

Uma Proposta Preliminar para Alocação de Redes Virtuais Usando Aprendizagem por Reforço

Beatriz Bento Martins, Guilherme Piêgas Koslovski

¹Programa de Pós-Graduação em Computação Aplicada (PPGCAP)
Universidade do Estado de Santa Catarina (UDESC)

beatriz.martins@edu.udesc.br, guilherme.koslovski@udesc.br

***Resumo.** Com a composição de redes virtuais, diversas aplicações podem compartilhar os recursos computacionais de data centers. O presente trabalho atua na alocação de recursos em data center para hospedar as redes virtuais. A proposta é baseada em aprendizagem por reforço, buscando um alocador escalável e adaptável a diversas cargas de trabalho e requisitos de qualidade de serviço.*

1. Introdução

As redes de computadores são elementos fundamentais para suportar o processamento de alto desempenho [Noormohammadpour and Raghavendra 2017]. Por exemplo, o Facebook indica que até 33% do tempo de processamento de seus dados são relacionados com as comunicações internas no *data center (DC)* [Rost et al. 2015]. Para mitigar problemas de desempenho e auxiliar no gerenciamento, aplica-se o conceito de virtualização de redes. Assim, redes virtuais (RVs) são compostas para interconectar elementos de processamento garantindo isolamento, confiabilidade e qualidade de serviço, conforme exemplificado pela Figura 1(a). Nesse contexto, o presente trabalho investiga a alocação das RVs sobre um DC virtualizado, aplicando aprendizado por reforço (AR) [Boutaba et al. 2018] para desenvolver um alocador escalável e sobretudo adaptável a diversos cenários.

2. Motivação e Proposta

A proposta busca aplicar aprendizado de máquina para alocação de redes virtuais e elementos de processamento sobre DCs de alto desempenho, dando continuidade a trabalhos anteriores que demonstraram seu potencial para controle de acesso [Blenk et al. 2016]. AR permite que o sistema explore e analise dados deduzindo conhecimento, ou seja, vai além de simplesmente aprender ou extrair conhecimento, identificando e explorando padrões ocultos nos dados através das interações realizadas. A Figura 1(b) ilustra a composição da proposta. Basicamente, o agente é, de fato, a inteligência artificial construída para explorar o ambiente (usando representações de estados) e realizar ações, que atuará de forma exploratória, procurando novos padrões de alocação de acordo os requisitos e dados disponíveis. Por sua vez, o ambiente representa o DC e as RVs previamente alocadas, quantificando recursos disponíveis de rede e de processamento. É importante ressaltar que esses dados são fornecidos por monitores externos à proposta.

A ação efetuada pelo agente impacta no ambiente, ou seja, após o agente decidir pela alocação de uma RV sobre o DC, o ambiente deve contabilizar os enlaces ocupados, compondo caminhos virtuais entre os recursos de processamento, respeitando as capacidades disponíveis e os requisitos solicitados. No cenário alvo, as RVs são individualmente processadas. Como a eficiência do AR depende da interação com o ambiente, o agente

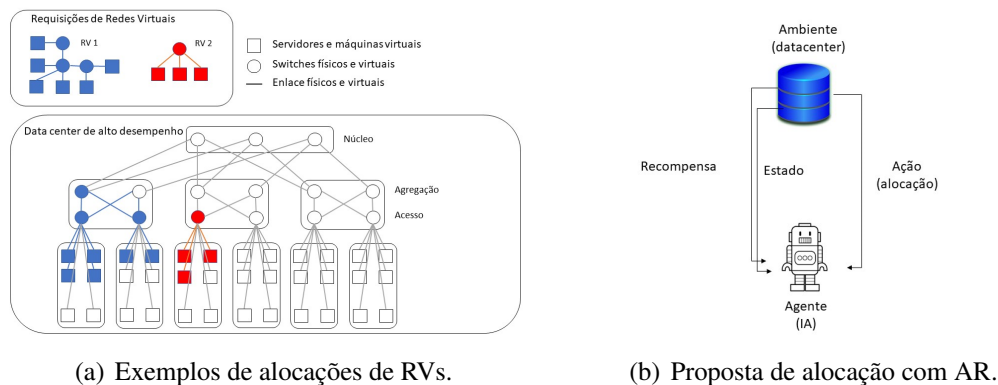


Figura 1. Exemplo e proposta para alocação de RVs usando AR.

deve receber uma sinalização sobre suas ações, denominada recompensa. Para cada ação, o ambiente elabora uma recompensa, ou seja, o agente receberá um retorno indicando sua eficiência perante ao objetivo final do administrador do DC, como por exemplo: reduzir o tempo de espera das tarefas, reduzir o consumo energético, entre outros.

Para obter um alocador escalável e sensível ao contexto de execução, alguns desafios devem ser considerados: (i) Cada requisição possui tamanho (número de enlaces virtuais) e topologia virtual distintos. Essa informação reflete na representação dos estados e das ações. (ii) Cada recurso físico pode alocar múltiplos recursos virtuais. Nesse contexto, é possível que recursos comunicantes sejam alocados no mesmo vértice. (iii) Intuitivamente, uma recompensa positiva é atribuída a um resultado que se aproxima de uma melhor alocação, entretanto, é necessário definir uma função de recompensa que compreenda rejeições de RVs e alocações ineficientes.

3. Considerações Finais e Trabalhos Futuros

A proposta preliminar apresentada busca a aplicação de AR para realizar a alocação de RVs em DCs de alto desempenho. Os trabalhos futuros vislumbram a implementação, treinamento e análise baseados em dados reais disponibilizados publicamente.

Referências

- Blenk, A., Kalmbach, P., Van Der Smagt, P., and Kellerer, W. (2016). Boost online virtual network embedding: Using neural networks for admission control. In *12th Int. Conf. on Network and Service Management (CNSM)*, pages 10–18. IEEE.
- Boutaba, R., Salahuddin, M. A., Limam, N., Ayoubi, S., Shahriar, N., Estrada-Solano, F., and Caicedo, O. M. (2018). A comprehensive survey on machine learning for networking: evolution, applications and research opportunities. *Journal of Internet Services and Applications*, 9(1):1–99.
- Noormohammadpour, M. and Raghavendra, C. S. (2017). Datacenter traffic control: Understanding techniques and tradeoffs. *IEEE Communications Surveys & Tutorials*, 20(2):1492–1525.
- Rost, M., Fuerst, C., and Schmid, S. (2015). Beyond the stars: Revisiting virtual cluster embeddings. *ACM SIGCOMM Computer Communication Review*, 45(3):12–18.