

Alocação de recursos e posicionamento de funções virtualizadas em redes de acesso por rádio desagregadas

Gabriel Matheus Almeida¹, Leizer de Lima Pinto¹, Kleber Vieira Cardoso¹

¹Instituto de Informática – Universidade Federal de Goiás (UFG)
Caixa Postal 131 - CEP 74001-970 - Goiânia - GO – Brazil

{gabrielmatheus, leizer, kleber}@inf.ufg.br

Abstract. *The optimization of virtualized radio functions positioning in the radio access network is essential to ensure efficient resource management, being a relevant research topic in 5G and Post-5G. This study presents three approaches to solve this problem in the network planning scenario and two approaches in the network operational scenario. It includes a Mixed-Integer Linear Programming (MILP) model as well as methods based on artificial intelligence, machine learning, and meta-heuristics. Exact approaches serve as optimal upper bounds, albeit with low scalability, while non-exact methods are more efficient and can provide high-quality solutions. Deep reinforcement learning stands out for its fast convergence and generalization capability, while the genetic algorithm demonstrates more efficient processing time in the experiments conducted. However, the complexity of the problem increases considerably in the operational scenario with dynamic demand in the network varying over time.*

Resumo. *A otimização do posicionamento das funções de rádio virtualizadas na rede de acesso sem fio é essencial para garantir o uso eficiente dos recursos, sendo um tema de pesquisa relevante em redes 5G e Pós-5G. Este estudo apresenta três abordagens para resolver esse problema no cenário de planejamento da rede e duas abordagens no cenário operacional da rede. Inclui um modelo de Programação Linear Inteira Mista (MILP), bem como métodos baseados em inteligência artificial, aprendizado de máquina e meta-heurística. Abordagens exatas servem como limites superiores ótimos, entretanto com baixa escalabilidade, enquanto métodos não exatos são eficientes computacionalmente e podem proporcionar soluções de alta qualidade. Destaca-se o agente de aprendizado por reforço profundo pela sua rápida convergência e capacidade de generalização, enquanto o algoritmo genético demonstra um tempo de processamento mais eficiente nos experimentos realizados. No entanto, a complexidade do problema aumenta consideravelmente no cenário operacional com demanda dinâmica na rede variando ao longo do tempo.*

1. Caracterização do problema e motivação

O aumento da demanda por conectividade móvel tem levado as operadoras a buscar soluções eficientes para expandir suas redes enquanto minimiza os custos da rede de acesso por rádio (RAN). Na transição para o 5G, a virtualização das funções de rádio (vRAN) tornou-se essencial. Isso permite o processamento das funções de rádio em nós de processamento genéricos (CNs) que podem ser divididos como: Unidade Central

(vCU), Unidade Distribuída (vDU) e Unidade de Rádio (RU). Entretanto, o posicionamento de funções da vRAN representa um desafiador problema de alocação de recursos.

O problema de posicionamento de funções da vRAN envolve otimizar a escolha da divisão funcional e do caminho de roteamento para cada RU, garantindo que as restrições de processamento e transporte sejam atendidas conforme a demanda [Laghrissi and Taleb 2018]. A Figura 1 ilustra os elementos desse problema, mostrando a pilha de rádio com as oito opções de divisões funcionais e uma topologia de vRAN, com triângulos representando as RUs e retângulos representando os CNs. A figura também mostra o posicionamento de vCUs e vDUs, juntamente com as rotas usadas por cada RU.

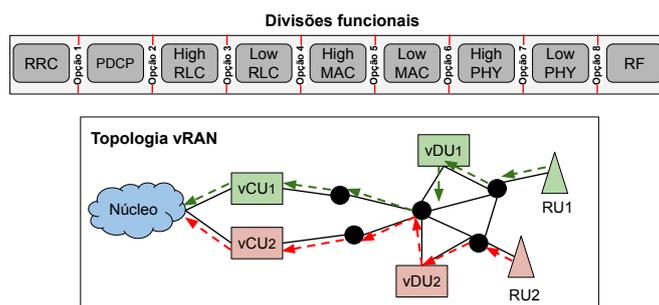


Figura 1. Problema de posicionamento de funções da vRAN.

2. Trabalhos relacionados

Nesta seção, dividida em três subseções, abordamos estudos relacionados ao posicionamento de funções na vRAN. Na primeira, destacamos pesquisas que resolvem o problema com demanda estática e métodos exatos. Na segunda, estudos que consideram demanda estática e métodos não exatos. Por fim, trabalhos que abordam a variação de demanda.

2.1. Demanda estática e métodos de otimização exata

Em [Garcia-Saavedra et al. 2018a], é proposta uma formulação para maximizar a centralização das funções da vRAN em uma única unidade de centralização (CU), baseando-se no princípio da C-RAN. No entanto, essa abordagem tem limitações de centralização comparada a cenários com múltiplas CUs. Já em [Garcia-Saavedra et al. 2018b], os autores consideram múltiplas CUs em sua formulação. Embora isso melhore a centralização devido à presença de vários pontos de centralização, a formulação assume que as RUs conectadas a uma determinada CU devem utilizar a mesma divisão funcional, o que limita a flexibilidade do *crosshaul*.

Em [Murti et al. 2020], a abordagem adotada é baseada em estudos anteriores [Garcia-Saavedra et al. 2018a], mas apresenta limitações de centralização devido ao posicionamento fixo das vDUs. Por outro lado, [Morais et al. 2022] propõe o PlaceRAN, uma formulação mais flexível que permite o posicionamento dinâmico de vCUs e vDUs em qualquer nó de processamento da rede, visando maximizar a centralização das funções da vRAN e minimizar o número de CNs utilizados.

2.2. Demanda estática e solução aproximada

Os estudos anteriores utilizam métodos clássicos de otimização para abordar o problema de posicionamento de funções na vRAN, porém, devido à sua complexidade, são limi-

tados para resolver instâncias maiores. Para contornar isso, métodos não exatos são explorados. Em [Murti et al. 2022a], é proposto um agente de Aprendizado por Reforço Profundo (DRL) para resolver esse problema, porém, a formulação simplificada utilizada limita a centralização e a redução de custos.

Em [Erazo-Agreto et al. 2021], são investigadas duas estratégias não exatas para resolver uma variante do problema de posicionamento de funções da vRAN. Os autores assumem que os provedores de infraestrutura recebem solicitações de operadores virtuais de redes móveis para criar suas próprias vRANs, modelando o problema como um problema de incorporação de rede virtual, considerando a seleção conjunta de roteamento e divisão funcional. Para resolver o problema são apresentados uma heurística gulosa e um algoritmo evolutivo. Entretanto, os autores consideram na formulação vDUs e vCUs de posicionamento fixo, o que limita a centralização e economia de custos na vRAN.

2.3. Demanda dinâmica e cenário prático

Os estudos [Murti et al. 2023, Alba et al. 2022, Joda et al. 2022, Pamuklu et al. 2021] tratam da variação dinâmica da demanda nas RUs no problema de posicionamento das funções da vRAN. Isso busca adaptar as soluções às mudanças no tráfego e diminuir os custos operacionais, embora aumente a complexidade do problema. Em [Murti et al. 2023], sugere-se o uso de um agente DRL para lidar com o posicionamento dinâmico das funções, considerando as variações na demanda das RUs. No entanto, a falta de garantias quanto ao cumprimento das restrições de posicionamento é uma limitação crítica, podendo comprometer a viabilidade das soluções.

Em [Pamuklu et al. 2021], um agente DRL é aplicado para tratar o problema de posicionamento considerando variação na demanda. Embora se concentre na eficiência energética, não garante o cumprimento das restrições de posicionamento, semelhante a [Murti et al. 2023]. Em contraste, [Joda et al. 2022] propõe um agente DRL com uma função de recompensa que penaliza soluções inviáveis, mitigando o problema, mas não o resolve completamente. A Tabela 1 resume as características dos trabalhos citados.

Referência	Formulação	CUs	Divisões funcionais	Demanda	Aplica restrições
[Garcia-Saavedra et al. 2018a]	MILP	Única e fixa	Fixas	Estática	Sim
[Garcia-Saavedra et al. 2018b]	MILP	Fixas	Fixas	Estática	Sim
[Murti et al. 2020]	MILP	Fixas	Fixas	Estática	Sim
[Morais et al. 2022]	MILP	Dinâmicas	Genéricas	Estática	Sim
[Murti et al. 2022a]	DRL	Única e fixa	Fixas	Estática	Sim
[Murti et al. 2022b]	DRL	Única e fixa	Fixas	Estática	Sim
[Murti et al. 2023]	DRL	Dinâmicas	Fixas	Dinâmica	Não
[Joda et al. 2022]	DRL	Única e fixa	Fixas	Dinâmica	Não
[Pamuklu et al. 2021]	DRL	Única e fixa	Fixas	Dinâmica	Não

Tabela 1. Principais diferenças entre os trabalhos citados.

3. Objetivos e contribuições

Na literatura, vários estudos propõem métodos exatos para resolver o problema do posicionamento de funções da vRAN. No entanto, devido à sua alta complexidade computacional, esses métodos enfrentam limitações de desempenho ao resolver o problema para

redes maiores. Alguns autores exploram modelos não exatos para lidar com a alta complexidade dos modelos anteriores, enquanto investigam a variação de demanda das RUs. Entretanto, tais trabalhos não garantem o cumprimento das restrições de posicionamento, permitindo soluções inviáveis de serem implementadas na rede.

Este estudo foca na formulação do problema de posicionamento de funções da vRAN e no desenvolvimento de soluções não exatas eficientes que respeitem as restrições de posicionamento. O objetivo é oferecer soluções de qualidade, mantendo a eficiência computacional e considerando a divisão de carga no roteamento multicaminho. Este trabalho avança o estado da arte com as seguintes contribuições:

- Desenvolvemos modelos matemáticos para o problema de posicionamento da vRAN, considerando roteamento multicaminho e recursos de rede heterogêneos. Comparamos essa abordagem com o roteamento simples, analisando as soluções, complexidade computacional e eficiência na busca pela solução ótima.
- Apresentamos um modelo de aprendizado por reforço profundo para resolver o problema. Avaliamos o treinamento, convergência, qualidade das soluções e capacidade de generalização do modelo em cenários com recursos heterogêneos.
- Desenvolvemos um Algoritmo Genético (GA) para resolver o problema de posicionamento de funções da vRAN de forma não exata. Avaliamos sua eficiência, a qualidade da população ao longo das gerações e a qualidade das soluções obtidas.
- Formulamos o posicionamento dinâmico das funções com conceitos de Processo de Decisão de Markov (MDP). Consideramos dois cenários: (i) infraestrutura própria da operadora; (ii) terceirização da carga de processamento para um provedor de nuvem. Ambas formulações apresentam um grande avanço em relação às contribuições anteriores ao considerar demanda dinâmica nas RUs. Avaliamos o MDP em termos de espaço de ações e observação, bem como a complexidade.

4. Resultados obtidos

Nesta seção, são apresentados quatro subseções com os resultados desta pesquisa. Na Subseção 4.1, é detalhado o modelo de alocação de recursos na vRAN, considerando roteamento multicaminho. Na Subseção 4.2, é apresentado um agente de DRL para resolver o problema de posicionamento de funções da vRAN. Na Subseção 4.3, são apresentados os resultados de um GA para o mesmo problema. Por fim, na Subseção 4.4, são apresentadas dois MDPs para o problema de posicionamento dinâmico de funções da vRAN.

4.1. Modelo geral de alocação de recurso na vRAN

O modelo geral de alocação de recursos na vRAN, denominado MuSt-RAN, é apresentado como uma evolução do PlaceRAN, com a inclusão do roteamento multicaminho. Essa formulação permite a divisão de carga no roteamento em várias rotas, otimizando a alocação de recursos. O MuSt-RAN considera topologias heterogêneas, divisões funcionais genéricas e posicionamento dinâmico de vCUs e vDUs. No MuSt-RAN nós inserimos uma variável de decisão $y_i^{p,r}$, que representa a porcentagem de tráfego de cada RU trafegado por cada caminho. Isso requer novas restrições para manter a linearidade da formulação, além da reformulação das restrições existentes do PlaceRAN.

A Figura 2 compara as soluções de MuSt-RAN, PlaceRAN e MCU-vRAN [Murti et al. 2020]. Na Figura 2a, o MuSt-RAN utiliza menos CNs do que o PlaceRAN, resultando em soluções mais econômicas, enquanto o MCU-vRAN utiliza todos

os CNs devido ao posicionamento fixo das vDUs. Na Figura 2b, o MuSt-RAN apresenta mais divisões funcionais (VNCs) que centralizam funções (cores amarela e cinza), em comparação com o MCU-vRAN e o PlaceRAN, que utilizam VNCs que não centralizam (cor vermelha). Isso demonstra as vantagens do roteamento multicaminho do MuSt-RAN em encontrar soluções mais econômicas e eficientes.



Figura 2. Comparando soluções de MCU-vRAN, PlaceRAN e MuSt-RAN.

4.2. Agente de aprendizado por reforço profundo

O agente de DRL é nossa primeira abordagem não exata para resolver o problema de posicionamento de funções da vRAN. No ambiente de aprendizado, o agente observa os recursos de transporte e processamento disponíveis na rede, conhecendo os recursos nos CNs, a capacidade de transporte nos enlaces e o número de RUs alocadas. Suas ações correspondem à seleção da divisão funcional e do caminho para o roteamento do fluxo de cada RU, exigindo decisões para cada RU na topologia em cada episódio de treinamento.

Após cada episódio, o agente recebe uma função de recompensa, que pode ser positiva ou negativa. Uma recompensa positiva indica a qualidade da solução encontrada, que depende da quantidade de CNs utilizados e do nível de centralização das funções. Essa recompensa positiva é atribuída quando o agente aloca as RUs sem violar nenhuma restrição de posicionamento. Por outro lado, uma recompensa negativa penaliza o agente quando ocorre a violação de restrições de posicionamento. Assim, o agente recebe uma penalização que corresponde à quantidade de RUs não alocadas durante o episódio.

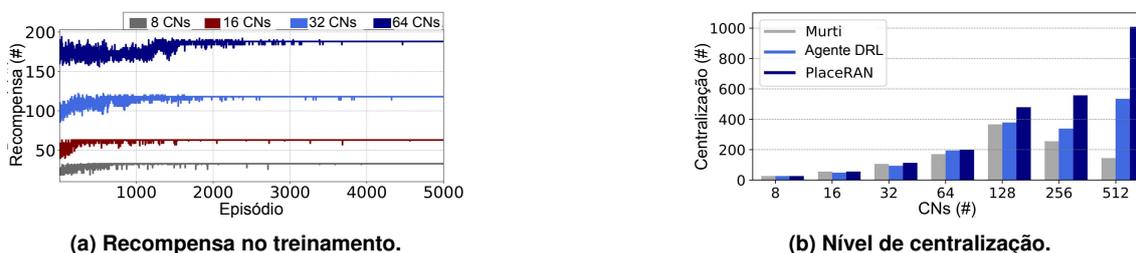


Figura 3. Analisando treinamento de qualidade das soluções do agente de DRL.

A Figura 3 apresenta a avaliação do nosso agente de DRL. Na Figura 3a, vemos a recompensa durante o treinamento em diversas topologias. O agente inicia explorando o espaço de soluções, evitando mínimos locais. Após cerca de 2000 episódios, converge para soluções mais determinadas. A Figura 3b compara a centralização das soluções com Murti [Murti et al. 2022a] e PlaceRAN. O PlaceRAN oferece soluções ótimas, mas é limitado em escalabilidade. Nosso agente centraliza mais funções que Murti em cenários com 64 CNs ou mais, devido ao posicionamento dinâmico de vCUs e vDUs.

4.3. Algoritmo Genético para posicionamento de funções da vRAN

Nesta seção, propomos uma abordagem baseada em algoritmos genéticos para resolver o problema de posicionamento de funções na vRAN. Cada indivíduo na população representa uma possível solução, com cada posição no cromossomo representando a divisão funcional e o caminho de roteamento para uma RU específica na topologia. Essa estrutura permite explorar uma ampla gama de soluções em busca da mais adequada.

Para implementar o GA, utilizamos várias técnicas de busca heurística. Na geração inicial da população, empregamos um método aleatório para gerar diversidade no espaço de soluções. Adicionalmente, inserimos um indivíduo gerado por uma heurística gulosa para maximizar a centralização. Cruzamento e mutação foram aplicados para criar novos indivíduos e diversificar a busca. Um método de reparo foi utilizado para corrigir soluções inviáveis, garantindo que respeitassem as restrições. Por fim, aplicamos elitismo para manter o melhor indivíduo em cada geração. Essas estratégias combinadas melhoraram a eficiência do GA na busca heurística.

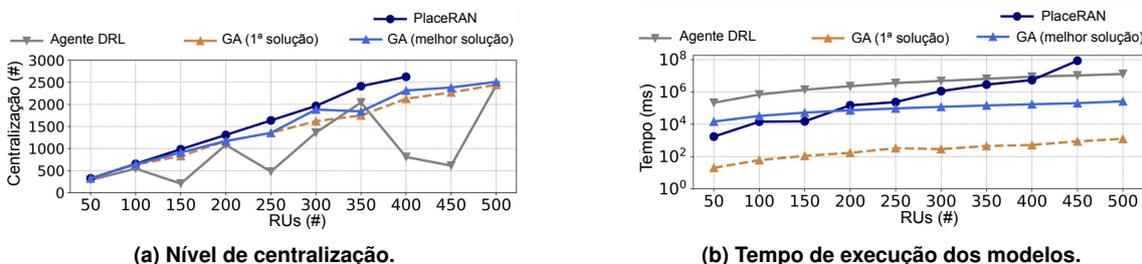


Figura 4. Comparando as soluções dos modelos em diferentes topologias.

A Figura 4 resume dois principais resultados de nossas simulações. Destacamos as soluções do GA em comparação com o PlaceRAN e o agente DRL (Subseção 4.2). Na Figura 4a, observamos a centralização de cada modelo, onde o PlaceRAN alcança o mais alto nível, porém enfrenta problemas de escalabilidade. Os modelos não exatos, incluindo o GA, resolvem todas as instâncias, superando o desempenho do agente DRL. Na Figura 4b, destacamos o tempo de execução, onde o GA supera o DRL em eficiência, e a primeira solução do GA alcança um bom equilíbrio entre tempo e centralização.

4.4. MDP para posicionamento dinâmico de funções da vRAN

Nesta seção apresentamos duas formulações MDP para o problema de posicionamento dinâmico de funções na vRAN. No primeiro cenário, consideramos que a operadora de rede possui CNs distribuídos pela rede. No segundo cenário, consideramos a terceirização da carga de processamento para CNs de um provedor de computação em nuvem.

No primeiro cenário, as ações do MDP envolvem a escolha do posicionamento das vCUs, vDUs, caminhos de roteamento e divisões funcionais para cada RU, em um determinado instante de demanda. Os estados contêm informações sobre a demanda das RUs, os recursos de processamento e transporte disponíveis e a posição atual das funções das RUs. A função de recompensa considera o custo total da solução de posicionamento, incluindo custos de instanciação, migração e processamento das funções, e custo de roteamento dos fluxos das RUs.

No segundo cenário, as ações são as mesmas do primeiro, porém há a consideração de uma operadora de computação em nuvem que fornece máquinas virtuais para processar

a carga da operadora de redes. Os estados representam apenas a demanda atual das RUs, já que a infraestrutura é terceirizada. A função de recompensa reflete o custo total das máquinas virtuais utilizadas pela operadora de rede.

O tamanho do espaço de ações dos MDPs formulados é representado como $\Theta(|\mathcal{C}||\mathcal{S}||\mathcal{F}||\mathcal{P}|^{|\mathcal{B}|})$, em que $|\mathcal{C}|$ representa a quantidade de CNs, $|\mathcal{S}|$ a quantidade de divisões funcionais, $|\mathcal{F}|$ tipos de VMs disponíveis, $|\mathcal{P}|$ a quantidade de caminhos e $|\mathcal{B}|$ a quantidade de RUs. O tamanho do espaço de observação é $\Theta(|\mathcal{B}| + |\mathcal{P}|)$ no primeiro cenário e $\Theta(|\mathcal{B}|)$ no segundo cenário, e a complexidade do cálculo da função de recompensa é $\Theta(|\mathcal{B}|^2)$ no primeiro cenário e $\Theta(|\mathcal{B}|)$ no segundo cenário.

5. Subprodutos do trabalho

Neste trabalho investigamos várias abordagens para resolver o problema de posicionamento de funções da vRAN. Inicialmente, propusemos uma formulação que inclui múltiplos caminhos, utilizando métodos exatos de otimização. No entanto, devido à complexidade, exploramos alternativas não exatas, como aprendizado por reforço, algoritmos genéticos e metaheurísticas. Além disso, desenvolvemos duas formulações MDP para lidar com a variação de demanda na rede de acesso, em cenários práticos.

A partir das investigações realizadas foram publicados os seguintes trabalhos:

- G. M. Almeida, L. Pinto, C. B. Both and K. V. Cardoso, “Optimal Joint Functional Split and Network Function Placement in Virtualized RAN With Splittable Flows” in IEEE Wireless Communications Letters, vol. 11, no. 8, pp. 1684-1688, Aug. 2022, doi: 10.1109/LWC.2022.3172878.
- G. M. Almeida, V. H. Lopes, A. Klautau and K. V. Cardoso, “Deep reinforcement learning for joint functional split and network function placement in vRAN,” IEEE Global Communications Conference, Rio de Janeiro, Brazil, 2022, pp. 1229-1234, doi: 10.1109/GLOBE-COM48099.2022.10001282.
- G. M. Almeida, C. Camilo-Junior, S. Correa and K. Cardoso, “A Genetic Algorithm for Efficiently Solving the Virtualized Radio Access Network Placement Problem,” ICC 2023 - IEEE International Conference on Communications, Rome, Italy, 2023, pp. 1874-1879, doi: 10.1109/ICC45041.2023.10279334.
- G. M. Almeida et al., “RIC-O: Efficient Placement of a Disaggregated and Distributed RAN Intelligent Controller With Dynamic Clustering of Radio Nodes,” in IEEE Journal on Selected Areas in Communications, vol. 42, no. 2, pp. 446-459, Feb. 2024, doi: 10.1109/JSAC.2023.3336159.

Os três primeiros trabalhos abordam o posicionamento de funções de rádio da vRAN, enquanto o quarto trata da alocação de recursos e posicionamento de funções virtualizadas de um controlador SDN para vRAN, mais especificamente o *Near-Real Time RAN Intelligent Controller* (Near-RT RIC) [IEEE 2021] introduzido pela O-RAN.

Com o objetivo de permitir a reprodutibilidade, sobretudo pela comunidade acadêmica, todos os artigos publicados possuem repositórios públicos com software e dados associados. A Tabela 2 apresenta os repositórios vinculados a cada artigo.

Publicação	Endereço
[Almeida et al. 2022b]	github.com/LABORA-INF-UFG/paper-GLCK-2021
[Almeida et al. 2022a]	github.com/LABORA-INF-UFG/paper-GVAK-2022
[Almeida et al. 2023]	github.com/LABORA-INF-UFG/paper-GCSK-2022
[Almeida et al. 2024]	github.com/LABORA-INF-UFG/paper-GGAMECK-2023

Tabela 2. Trabalhos com implementação publicamente disponível.

Referências

- Alba, M. et al. (2022). Dynamic Functional Split Adaptation in Next-Generation Radio Access Networks. *IEEE Trans. Netw. Serv. Manag.*, 19(3):3239–3263.
- Almeida, G. M. et al. (2022a). Deep reinforcement learning for joint functional split and network function placement in vRAN. In *IEEE Glob. Commun. Conf.*, pages 1229–1234.
- Almeida, G. M. et al. (2022b). Optimal Joint Functional Split and Network Function Placement in Virtualized RAN With Splittable Flows. *IEEE Wirel. Commun.*, 11(8):1684–1688.
- Almeida, G. M. et al. (2023). A Genetic Algorithm for Efficiently Solving the Virtualized Radio Access Network Placement Problem. In *IEEE Int. Conf. Commun.*, pages 1874–1879.
- Almeida, G. M. et al. (2024). RIC-O: Efficient Placement of a Disaggregated and Distributed RAN Intelligent Controller With Dynamic Clustering of Radio Nodes. *IEEE J. Sel. Areas Commun.*, 42(2):446–459.
- Erazo-Agredo et al. (2021). Joint Route Selection and Split Level Management for 5G C-RAN. *IEEE TNSM*, pages 4616–38.
- Garcia-Saavedra et al. (2018a). FluidRAN: Optimized vRAN/MEC Orchestration. In *IEEE INFOCOM 2018 - IEEE Conf. Comp. Commun.*, pages 2366–2374.
- Garcia-Saavedra, A. et al. (2018b). WizHaul: On the Centralization Degree of Cloud RAN Next Generation Fronthaul. *IEEE Trans. Mob. Comput.*, 17(10):2452–2466.
- IEEE (2021). O-RAN Introduces 48 New Specifications Released Since July 2021.
- Joda, R. et al. (2022). Deep Reinforcement Learning-Based Joint User Association and CU–DU Placement in O-RAN. *IEEE Trans. Netw. Service Manag.*, 19(4):4097–4110.
- Laghrissi, A. and Taleb, T. (2018). A survey on the placement of virtual resources and virtual network functions. *IEEE Commun. Surv. Tutor.*, 21(2):1409–1434.
- Morais, F. Z. et al. (2022). PlaceRAN: optimal placement of virtualized network functions in Beyond 5G radio access networks. *IEEE Trans. Mob. Comput.*, pages 1–1.
- Murti, F. W. et al. (2020). Optimal Deployment Framework for Multi-Cloud Virtualized Radio Access Networks. *IEEE Trans. Wirel. Commun.*, pages 1–1.
- Murti, F. W. et al. (2022a). Constrained Deep Reinforcement Based Functional Split Optimization in Virtualized RANs. *IEEE Trans. Wirel. Commun.*, 21(11):9850–9864.
- Murti, F. W. et al. (2022b). Learning-Based Orchestration for Dynamic Functional Split and Resource Allocation in vRANs. In *2022 J. Eur. Conf. Net. Commun. & 6G Sum.*, pages 243–248.
- Murti, F. W. et al. (2023). Deep Reinforcement Learning for Orchestrating Cost-Aware Reconfigurations of vRANs. *IEEE Trans. Netw. Serv. Manag.*
- Pamuklu, T. et al. (2021). Reinforcement Learning Based Dynamic Function Splitting in Disaggregated Green Open RANs. In *IEEE Int. Conf. Commun.*, pages 1–6.