

MPP-RAN: Posicionamento de funções de rede virtualizadas em redes de acesso de nova geração com divisão de fluxos

Gabriel M. F. de Almeida¹, Victor Hugo L. Lopes^{1,3},
Cristiano B. Both², Sand Corrêa¹, Aldebaro Klautau⁴, Kleber V. Cardoso¹

¹Instituto de Informática – Universidade Federal de Goiás (UFG)
Goiânia – GO – Brasil

²Universidade do Vale do Rio dos Sinos (UNISINOS) - Brasil

³Instituto Federal de Goiás (IFG) - Inhumas – GO - Brasil

⁴Universidade Federal do Pará (UFPA) - Belém – PA - Brasil

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

victor.lopes@ifg.edu.br, cbboth@unisinis.br, aldebaro@ufpa.br

Abstract. *Next Generation Radio Access Networks (NG-RAN) shall support eight functional splits combining placement into three nodes, i.e., Central Unit, Distributed Unit and Radio Unit. Furthermore, these nodes must work virtualized, resulting in a vNG-RAN solution. In this paper, an exact optimization model is proposed that aims to position VNFs for the planning of vNG-RAN with the possibility of splitting the routing flow into multiple paths. However, our tests show that this approach is complex for full-size vNG-RANs. Thus, we present a discussion of using deep reinforcement learning to solve this problem.*

Resumo. *Redes de Acesso por Rádio de Próxima Geração (NG-RAN) devem suportar oito opções de divisões funcionais combinando o posicionamento em três nós, i.e., Unidade Central, Unidade Distribuída e Unidade de Rádio. Além disso, esses nós devem trabalhar de forma virtualizada, resultando em uma solução vNG-RAN. Neste artigo, é proposto um modelo de otimização exato que tem como objetivo o posicionamento de VNFs para o planejamento de vNG-RAN com possibilidade de divisão do fluxo de roteamento em múltiplos caminhos. Entretanto, nossos testes apresentam que esta abordagem é complexa para vNG-RAN de tamanho real. Desta forma, esse artigo apresenta uma discussão sobre a utilização de aprendizagem por reforço profundo para resolver este problema.*

1. Introdução

Em redes móveis de sexta geração (6G) é apresentada uma proposta de evolução em termos estruturais da Rede de Acesso por Rádio (RAN) que possibilita a desagregação da Pilha de Protocolos de Rádio Virtualizado (vRAN) em um conjunto de Funções Virtualizadas (VNFs). Essa evolução é baseada nos padrões [3GPP 2018, 3GPP 2017], que trazem para a discussão a arquitetura NG-RAN planejada para atender às novas demandas de serviços previstas para as redes de próxima geração. A arquitetura proposta em NG-RAN permite que a Estação Base (BS) divida a pilha de protocolos de rádio em até

oito opções combinadas em três nós RAN: Unidade Central (CU), Unidade Distribuída (DU) e Unidade de Rádio (RU) [ITU-T 2018]. Tais divisões visam habilitar melhorias nos recursos de rádio e aumentar a economia de custos de funcionamento em comparação com as gerações móveis anteriores [Marsch et al. 2018].

Adicionalmente, o emprego de RANs virtualizadas em NG-RANs (vNG-RAN) contribui na transformação do posicionamento de VNFs em um problema complexo. Por exemplo, para cada divisão funcional os requisitos de latência, largura de banda e consumo de recurso computacional devem ser levados em consideração, e para cada BS é necessário determinar qual Combinação de RAN Desagregada (DRC) será utilizado e quais caminhos serão utilizados no roteamento. Desta forma, neste trabalho é proposto um modelo de otimização exato para este problema tendo como objetivo minimizar o uso de recursos computacionais e maximizar a agregação de VNFs. Nosso diferencial é a divisão de fluxos em múltiplos caminhos e o posicionamento livre de CUs e DUs, respeitando os requisitos de latência, bitrate e processamento para cada DRC e a capacidade dos recursos computacionais da rede e de seus enlaces.

O problema de posicionamento de VNFs é conhecido como um problema de otimização complexo [Morais et al. 2021] em que uma abordagem de otimização exata pode resultar em tempos de execução proibitivos. Neste sentido, trabalhos como [Murti et al. 2021], apresentam algoritmos de Aprendizagem por Reforço Profundo (DRL) para resolver este problema encontrando uma solução satisfatória em um tempo hábil de execução.

2. Formulação do problema

Em gerações de redes móveis anteriores, a estrutura da pilha de protocolos de funções de rádio era rígida e fixa, não admitindo divisões funcionais e posicionamento elástico de parte das VNFs. Assim, em vNG-RAN a estrutura da pilha de protocolos de funções de rádio é elástica e permite o posicionamento de suas partes em diferentes dispositivos de computação presentes na rede. As divisões funcionais especificam todas as partições possíveis da pilha de protocolos de rádio virtualizados, estabelecendo pontos de interface entre as VNFs e os requisitos para cada uma das divisões funcionais.

O número de divisões funcionais e as partições da pilha são determinadas em [3GPP 2017, ITU-T 2018]. A Figura 1b mostra as especificações da pilha de protocolos desagregada. A latência e os valores de bitrate devem ser atendidos na comunicação entre os nós RAN. Os valores de latência e taxa de bits apresentados na tabela correspondem a uma RU com largura de banda de 100 MHz do espectro, 32 antenas, 8 camadas MIMO, e modulação QAM 256 [3GPP 2017]. Para cada nó RAN é alocado um conjunto de VNFs que podem executar até três divisões independentes da pilha de protocolos. Os caminhos ao longo da rede conectando o núcleo ao CU, CU ao DU e DU ao RU são definidos como *backhaul*, *midhaul* e *fronthaul*, respectivamente, formando o *crosshaul*. A Figura 1a apresenta as possibilidades de desagregação das VNFs, agrupados em DRCs [Morais et al. 2021], que representam a preservação da ordem de posicionamento das VNFs, independente de existir ou não a divisão funcional.

Resumidamente, NG-RAN desagregado pode ser implementado a partir da alocação de VNFs em nós RAN, que são elementos virtuais que podem ser executados em diferentes nós de recursos computacionais da rede. Os diferentes posicionamentos de

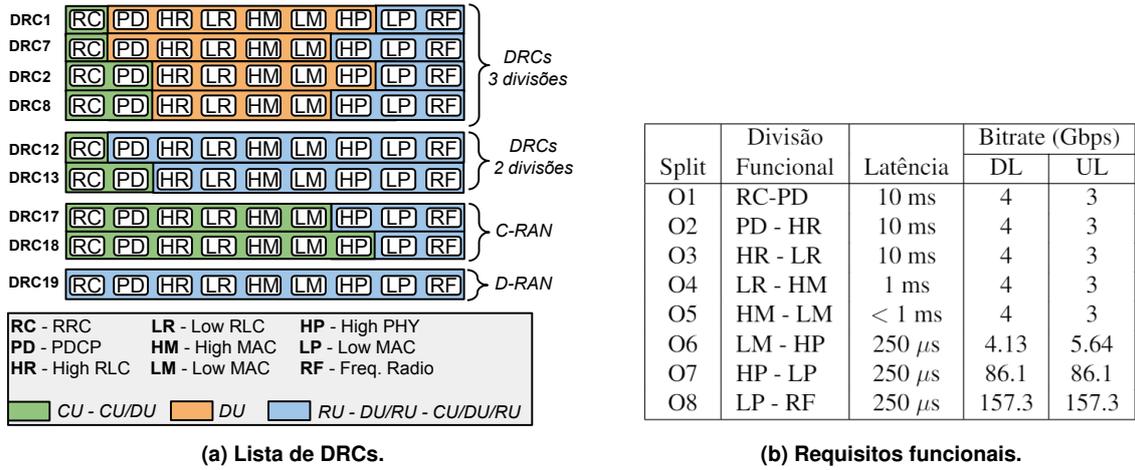


Figura 1. Lista de divisões funcionais, e os seus requisitos funcionais.

VNFs na rede impactam seu desempenho, pois está altamente relacionado com o consumo de recursos de rede e recursos computacionais. O objetivo geral do problema é atribuir um DRC para cada BS presente na rede de acesso, visando minimizar a quantidade de recurso computacional utilizado e maximizar a centralização e agregação de VNFs, o que caracteriza um problema de otimização complexo. A fim de resolver este problema, o modelo de otimização matemático exato MPP-RAN é proposto.

3. MPP-RAN

Nas subseções a seguir apresentamos as definições e a formulação do MPP-RAN.

3.1. Definições do modelo

Define-se como $\mathcal{C} = \{c_1, c_2, \dots, c_{|\mathcal{C}|}\}$ o conjunto de Recursos Computacionais (CRs) e c_m^{Proc} sua capacidade de processamento, $\mathcal{B} = \{b_1, b_2, \dots, b_{|\mathcal{B}|}\}$ o conjunto de RUs, $\mathcal{T} = \{t_1, t_2, \dots, t_{|\mathcal{T}|}\}$ o conjunto de nós de encaminhamento e \mathcal{P}_l o conjunto dos k caminhos mais curtos de origem o núcleo da rede e destino cada RU $b_l \in \mathcal{B}$. Cada caminho $p \in \mathcal{P}_l$ é composto por três subcaminhos p_{BH} , p_{MH} e p_{FH} , onde pelo menos um dos subcaminhos é não vazio, $\mathcal{F} = \{f_1, f_2, f_3, f_4, f_5, f_6, f_7\}$ é o conjunto das VNFs e $\mathcal{D} = \{D_1, D_2, \dots, D_{|\mathcal{D}|}\}$ o conjunto dos DRCs ilustrados na Figura 1. Para representar a RAN e o núcleo da rede, definiu-se um grafo $G = (\mathcal{V}, \mathcal{E})$, em que $\mathcal{V} = \{v_0\} \cup \mathcal{B} \cup \mathcal{C} \cup \mathcal{T}$ é o conjunto de vértices e $\mathcal{E} = \{e_{ij}; v_i, v_j \in \mathcal{V}\}$, $v_i, v_j \in \mathcal{V}$ é o conjunto de arestas. O vértice v_0 representa o núcleo da rede, sendo que para para cada aresta $e_{ij} \in \mathcal{E}$ são atribuídos uma capacidade de transmissão e_{ij}^{Cap} e latência e_{ij}^{Lat} .

3.2. Formulação do MPP-RAN

O MPP-RAN leva em consideração dois pontos importantes no planejamento de RAN, o primeiro deles é relacionado à centralização de NFVs. A partir da centralização em camadas mais próximas ao núcleo da rede, ganhos de desempenho são alcançados para controle e comunicação entre as RUs [Murti et al. 2020]. Entretanto, o MPP-RAN leva em consideração casos específicos de centralização chamados agregação, que ocorrem quando há centralização de NFVs iguais em um mesmo CR. A agregação tem como objetivo alcançar melhorias que beneficiam a maioria das RUs e não apenas um conjunto de

RUs específico. A partir desta ideia, o primeiro objetivo do nosso modelo de otimização matemático é maximizar o nível de agregação da solução.

A principal diferença entre o MPP-RAN e o PlaceRAN [Morais et al. 2021] é a utilização de divisão de fluxos que possibilitam uma otimização dos recursos da rede. Desta forma, o objetivo do MPP-RAN é minimizar a quantidade de CRs utilizados enquanto maximiza o nível de agregação da RAN. Para isso, definiu-se em (1) a relação de CRs utilizados e em (2) o nível de agregação. A variável de decisão $x_l^{p,r} \in \{0, 1\}$ representa a configuração utilizada para a RU $b_l \in \mathcal{B}$ e $y_l^{p,r} \in \mathbb{R}$ representa a parcela do fluxo que passa pelo caminho $p \in \mathcal{P}_l$. Além disso, $u_m^p \in \{0, 1\}$ indica se o CR $c_m \in \mathcal{C}$ faz parte do caminho $p \in \mathcal{P}_l$ e $M(c_m, f_s, b_l) \in \{0, 1\}$ indica se o CR c_m executa a VNF f_s para a RU b_l . O modelo de otimização MPP-RAN é definido a seguir e tem como objetivo minimizar a quantidade de CRs utilizados (1) e maximizar a agregação de VNFs (2):

$$\Phi_1 = \sum_{c_m \in \mathcal{C}} \left[\frac{\sum_{b \in \mathcal{B}} \sum_{p \in \mathcal{P}_l} \sum_{D_r \in \mathcal{D}} (x_l^{p,r} \cdot u_m^p)}{|\mathcal{P}|} \right] \quad (1)$$

$$\Phi_2 = \sum_{c_m \in \mathcal{C}} \sum_{f_s \in \mathcal{F}} \left(\sum_{b_l \in \mathcal{B}} \left[\frac{\sum_{p \in \mathcal{P}_l} \sum_{D_r \in \mathcal{D}} (x_l^{p,r} u_m^p)}{|\mathcal{P}|} \right] M(c_m, f_s, b_l) - \left[\frac{\sum_{b_l \in \mathcal{B}} \left[\frac{\sum_{p \in \mathcal{P}_l} \sum_{D_r \in \mathcal{D}} (x_l^{p,r} u_m^p)}{|\mathcal{P}|} \right]}{|\mathcal{B}|} \right] \right) \quad (2)$$

$$\text{minimize } \Phi_1 - \Phi_2 \quad (3)$$

Sujeito a:

$$\sum_{p \in \mathcal{P}_l} \sum_{D_r \in \mathcal{D}} x_l^{p,r} \geq 1 \quad \forall b_l \in \mathcal{B} \quad (4)$$

$$\sum_{p \in \mathcal{P}_l} \sum_{D_r \in \mathcal{D}} y_l^{p,r} = 1 \quad \forall b_l \in \mathcal{B} \quad (5)$$

$$y_l^{p,r} \leq x_l^{p,r} \quad \forall p \in \mathcal{P}_l, b_l \in \mathcal{B}, D_r \in \mathcal{D} \quad (6)$$

$$x_l^{p,r} - y_l^{p,r} \leq 1 - \varepsilon \quad \forall p \in \mathcal{P}_l, b_l \in \mathcal{B}, D_r \in \mathcal{D} \quad (7)$$

$$\sum_{e_{ij} \in \mathcal{E}} x_l^{p,r} \cdot y_{e_{ij}}^{p_{XH}} \cdot e_{ij}^{Lat} \leq \beta_{XH}^r, \forall b_l \in \mathcal{B}, p \in \mathcal{P}_l, D_r \in \mathcal{D} \quad (8)$$

$$\sum_{D \in \mathcal{D}} \sum_{b \in \mathcal{B}} \sum_{p \in \mathcal{P}_b} \left[y_b^{pD} \cdot \left(i_{e_{ij}}^{p_{BH}} \cdot \alpha_{BH}^r + i_{e_{ij}}^{p_{MH}} \cdot \alpha_{MH}^r + i_{e_{ij}}^{p_{FH}} \cdot \alpha_{FH}^r \right) \right] \leq e_{ij}^{Cap} \quad \forall e_{ij} \in \mathcal{E} \quad (9)$$

$$\sum_{f_s \in \mathcal{F}} \left[\sum_{b_l \in \mathcal{B}} \left[\frac{\sum_{p \in \mathcal{P}_l} \sum_{D_r \in \mathcal{D}} (x_l^{p,r} \cdot u_m^p)}{|\mathcal{P}_l|} \right] \cdot M(c_m, D_r, f_s, b_l) \cdot \gamma_m^s \right] \leq c_m^{Proc} \quad \forall c \in \mathcal{C} \quad (10)$$

As restrições (4) e (5) definem que pelo menos um caminho deve ser utilizado para cada RU e que as divisões de fluxo devem entregar a carga total do DRC escolhido. As restrições (6) e (7) definem a relação entre as variáveis de decisão, onde um caminho não utilizado, não deve trafegar dados e o grau de granulosidade das divisões de fluxo representado por ε . Além disso, (8) representa um conjunto de restrições para cada parte do *Crosshaul* e, juntamente, com (9) e (10) definem os limites dos recursos da rede, neste caso, banda e latência dos enlaces e dos DRCs. Finalmente, a restrição (10) define o

limite de utilização de processamento dos CRs a ser respeitado.

4. Resultados

Para avaliar o modelo de otimização foram executados diversos testes com diferentes topologias de RAN. Foram obtidos resultados interessantes quando comparados a solução encontrada pelo MPP-RAN com a solução encontrada pelo PlaceRAN para topologias com uma quantidade de CRs relativamente baixa. Entretanto, outros testes apontaram um resultado ainda mais desafiador em relação à complexidade do MPP-RAN. Nesta seção discute-se estes resultados para justificar a diferença de complexidade entre os modelos e realizar uma discussão sobre possíveis soluções para o problema,

Em topologias relativamente pequenas o MPP-RAN apresenta melhorias em ambos objetivos principais do modelo quando compara-se sua solução ótima à solução ótima encontrada pelo PlaceRAN, pois, leva em consideração a divisão de fluxos em múltiplos caminhos. Entretanto, este fato impacta diretamente na complexidade do MPP-RAN para encontrar soluções ótimas. A Tabela 1 apresenta os resultados encontrados para uma topologia hierárquica com diferentes quantidades de CRs e RUs. Note que conforme o tamanho da topologia cresce a diferença entre os tempos de execução aumenta consideravelmente. Isto deve-se ao fato de que o MPP-RAN admite mais soluções que o PlaceRAN e, por isso, precisa explorar um espaço de solução viável maior.

Cenários	PlaceRAN	MPP-RAN
10 CRs e 8 RUs	< 1 segundo	3 minutos
27 CRs e 25 RUs	5 segundo	2 horas*
51 CRs e 49 RUs	10 segundo	16 horas*
128 CRs e 126 RUs	5 minutos	1 semana*

* Testes que não chegaram a encontrar solução ótima.

Tabela 1. Tempos de execução PlaceRAN x MPP-RAN.

Embora as soluções providas pelo MPP-RAN sejam superiores ao PlaceRAN, principalmente devido à flexibilidade gerada pelo uso da divisão de fluxos, o tempo gasto na otimização tende a ser, de fato, proibitivo, em que o emprego de métodos de otimização não exatos se torna desejável. Entretanto, observa-se que a estrutura do problema de posicionamento de VNFs apresenta características que habilitam o emprego de métodos baseados em Inteligência Artificial (IA), que podem lidar com problemas complexos com ou sem a necessidade de se apoiar em modelos formalmente definidos [Moerland et al. 2020].

Tendo em vista que o presente problema pode ser modelado como uma otimização combinatória, como em [Murti et al. 2021], uma solução baseada em DRL se mostra uma possibilidade atraente, no qual a função objetivo, bem como as restrições do problema, podem ser aprendidas por um agente, enquanto interage com um ambiente que replica o problema, mapeando as recompensas recebidas pelas ações tomadas diante de observações do estado, buscando construir uma política de decisão que visa maximizar tal recompensa no longo prazo. Desta forma, o desafio envolve a definição do espaço de observações, o espaço de ações para o agente, e a função de recompensa que agrega os objetivos e restrições, eliminando a necessidade da própria formulação matemática do problema. Entretanto, esta não é uma tarefa trivial, dado que embora parte das restrições

possam ser incorporadas no espaço de ações, a função de recompensa deve representar a função objetivo e as demais restrições.

5. Conclusão

Em redes 6G é apresentada a proposta de evolução estrutural conhecida como vNG-RAN. O problema de posicionamento de VNFs em vNG-RAN é um problema de otimização complexo e a abordagem com utilização de divisão de fluxos apresentada pelo MPP-RAN contribui ainda mais para este quadro. Entretanto, esta abordagem é capaz de encontrar melhores soluções para o problema, principalmente quando os recursos não são ideais. Com isso, alternativas para encontrar soluções em tempo hábil e de boa qualidade é um dos desafios desta área. Técnicas com a utilização de DRL e outras técnicas de IA estão surgindo cada vez mais para problemas desta natureza e aparentam ser uma boa saída.

Como trabalhos futuros, o emprego de soluções baseadas em DRL em cenários em que o MPP-RAN não apresente um tempo adequado ou não consiga encontrar a solução ótima deve ser investigado. Adicionalmente, pode-se realizar a avaliação das soluções encontradas a partir das métricas de quantidade de CRs utilizados, nível de agregação e qualidade dos DRCs. Outros pontos interessantes de avaliação são o tempo de execução em relação à qualidade da solução e comparar os resultados obtidos com pelos métodos de IA com as soluções ótimas de abordagens que não utilizam divisão de fluxo.

Agradecimentos

O presente trabalho foi realizado com apoio do Projeto Brasil 6G, financiado pelo Ministério da Ciência, Tecnologia e Inovações (MCTI) e Rede Nacional de Pesquisa (RNP).

Referências

- 3GPP (2017). Study on New Radio Access Technology; Radio Access Architecture and Interfaces (Release 14). Technical Recommendation (TR) 38.801, 3rd Generation Partnership Project (3GPP).
- 3GPP (2018). System Architecture for the 5G (Release 15). Technical Recommendation 23.501.
- ITU-T, G.-T. (2018). Transport network support of IMT-2020/5G.
- Marsch, P. et al. (2018). *5G system design: architectural and functional considerations and long term research*. John Wiley & Sons.
- Moerland, T. M., Broekens, J., and Jonker, C. M. (2020). Model-based reinforcement learning: A survey. *arXiv preprint arXiv:2006.16712*.
- Morais, F. Z. et al. (2021). PlaceRAN: Optimal Placement for the Virtualized Next-Generation RAN. *CoRR*, abs/2102.13192.
- Murti, F. W., Ali, S., and Latva-aho, M. (2021). Deep reinforcement based optimization of function splitting in virtualized radio access networks. *arXiv preprint arXiv:2105.14731*.
- Murti, F. W. et al. (2020). On the optimization of multi-cloud virtualized radio access networks. In *ICC 2020 - 2020 IEEE International Conference on Communications (ICC)*, pages 1–7.