*Fifth-Generation* (5G)), bem como sua progressão para *Beyond 5G* (B5G), tem impulsionado uma transformação fundamental nas comunicações sem fio, caracterizada por requisitos cada vez mais rigorosos de Qualidade da Experiência (*Quality of Experience* (QoE)) e pela necessidade de otimizar conjuntamente diversos Índices de Desempenho (*Key Performance Indicators* (KPIs)). Para lidar com essas complexidades, as arquiteturas de Rede de Acesso Rádio de Nova Geração (*Next Generation Radio Access Networks* (NG-RANs)) têm adotado, de forma crescente, princípios como inteligência, virtualização, desagregação e interfaces abertas como pilares de projeto [1].

A arquitetura de Rede de Acesso Rádio Aberta (*Open Radio Access Network* (O-RAN)), proposta pela O-RAN Alliance, oferece uma estrutura aberta e multi-fornecedor que permite

implantações modulares e programáveis da Rede de Acesso Rádio (*Radio Access Network* (RAN)) [2]. A O-RAN introduz uma desagregação funcional da Estação Rádio Base (*Next Generation Node B* (gNB)) em três componentes interoperáveis: Unidade de Rádio Aberta (*Open Radio Unit* (O-RU)), Unidade Distribuída Aberta (*Open Decentralized Unit* (O-DU)) e Unidade Centralizada Aberta (*Open Centralized Unit* (O-CU)). Esses componentes são implementados como Funções de Rede Virtualizadas (*Virtualized Network Functions* (VNFs)) ou Funções de Rede Containerizadas (*Containerized Network Functions* (CNFs)) e instanciados sobre infraestruturas distribuídas na nuvem *O-Cloud*. A desagregação da rede permite que operadoras utilizem um ecossistema heterogêneo de hardware e software de múltiplos fornecedores, promovendo interoperabilidade, estimulando a inovação e contribuindo para a redução de custos [1].

Na arquitetura *Open RAN*, a camada PHY é dividida em *low-PHY* e *high-PHY* por meio do chamado *split* funcional 7.2x. Enquanto a camada *low-PHY* é processada pela O-RU, as funcionalidades de *high-PHY*, *Medium Access Control* (MAC) e *Radio Link Control* (RRC) são alocadas na O-DU. As funções de camadas superiores, como *Packet Data Convergence Protocol* (PDCP) e *Service Data Adaptation Protocol* (SDAP), são processadas na O-CU. Na prática, as O-DUs e O-CUs podem ser implantadas dinamicamente em nuvens de borda e regionais, explorando o paradigma de *Edge Cloud* para aproximar os recursos computacionais dos usuários e, assim, reduzir a latência ponta a ponta (*End-to-End* (E2E)), o que é essencial para aplicações sensíveis a atraso [3].

O Fatiamento de Rede (*Network Slicing* (NS)) é outra tecnologia fundamental introduzida no 5G, permitindo que Operadoras de Rede Móvel (*Mobile Network Operators* (MNOs)) instanciem múltiplas redes lógicas sobre uma única infraestrutura física, cada uma configurada com recursos e políticas específicas para atender diferentes tipos de serviços [4]. Nesse cenário, as fatias de rede possibilitam suportar casos de uso como *enhanced Mobile BroadBand* (eMBB), voltado a aplicações com alta demanda de banda, *massive Machine Type Communications* (mMTC), associado a aplicações de *Internet-of-Things* (IoT) com tráfego esporádico e alta densidade de dispositivos, e *Ultra-Reliable and Low-Latency Communications* (URLLC), direcionado a aplicações críticas com requisitos rigorosos de latência e confiabilidade.

Entretanto, alcançar desempenho ótimo em um ambiente desagregado e virtualizado permanece um desafio significativo. Em particular, a otimização conjunta da admissão de usuários, da associação *User Equipment* (UE)/O-RU e do posicionamento dinâmico de O-DUs e O-CUs deve considerar condições de rede variáveis, requisitos heterogêneos de

Qualidade de Serviço (*Quality of Service* (QoS)) e limitações de recursos computacionais na infraestrutura de nuvem [5]. A natureza fortemente acoplada dessas decisões torna o problema intrinsecamente complexo e de difícil resolução por métodos tradicionais, especialmente em cenários de larga escala.

Este trabalho aborda o problema de maximizar a taxa de admissão de usuários em redes O-RAN, assegurando simultaneamente o atendimento de Acordos de Nível de Serviço (*Service Level Agreements* (SLAs)). Para isso, considera o posicionamento flexível das unidades funcionais virtualizadas da *Open* RAN, o que introduz desafios adicionais decorrentes da interação entre alocação de recursos, restrições de latência e capacidade computacional distribuída. A abordagem proposta adota uma estratégia de implantação flexível alinhada com os Cenários A e B ilustrados na Fig. 1, considerando o *split* funcional 7.2x entre O-RU e O-DU, bem como o *split* opção 2 entre O-DU e O-CU. No Cenário A, tanto O-DUs quanto O-CUs são implantadas na borda, enquanto no Cenário B as O-DUs permanecem na borda e as O-CUs são instanciadas na nuvem regional [1], [2].

A análise do estado da arte evidencia que grande parte dos trabalhos existentes trata apenas subconjuntos do problema em análise [6], [7]. Em geral, observa-se foco em posicionamento estático de funções, políticas simplificadas de associação UE/O-RU ou configurações fixas de posicionamento de unidades funcionais. Além disso, o fatiamento de rede é frequentemente abordado de forma isolada, desconsiderando sua interação com restrições físicas de alocação de recursos e capacidade computacional.

Para suprir essa lacuna, propõe-se neste trabalho uma estrutura unificada para redes O-RAN com suporte a NS, no qual são tratadas de forma conjunta as decisões de associação UE/O-RU e posicionamento de O-DUs e O-CUs. O modelo incorpora restrições de latência (*Fronthaul* (FH)/*Midhaul* (MH)), capacidades heterogêneas de processamento e requisitos específicos de cada fatia, permitindo uma representação mais fiel do sistema.

O problema é formulado como um modelo de Programação Linear Inteira (*Integer Linear Programming* (ILP)), cuja solução ótima apresenta baixa escalabilidade. Como alternativa, utiliza-se Aprendizado por Reforço Profundo (*Deep Reinforcement Learning* (DRL)), por meio de um agente *Double Deep Q-Network* (DDQN), permitindo obter soluções subótimas com desempenho próximo ao ótimo, porém com maior escalabilidade e menor tempo de processamento.

II. MODELAGEM DO SISTEMA

O sistema consiste em um conjunto $\mathcal{B}$ de O-RUs distribuídas em uma área quadrada de lado L , tal que cada O-RU $b \in \mathcal{B}$ está localizada em uma posição $P_b = (X_b, Y_b) \in [0, L]^2$. Um conjunto $\mathcal{U}$ de UEs é distribuído arbitrariamente nas áreas de cobertura das O-RUs, sendo cada UE $u \in \mathcal{U}$ posicionado em $P_u = (X_u, Y_u) \in [0, L]^2$.

A infraestrutura de *O-Cloud* é modelada como um grafo $G = (\mathcal{H}, E)$, em que $\mathcal{H}$ representa o conjunto de nós (*hosts*) e E o conjunto de enlaces físicos entre nós adjacentes. O conjunto $\mathcal{H}$ é particionado em dois domínios de acordo com




Fig. 1. Cenários de implantação O-RAN.

a proximidade em relação à RAN: *hosts* de borda $\mathcal{H}_E$ e *hosts* da nuvem regional $\mathcal{H}_R$, sendo que $\mathcal{H} = \mathcal{H}_E \cup \mathcal{H}_R$. Cada *host* $h \in \mathcal{H}$ possui uma localização espacial definida: se $h \in \mathcal{H}_E$, então $P_h \in [L, L']^2$; caso contrário, se $h \in \mathcal{H}_R$, então $P_h \in [L'', L''']^2$. Cada O-RU pode se conectar a qualquer *host* de borda.

Cada UE solicita o provisionamento de um serviço de comunicação pertencente a um conjunto predefinido de fatias de rede $\mathcal{L}$. Cada fatia $\sigma \in \mathcal{L}$ possui requisitos de QoS definidos em termos de (i) taxa de dados (vazão) e (ii) latência fim a fim (E2E). Um UE é admitido no sistema somente se os requisitos de QoS da fatia solicitada puderem ser atendidos.

A. Problema Conjunto de Associação UE/O-RU e Posicionamento de O-CU/O-DU

O problema conjunto de associação de usuários e posicionamento de unidades funcionais é formulado como um modelo ILP. As notações são apresentadas na Tabela I. A modelagem detalhada das especificidades do sistema e que influenciam o seu provisionamento é descrita em [8], cujas premissas estão alinhadas com os trabalhos correlatos [9], [10].

$$\max_{\mathbf{x}, \rho} \sum_{u \in \mathcal{U}} \sum_{b \in \mathcal{B}} \sum_{h, h' \in \mathcal{H}} \epsilon_{\sigma(u)} \Phi_{ubhh'} \quad (1)$$

Sujeito a:

$$\Phi_{ubhh'} \geq x_{u,h}^{DU} + x_{u,h'}^{CU} + x_{u,b}^{RU} - 2, \forall h, h' \in \mathcal{H}, b \in \mathcal{B}, u \in \mathcal{U} \quad (2)$$

$$\Phi_{ubhh'} \leq \frac{x_{u,h}^{DU} + x_{u,h'}^{CU} + x_{u,b}^{RU}}{3}, \forall h, h' \in \mathcal{H}, b \in \mathcal{B}, u \in \mathcal{U} \quad (3)$$

$$\sum_{h, h' \in \mathcal{H}} \Phi_{uhh'} = \sum_{b \in \mathcal{B}} x_{u,b}^{RU}, \forall u \in \mathcal{U} \quad (4)$$

$$\Phi_{uhh'} \geq x_{u,h}^{DU} + x_{u,h'}^{CU} - 1, \forall h, h' \in \mathcal{H}, u \in \mathcal{U} \quad (5)$$

TABELA I
NOTAÇÕES

Símbolo	Descrição
$\mathcal{U}, u$	Conjunto e índice de equipamentos de usuário (UEs).
$\mathcal{B}, b$	Conjunto e índice de O-RUs.
$\mathcal{H}, h$	Conjunto e índice de <i>hosts</i> O-Cloud (borda/regional).
$\mathcal{H}_E, \mathcal{H}_R$	Partições de <i>hosts</i> de borda e regionais de $\mathcal{H}$ (i.e., $\mathcal{H} = \mathcal{H}_E \cup \mathcal{H}_R$).
$\mathcal{L}, \sigma$	Conjunto e índice de fatias de rede (fatia σ).
M_b	Número total de RBs disponíveis na O-RU b .
λ_σ	Taxa de dados requerida (vazão) para a fatia σ .
$\eta_{u,b}$	Taxa de dados por RB para o UE u na O-RU b .
G_h	Capacidade de processamento (<i>Giga Operations Per Second</i> (GOPS)) do <i>host</i> h .
D_u^{MH}	Atraso máximo permitido de MH para o UE u .
D_u^{FH}	Atraso máximo permitido de FH para o UE u .
$x_{u,b}^{RU}$	Variável binária: $x_{u,b}^{RU} = 1$ se o UE u está associado à O-RU b , caso contrário 0.
$x_{u,h}^{DU}$	Variável binária: $x_{u,h}^{DU} = 1$ se a O-DU do UE u está alocada no <i>host</i> h , caso contrário 0.
$x_{u,h}^{CU}$	Variável binária: $x_{u,h}^{CU} = 1$ se a O-CU do UE u está alocada no <i>host</i> h , caso contrário 0.
$\Phi_{u,h,h'}$	Variável binária: $\Phi_{u,h,h'} = 1$ se O-DU e O-CU do UE u estão nos <i>hosts</i> h, h' , caso contrário 0.
$\Phi_{u,b,h,h'}$	Variável binária: $\Phi_{u,b,h,h'} = 1$ se o UE u está associado à O-RU b e alocado nos <i>hosts</i> h, h' (O-DU, O-CU), caso contrário 0.
$\rho_{b,\sigma}$	Variável inteira: número de RBs na O-RU b alocados para a fatia σ .
ϵ_σ	Peso de prioridade da fatia σ .

$$\Phi_{u,h,h'} \leq \frac{x_{u,h}^{DU} + x_{u,h'}^{CU}}{2}, \forall h, h' \in \mathcal{H}, u \in \mathcal{U} \quad (6)$$

$$\sum_{h \in \mathcal{H}_R} x_{u,h}^{DU} = 0, \forall u \in \mathcal{U} \quad (7)$$

$$\sum_{\sigma \in \mathcal{L}} \rho_{b,\sigma} \leq M_b, \forall b \in \mathcal{B} \quad (8)$$

$$RB_u(\mathbf{x}^{RU}) \leq \rho_{b,\sigma}, \forall b \in \mathcal{B}, \sigma \in \mathcal{L} \quad (9)$$

$$g_h(\mathbf{x}^{RU}) \leq G_h, \forall h \in \mathcal{H} \quad (10)$$

$$d_u^{MH}(\mathbf{x}) \leq D_u^{MH}, \forall u \in \mathcal{U} \quad (11)$$

$$d_u^{FH}(\mathbf{x}) \leq D_u^{FH}, \forall u \in \mathcal{U} \quad (12)$$

A função objetivo (1) busca maximizar o número de usuários admitidos, ponderado pela prioridade $\epsilon_{\sigma(u)}$ da fatia $\sigma(u)$ requisitada por cada UE. As variáveis auxiliares $\Phi_{u,b,h,h'}$ e $\Phi_{u,h,h'}$, conceitualmente definidas como $\Phi_{u,b,h,h'} = x_{u,b}^{RU} \cdot x_{u,h}^{DU} \cdot x_{u,h'}^{CU}$ e $\Phi_{u,h,h'} = x_{u,h}^{DU} \cdot x_{u,h'}^{CU}$, são linearizadas por meio das restrições (2), (3), (5) e (6), permitindo que o modelo capture conjuntamente a associação UE/O-RU e o posicionamento de O-CU/O-DU, ao mesmo tempo em que preserva a estrutura linear do ILP.

A restrição (4) assegura que cada UE admitido esteja associado a exatamente uma combinação válida de O-RU, O-DU e O-CU. Considerando os requisitos de latência definidos em [11], a restrição (7) impõe que as O-DUs sejam posicionadas exclusivamente na borda (*edge cloud*), enquanto as O-CUs podem ser instanciadas tanto na borda quanto na nuvem regional.

As restrições de alocação de recursos de rádio são modeladas por (8) e (9). A restrição (8) garante que o total de blocos de recursos (RBs) alocados por cada O-RU não exceda

sua capacidade M_b , enquanto (9) assegura que a demanda de RB de cada UE admitido seja atendida dentro da alocação da respectiva fatia.

A restrição (10) limita a carga computacional total em cada *host* h à sua capacidade G_h , garantindo a viabilidade do posicionamento das funções virtualizadas. Por fim, as restrições (11) e (12) asseguram que os atrasos de MH e FH de cada usuário permaneçam dentro dos limites toleráveis, atendendo aos requisitos de SLA. A solução ótima do sistema é representada por $\mathbf{x}^*$ (variáveis de associação e posicionamento) e ρ^* (quantidade de RBs).

III. SOLUÇÃO DO PROBLEMA VIA DRL

A complexidade computacional do modelo de otimização da Seção II cresce rapidamente com o aumento do número de usuários na rede, limitando sua aplicabilidade em cenários O-RAN de grande porte. Para contornar essa limitação, é proposta uma estrutura baseada em DDQN-DRL. Ao incorporar, no processo de aprendizado, tanto a alocação de recursos sensível a fatias quanto o posicionamento dinâmico de O-CU/O-DU, o agente DDQN é capaz de aprender políticas escaláveis que respeitam restrições de latência fim a fim, isolamento entre fatias e limites de capacidade computacional das unidades virtualizadas.

A. Processo de Decisão

O agente DDQN interage continuamente com o ambiente e recebe recompensas associadas às ações executadas, que incluem decisões de associação UE/O-RU e posicionamento de O-CU/O-DU. O sistema é modelado como um *Markov Decision Process (MDP)* totalmente observável, definido pela tupla $\langle \mathcal{S}, \mathcal{A}, P, r \rangle$, em que $\mathcal{S}$ representa o espaço de estados, $\mathcal{A}$ o espaço de ações, $P(s' | s, a)$ a probabilidade de transição e r a função de recompensa [12].

O estado $s \in \mathcal{S}$ descreve a configuração atual da rede, incluindo associações, posicionamentos, alocação de recursos e métricas de desempenho:

$$s = \{x_{u,r}^{RU}, x_{u,h}^{DU}, x_{u,h}^{CU}, \rho_{r,s}, g_h(\mathbf{x}^{RU}), d_u^{MH}(\mathbf{x}), d_u^{FH}(\mathbf{x})\} \quad (13)$$

A ação $a \in \mathcal{A}$ corresponde às decisões de associação e posicionamento:

$$a = \{a_{u,r}^{RU}, a_{u,h}^{DU}, a_{u,h}^{CU}\}. \quad (14)$$

A função de recompensa prioriza a admissão de usuários, conforme função objetivo (1) do ILP, bonifica as ações (*Bon_i*) que respeitam SLA e penaliza aquelas que causam violação de restrições (*Pen_k*):

$$r = \sum_{u \in \mathcal{U}} \epsilon_{n_s(u)} \cdot \mathbb{I}[\text{UE admitido}] + \alpha_i \text{Bon}_i - \beta_k \text{Pen}_k. \quad (15)$$

B. Estrutura do DRL

O agente interage com o ambiente em instantes discretos, observando o estado s , executando uma ação a e recebendo uma recompensa r , formando a tupla (s, a, r, s') . O objetivo

é aprender uma política π que maximize a recompensa acumulada descontada:

$$R = \mathbb{E} \left[\sum_{t=0}^T \gamma^t r_t(s_t, a_t) \right]. \quad (16)$$

Métodos baseados em valor são empregados para estimar a função:

$$Q^\pi(s, a) = \mathbb{E}_\pi \left[\sum_{t=0}^T \gamma^t r_t(s_t, a_t) \middle| s_0 = s, a_0 = a \right], \quad (17)$$

cujas versão ótima é obtida através das equações de otimalidade de Bellman:

$$Q^*(s, a) = r(s, a) + \gamma \sum_{s'} P(s'|s, a) \max_{a'} Q^*(s', a'). \quad (18)$$

A política ótima é então derivada como:

$$\pi^*(s) = \arg \max_a Q^*(s, a). \quad (19)$$

C. Agente DDQN

Devido ao grande espaço de estados e de ações, a função Q é aproximada por Redes Neurais Profundas (*Deep Neural Networks* (DNNs)). O algoritmo *Deep Q-Network* (DQN) utiliza uma rede principal e uma rede alvo, com memória de repetição. Para reduzir o viés de superestimação do DQN, adota-se o agente DDQN [13], no qual a seleção e avaliação das ações são desacopladas. Alvo do DDQN é definido por:

$$Y_{\text{DDQN}} = r + \gamma Q(s', \arg \max_{a'} Q(s', a'; \theta), \theta^-). \quad (20)$$

Os parâmetros da rede são atualizados por descida de gradiente:

$$\theta \leftarrow \theta + \delta (Y_{\text{DDQN}} - Q(s, a; \theta)) \nabla_\theta Q(s, a; \theta). \quad (21)$$

IV. AVALIAÇÃO DE DESEMPENHO

A. Cenário de Simulação

O ambiente de simulação considera um cenário O-RAN composto por 4 O-RUs distribuídas em uma área industrial quadrada com lado $L = 1$ km. Os UEs estão distribuídos aleatoriamente dentro da área definida e pertencem a diferentes tipos de aplicação: eMBB (25%), URLLC (25%) e mMTC (50%). Para refletir requisitos diferenciados de serviço, as fatias eMBB e URLLC recebem pesos de prioridade mais elevados em relação à mMTC. A Tabela II apresenta a configuração em nível de sistema do cenário O-RAN considerado.

O *benchmark* de qualidade da solução é obtido pela resolução do modelo ILP (Seção II), escrito em Python e solucionado com o *solver IBM Cplex* [14]. O conjunto de hiperparâmetros do DDQN proposto é apresentado na Tabela III. As suas fases de treinamento e inferência foram implementadas em Python com a biblioteca *PyTorch* [15]. Como *baseline* para avaliar o potencial de escalabilidade do algoritmo DDQN proposto, especialmente em cenários com maior número de UEs, adota-se uma abordagem meta-heurística baseada em Algoritmos Genéticos (*Genetic Algorithm* (GA)). Os principais ajustes de hiperparâmetros do GA foram 600 gerações e população com 350 indivíduos. As simulações com o GA foram realizadas no ambiente Matlab, utilizando sua *toolbox* de GA [16].

TABELA II
CONFIGURAÇÃO DA SIMULAÇÃO

Parâmetro	Valor
Número de O-RUs	4
Número de UEs	[4, 120]
Número de nós O-Cloud (Regional e Borda)	1, 3
Localização das O-RUs - [x,y] m	[250,250],[250,750], [750,250],[750,750]
Localização dos UEs - [x,y] m	<i>unifor</i> ([0,1000], [0,1000])
Distância entre nós Borda-Regional - km	<i>unifor</i> (5,10), <i>unifor</i> (40,80)
Capacidade dos nós Borda-Regional - GOPS	<i>unifor</i> (100,300), <i>unifor</i> (1000,2000)
Largura de banda - MHz	20
RBs disponíveis por TTI em cada O-RU	100
Potência de transmissão da O-RU - dBm	30
Prioridade (ϵ_σ) para eMBB, URLLC e mMTC	2, 2, 1
Taxa de dados (λ_σ) para eMBB, URLLC e mMTC - Mbps	20, 5, 1
Limite de atraso MH para eMBB, URLLC e mMTC - ms	0.5, 0.4, 1.0
Limite de atraso FH para eMBB, URLLC e mMTC - ms	1.0, 1.0, 1.0

TABELA III
HIPERPARÂMETROS DO DDQN

Hiperparâmetro	Valor
Taxa de aprendizado	0.0005
Política de exploração (ϵ -gulosa)	0.996
Taxa máxima de exploração ($\epsilon_{\max}$)	1
Taxa mínima de exploração ($\epsilon_{\min}$)	0.01
Fator de desconto (γ)	0.99
Número de episódios	4000
Máximo de passos por episódio	500
Tamanho da memória de repetição	100000
Tamanho do mini-lote	512
Intervalo de atualização da rede alvo	5000
Número de neurônios (camadas ocultas)	256
Otimizador	Adam
Função de ativação	ReLU

B. Resultados e Discussões

Nesta seção, investiga-se o desempenho dos modelos para diferentes densidades de usuários. Nas simulações, são empregadas as seguintes métricas de desempenho: taxa ponderada de admissão de UEs, correspondente ao valor da função objetivo, na equação (1) do ILP, e o *tradeoff* entre qualidade da solução, escalabilidade e tempo de execução computacional.

A Figura 2a apresenta a taxa de admissão em função do número total de usuários. Observa-se que todos os métodos sofrem degradação de desempenho à medida que a carga do sistema aumenta, devido à limitação de recursos de rádio e computacionais. A solução ILP, apesar de ótima, serviu como referência só até 20 UEs; para instâncias maiores, seu custo computacional tornou-se proibitivo. Entre as abordagens heurísticas, o método baseado em DRL supera consistentemente o GA, destacando-se sobretudo em cenários com mais de 80 UEs. Esse resultado indica maior capacidade de balancear recursos e demandas, considerando as prioridades das fatias. Em contraste, o GA apresenta degradação mais acentuada sob alta carga, evidenciando menor adaptabilidade.

A equidade na admissão entre os diferentes tipos de serviço também é um indicador relevante de desempenho. Conforme




Fig. 2. Resultados obtidos para a variação do número de usuários na O-RAN: (a) Taxa de admissão, (b) Índice de justiça e (c) Tempo de execução.

Figura 2b, em condições de baixa e média carga, todos os métodos apresentam índices próximos da unidade, indicando alocação equilibrada. Contudo, para cenários com mais de 70 UEs, observa-se degradação do índice de justiça, refletindo o impacto do congestionamento. Nessas condições, as abordagens baseadas em DRL mantêm níveis satisfatórios de equidade, mesmo priorizando eficiência global, enquanto o GA apresenta maior variabilidade e menor estabilidade nas decisões.

A Figura 2c apresenta o tempo de execução computacional das abordagens. O GA apresenta crescimento acentuado do tempo de execução com o aumento do número de usuários, indicando limitações de escalabilidade. Em contraste, o DRL mantém tempos significativamente menores e insensíveis ao aumento do número de usuários, refletindo à natureza inferencial do modelo treinado.

V. CONCLUSÕES

Este trabalho abordou o problema conjunto de associação de usuários e posicionamento das unidades funcionais O-CU e O-DU em um ambiente de rede compatível com a arquitetura *Open RAN*, considerando suporte a fatiamento de rede. O objetivo foi alcançar a maior quantidade de associações UEs/O-RUs, conjuntamente com a alocação eficiente das unidades funcionais virtualizadas (O-CUs e O-DUs) nos nós *O-Cloud*, respeitando restrições de recursos, capacidade computacional dos servidores e requisitos de QoS.

O problema foi modelado e resolvido por meio de uma formulação ILP, para obtenção de soluções ótimas, e de uma abordagem baseada em DRL, visando garantir escalabilidade e eficiência computacional. Avaliou-se o impacto da densificação de UEs no desempenho do sistema, considerando admissão de usuários, alocação de recursos e carga computacional nas O-DUs e O-CUs virtualizadas em *hosts O-Cloud*.

Os resultados demonstram que a abordagem baseada em DRL é capaz de aproximar o desempenho ótimo com significativa redução no tempo de processamento, apresentando escalabilidade superior em cenários de alta densidade. Em particular, os tempos de execução observados, entre 70 ms e 100 ms, estão dentro do ciclo de operação do O-RAN *near-Real Time - RAN Intelligent Controller (near-RT-RIC)*, indicando potencial para trabalhos futuros com enfoque prático.

AGRADECIMENTOS

Os autores agradecem ao Centro de Excelência em Redes Inteligentes Sem Fio e Serviços Avançados (CERISE) e à

Fundação de Amparo à Pesquisa do Estado de Goiás (FAPEG) pelo apoio e financiamento à pesquisa.

REFERÊNCIAS

- [1] M. Polese, L. Bonati, S. D'Oro, S. Basagni, and T. Melodia, "Understanding o-ran: Architecture, interfaces, algorithms, security, and research challenges," *IEEE Communications Surveys & Tutorials*, vol. 25, no. 2, pp. 1376–1411, 2023.
- [2] O-RAN Working Group 6, "O-ran cloud architecture and deployment scenarios for o-ran virtualized ran 4.0," O-RAN Alliance, Tech. Rep. O-RAN.WG6.CADS-v04.00, Oct. 2022, [Online]. Available: <https://orandownloadswb.azurewebsites.net/specifications>.
- [3] F. Gringoli, L. Cominardi, and A. Capone, "Flexible and efficient o-ran functional splits with open-source platforms," in *Proc. of ACM MobiCom Workshop on Open RAN (OpenRAN)*, 2023, pp. 1–6.
- [4] O-RAN WG1, "O-ran slicing architecture 13.0," O-RAN Alliance, Tech. Rep. O-RAN.WG1-Slicing Architecture-R003-v13.00, 2024.
- [5] F. Z. Morais, G. M. F. de Almeida, L. Pinto, K. V. Cardoso, L. M. Contreras, R. d. R. Righi, and C. B. Both, "Placeran: Optimal placement of virtualized network functions in beyond 5g radio access networks," *IEEE Transactions on Mobile Computing*, vol. 22, no. 9, pp. 5434–5448, 2023.
- [6] A. Ndao, X. Lagrange, N. Huin, G. Texier, and L. Nuaymi, "Optimal placement of virtualized dnf in o-ran architecture," in *2023 IEEE 97th Vehicular Technology Conference (VTC2023-Spring)*, 2023, pp. 1–6.
- [7] G. I. Ricardo, A. Benhamiche, N. Perrot, and Y. Carlinet, "Latency constrained task distribution in multi-access edge computing systems," in *2022 IEEE 11th International Conference on Cloud Networking (CloudNet)*, 2022.
- [8] M. A. de Sousa, F. G. C. Rocha, J. dos Santos, and F. de Castro Fernandes, "Recursos na borda: Otimização para o open ran usando programação inteira e algoritmos genéticos," in *Anais do XLIII Simpósio Brasileiro de Telecomunicações e Processamento de Sinais (SBrt 2025)*, 2025. [Online]. Available: <https://biblioteca.sbrt.org.br/articles/4992>
- [9] H. Hojeij, M. Sharara, S. Hoteit, and V. Vèque, "On flexible placement of o-cu and o-du functionalities in open-ran architecture," *IEEE Transactions on Network and Service Management*, vol. 22, no. 1, pp. 660–674, 2025.
- [10] H. Hojeij, G. I. Ricardo, M. Sharara, S. Hoteit, V. Vèque, and S. Secci, "Flexible association and placement for open-ran," in *IEEE INFOCOM 2024 - IEEE Conference on Computer Communications Workshops (INFOCOM WKSHPS)*, 2024, pp. 1–6.
- [11] O-RAN Alliance, "O-ran cloud architecture and deployment scenarios for o-ran virtualized ran 2.02," O-RAN Alliance, Tech. Rep., Feb. 2021, [Online]. Available: <https://orandownloadswb.azurewebsites.net/specifications>.
- [12] S. Chakraborty and K. Sivalingam, "Drl-based admission control and resource allocation for 5g network slicing," *Sādhanā*, vol. 48, p. 155, 2023. [Online]. Available: <https://doi.org/10.1007/s12046-023-02201-4>
- [13] S. Gengtian, J. Liu, and S. Shimamoto, "Deep q-network for optimizing noma-aided resource allocation in smart factories with urllc constraints," in *2025 IEEE Wireless Communications and Networking Conference (WCNC)*, 2025, pp. 1–6.
- [14] IBM Corporation, *User's Manual for CPLEX*, 2022, cplex-22.1.2.0.
- [15] A. Zhang, Z. C. Lipton, M. Li, and A. J. Smola, *Dive into Deep Learning*, 1st ed. Cambridge, UK: Cambridge University Press, 2023.
- [16] MathWorks, "Genetic algorithm (ga)," <https://la.mathworks.com/help/gads/ga.html>, 2025, accessed: March 10, 2026.