

**Universidade de Pernambuco**  
**Programa de Pós-Graduação em Engenharia da Computação**  
**(PPGEC)**

**Proposta de Tese de Doutorado**

**Área:** Inteligência Computacional

**Título** Aplicação de Graph Neural Networks para Previsão de Desempenho de Redes Ópticas de Alta Capacidade

**Orientador:** Daniel Augusto Ribeiro Chaves (darc@ecomp.poli.br)

As redes ópticas desempenham um papel crucial no cenário tecnológico atual, sendo fundamentais para suportar a crescente demanda por largura de banda e velocidade nas comunicações modernas (GIORDANI, et al 2020; TELEGEOGRAPHY, 2021). No entanto, a implantação dessas redes envolve custos elevados, destacando a necessidade de otimização para maximizar a eficiência e reduzir custos (CHAVES, 2010).

A otimização eficaz das redes ópticas exige modelos precisos para prever seu desempenho, mas a complexidade inerente dessas redes torna desafiadora a formulação de modelos analíticos fechados (ARAÚJO; BASTOS-FILHO; MARTINS-FILHO, 2015). Normalmente, as previsões de desempenho são realizadas por meio de simuladores de rede, os quais, apesar de precisos, demandam um tempo computacional excessivo (CAVALCANTE; PEREIRA; ALMEIDA, 2017). Essa lentidão impede a rápida avaliação de diversos cenários de rede, limitando a capacidade de otimização dinâmica.

Em contraste, o uso de técnicas de *machine learning* (ML) surge como uma alternativa promissora para prever o desempenho das redes ópticas de forma mais ágil (SUÁREZ-VARELA, J.; et al., 2023). Embora o treinamento de um modelo de ML possa ser demorado, uma vez treinado, ele pode generalizar eficientemente a performance da rede, permitindo avaliações rápidas e precisas (WANG et al., 2022).

Redes ópticas são frequentemente representadas por grafos, e modelos de ML que lidam bem com dados estruturados dessa forma, como as graph neural networks (GNNs), têm mostrado excelente potencial de generalização (SUÁREZ-VARELA, J.; et al., 2023). As GNNs aproveitam a estrutura dos dados em grafo para capturar relações complexas entre os nós e os enlaces (representando elementos da rede), o que as torna particularmente adequadas para prever a performance em redes ópticas. Essas redes neurais são capazes de realizar previsões de desempenho mesmo quando apresentam-se topologias ou padrões de tráfego diferentes daqueles utilizados durante o treinamento, demonstrando uma robustez notável (ALMASAN et al., 2022).

O objetivo deste projeto de tese de doutorado é aplicar GNNs para prever o desempenho em redes ópticas de alta capacidade. Espera-se que, ao desenvolver um modelo eficaz de GNN, seja possível criar um substituto para os simuladores de rede tradicionais, resultando em um modelo de gêmeo digital da rede óptica. Esse gêmeo digital poderá ser utilizado para otimização da rede, permitindo ajustes rápidos e precisos que potencialmente reduzirão custos e aumentarão a eficiência operacional (WANG et al., 2022). Assim, a aplicação das GNNs não apenas representa um avanço teórico na previsão de performance de redes ópticas, mas também uma solução prática para desafios reais de otimização no campo das telecomunicações.

**Referências:**

ALMASAN, Paul; SUÁREZ-VARELA, José; RUSEK, Krzysztof; BARLET-ROS, Pere; CABELLOS-APARICIO, Albert. Deep reinforcement learning meets graph neural networks: Exploring a routing optimization use case. *Computer Communications*, v. 196, p. 184-194, 2022. ISSN 0140-3664. Disponível em: <<https://doi.org/10.1016/j.comcom.2022.09.029>>.

CAVALCANTE, M. A.; PEREIRA, H. A.; ALMEIDA, R. C. SimeON: an open-source elastic optical network simulator for academic and industrial purposes. *Photonics Network Communications*, v. 34, p. 193-201, 2017. Disponível em: <<https://doi.org/10.1007/s11107-017-0697-9>>.

ARAÚJO, Danilo R. B. de; BASTOS-FILHO, Carmelo J. A.; MARTINS-FILHO, Joaquim F. An evolutionary approach with surrogate models and network science concepts to design optical networks. *Engineering Applications of Artificial Intelligence*, v. 43, p. 67-80, 2015. ISSN 0952-1976. Disponível em: <<https://doi.org/10.1016/j.engappai.2015.04.004>>.

CHAVES, D. A. R. et al. Multiobjective physical topology design of all-optical networks considering qos and capex. In: Optical Fiber Communication Conference (OFC), March 2010, p. 1–3.

GIORDANI, M. et al. Toward 6G Networks: Use Cases and Technologies. *IEEE Communications Magazine*, v. 58, n. 3, p. 55-61, mar. 2020. DOI: 10.1109/MCOM.001.1900411.

SUÁREZ-VARELA, J.; et al. Graph Neural Networks for Communication Networks: Context, Use Cases and Opportunities. *IEEE Network*, v. 37, n. 3, p. 146-153, maio/jun. 2023. Disponível em: <<https://doi.org/10.1109/MNET.123.2100773>>.

TELEGEOGRAPHY. Submarine Cable Map. Disponível em: <<https://www.submarinecablemap.com>>. Acesso em: 10 dez. 2021.

WANG, H.; WU, Y.; MIN, G.; MIAO, W. A Graph Neural Network-Based Digital Twin for Network Slicing Management. *IEEE Transactions on Industrial Informatics*, v. 18, n. 2, p. 1367-1376, fev. 2022. Disponível em: <<https://doi.org/10.1109/TII.2020.3047843>>