

15º Congresso de Inovação, Ciência e Tecnologia do IFSP - 2024

Rede Neural Artificial como agente em Redes Ópticas Elásticas

Samuel do Prado Rodrigues¹, Guilherme do Vale de Sousa², Rodrigo Campos Bortoletto³

¹ Graduando em Engenharia da Computação, Bolsista CNPq, IFSP, Campus Guarulhos, samuel.rodrigues@aluno.ifsp.edu.br.

² Graduando em Engenharia da Computação, Bolsista PIBIFSP, IFSP, Campus Guarulhos, guilherme.vale@aluno.ifsp.edu.br.

³ Instituto Federal de Educação, Ciência e Tecnologia de São Paulo, Campus Guarulhos, bortoletto@ifsp.edu.br.

Área de conhecimento (Tabela CNPq): 3.04.06.00-5 Telecomunicações

RESUMO: As Redes Ópticas Elásticas (EONs) emergem como uma solução eficaz para enfrentar o aumento exponencial do tráfego de dados, no entanto, a tarefa de alocação de rota e espectro em EONs impõe desafios significativos, como a fragmentação espectral e a elevada complexidade computacional dos métodos exatos. Este trabalho visa o desenvolvimento e avaliação de uma rede neural artificial projetada para atuar como agente que aceita ou recusa requisições de conexão. Os resultados demonstram que o uso de algoritmos de aprendizado de máquina que auxiliem na classificação de requisições é promissor, mas que são necessárias pesquisas futuras para alcançar maior desempenho.

PALAVRAS-CHAVE: Alocação de Rota e Espectro; Redes Ópticas Elásticas; Aprendizado de Máquina; Inteligência Artificial.

Artificial Neural Network as a Broker in Elastic Optical Networks

ABSTRACT: Elastic Optical Networks (EONs) are emerging as an effective solution for dealing with the exponential increase in data traffic. However, the task of route and spectrum allocation in EONs poses significant challenges, such as spectral fragmentation and the high computational complexity of exact methods. This work aims to develop and evaluate an artificial neural network designed to act as an agent that accepts or rejects connection requests. The results show that the use of machine learning algorithms to help classify requests is promising, but that future research is needed to achieve greater performance.

KEYWORDS: Route and Spectrum Allocation; Elastic Optical Networks; Machine Learning; Artificial Intelligence.

INTRODUÇÃO

O volume de tráfego da Internet está ultrapassando os avanços tecnológicos das redes de telecomunicações. Em 2024, o tráfego mundial de Internet atingirá aproximadamente 33 Exabytes por dia (Sandvine, 2024). Portanto, é necessário desenvolver tecnologias de redes que suportem transmissões flexíveis e de alta velocidade. Nesse contexto, a tecnologia de grade flexível, conhecida como redes ópticas elásticas (EONs), surge para atender ao aumento da demanda de largura de banda.

As EONs são capazes de atribuir caminhos ópticos de forma flexível, conforme os requisitos de largura de banda dos clientes. Os recursos espectrais são divididos em slots de espectro, que suportam granularidade fina, e um número de slots contíguos é necessário para estabelecer uma conexão óptica (Oki et al., 2017). Dadas as características dessa rede, seu principal atrativo é o aumento da eficiência espectral quando comparada às redes de multiplexação por divisão de comprimento de onda (WDM).

Entretanto, um dos principais problemas das EONs é a fragmentação da largura de banda, decorrente das restrições de adjacência e continuidade de espectro. Esse aspecto resulta na rejeição de conexões e, conseqüentemente, no aumento da probabilidade de bloqueio da rede (Chatterjee et al., 2018). Para contornar o problema da fragmentação, são empregadas técnicas de desfragmentação utilizando políticas de roteamento conscientes desse fenômeno. Todavia, tais métodos possuem alta

complexidade computacional, tornando necessário o uso de novas heurísticas não convencionais (Zhang et al., 2020).

O uso de algoritmos de aprendizado de máquina (ML) tem se mostrado uma alternativa promissora para enfrentar o problema de alocação de rota e espectro (RSA), permitindo decisões adaptativas e eficientes (Salani et al., 2019). As redes neurais artificiais (ANN) têm diversas aplicações, especialmente na modelagem de sistemas complexos que não podem ser descritos matematicamente. Elas consistem em uma série de algoritmos que buscam reconhecer relações subjacentes em um conjunto de dados por meio de um processo que imita a forma como o cérebro humano opera (Mahesh, 2020).

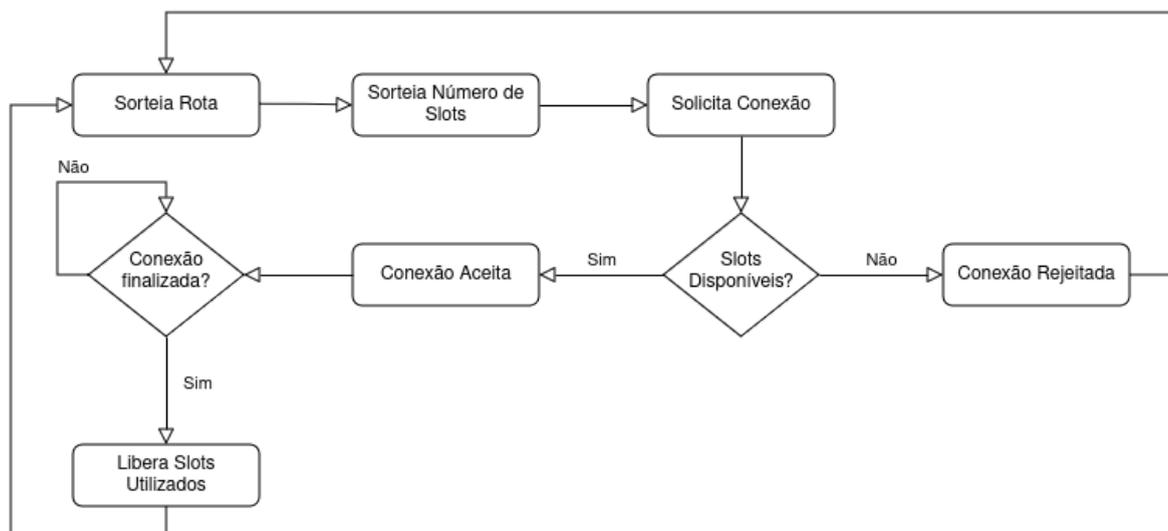
As ANNs podem se adaptar às mudanças de entrada, gerando o melhor resultado possível sem a necessidade de reprojeter os critérios de saída. Elas têm sido amplamente aplicadas a problemas de classificação binária em diversas áreas, incluindo reconhecimento de padrões, diagnóstico médico e telecomunicações (Uhrig, 1995). Este trabalho avalia o desempenho de uma arquitetura de rede neural simples para um problema de classificação binária, usando o gradiente descendente estocástico (SGD) e o critério de Early Stopping, visando mitigar problemas de sobreajuste e analisar sua capacidade de auxiliar na gestão de tráfego em uma EON.

MATERIAL E MÉTODOS

A metodologia de pesquisa utilizada neste estudo é de caráter qualitativo e experimental, fundamentando-se em artigos acadêmicos e científicos disponíveis em bases de dados bibliográficos, como Periódicos CAPES, IEEE Xplore e Elsevier, além de livros focados em ML e EONs, com destaque para as obras de Eiji Oki e Bijoy Chand Chatterjee. Após o levantamento bibliográfico, os conhecimentos adquiridos foram aplicados no desenvolvimento de um software que simula o comportamento de EONs sob as restrições do modelo de tráfego telefônico Erlang B (Angus, 2001; Nesenbergs, 1979), com o objetivo de coletar dados para treinar a ANN.

O simulador foi implementado em C++, permitindo o uso de diferentes topologias de rede e a parametrização da intensidade de tráfego, do número de requisições de conexão, da largura de banda disponível por enlace e do algoritmo de alocação de espectro a ser utilizado. Em resumo, o funcionamento do software pode ser descrito de maneira simplificada no fluxograma abaixo, que representa o estado do simulador durante a execução do número de requisições previamente definido:

FIGURA 1. Fluxograma do simulador.



Ao final de cada simulação, é exibido um relatório contendo estatísticas como a probabilidade de bloqueio (P), calculada pela equação 1:

$$P = \frac{\text{Número de requisições de conexão rejeitadas}}{\text{Número total de requisições de conexão solicitadas}} \quad (1)$$

Durante os experimentos, foi utilizada uma topologia de rede com enlace único (dois nós interconectados) e o algoritmo de alocação de espectro first fit. Foram considerados dois tipos de requisições, e o estado da rede foi armazenado no momento em que cada requisição de conexão foi aceita ou rejeitada. Foram registrados em arquivos a quantidade de slots solicitados para cada requisição (3 slots ou 5 slots). Além disso, foi armazenado se a requisição foi aceita ou rejeitada, a fragmentação espectral total da rede e a disponibilidade de slots no enlace. Os dados coletados foram divididos em conjuntos de treino e teste, utilizando-se uma proporção de 80% para treino e 20% para validação.

A Fragmentação (F) da rede foi dada pela equação 2 abaixo, onde L é a soma do número de slots disponíveis na rede e T é o número total de slots da rede:

$$F = 1 - \frac{T+L}{T} \quad (2)$$

O conjunto de treinamento foi normalizado utilizando o Standard Scaler para padronizar as características, garantindo que os valores estivessem centrados em torno de zero com desvio padrão unitário (Pedregosa et al., 2011). A arquitetura da ANN foi implementada em Python (utilizando as bibliotecas TensorFlow e NumPy) e consiste em cinco camadas densas conectadas. A camada de entrada, com 64 neurônios, é seguida de três camadas ocultas com 32, 16 e 8 neurônios, respectivamente, todas com a função de ativação ReLU. A camada de saída é composta por um único neurônio com função de ativação sigmóide, vale ressaltar que essa função foi escolhida por representar os estados de saída da variável alvo que corresponde ao bloqueio ou aceitação da requisição.

Para mitigar o sobreajuste, foi aplicada uma camada de Dropout com uma taxa de 0,4 após a camada de entrada. O Dropout desativa aleatoriamente 40% dos neurônios durante o treinamento, forçando a rede a aprender representações mais robustas dos dados. A rede foi treinada utilizando o otimizador SGD, com uma taxa de aprendizado de 0,01 e um fator de momentum de 0,9. O momentum foi utilizado para acelerar a convergência e evitar mínimos locais, aumentando a estabilidade do processo de otimização.

A função de custo utilizada foi a entropia binária cruzada (BCE), que mede a diferença entre as previsões e as saídas esperadas, sendo representada na equação 3. Para evitar o sobreajuste, o critério de Early Stopping foi empregado, monitorando a perda de validação. A condição de parada foi definida com uma paciência de 10 épocas, restaurando os melhores pesos ao final do treinamento.

$$BCE = -\frac{1}{N} \times \sum_{i=1}^N [y_i \times \log(p_i) + (1 - y_i) \times \log(1 - p_i)] \quad (3)$$

Onde N é Número total de amostras, y_i é o valor real da classe para a amostra i e p_i é a probabilidade prevista pelo modelo para a amostra i pertencer à classe 1. O valor de BCE será menor quanto mais as previsões p_i se aproximarem dos valores reais de y_i , ou seja, quando o modelo for mais preciso.

Com o objetivo de mensurar o desempenho da ANN na classificação das requisições, foram utilizadas quatro características principais: previsões positivas corretas (TP), previsões negativas corretas (TN), previsões positivas incorretas (FP) e previsões negativas incorretas (FN) (Singh et al., 2021). Com base nessas métricas, foram extraídas as seguintes medidas de performance: acurácia (ACC), precisão (PPV), revocação (TPR), taxa de falso alarme (FPR) e F1-Score. Essas métricas correspondem, respectivamente, à proporção de classificações corretas, à precisão das classificações positivas, à taxa de verdadeiros positivos, à taxa de falsos positivos e à média harmônica entre precisão e revocação (Boateng, 2020).

ACC	PPV	TPR	FPR	F1-Score
$\frac{TP + TN}{TP + FP + FN + TN}$	$\frac{TP}{TP + FP}$	$\frac{TP}{TP + FN}$	$\frac{FP}{FP + TN}$	$\frac{2 * PPV * TPR}{PPV + TPR}$

Embora essas métricas sejam amplamente utilizadas para avaliar a performance de classificadores binários, há métricas mais refinadas que proporcionam uma avaliação mais confiável. Entre elas, destaca-se o coeficiente de correlação de Matthew (MCC) (Terven et al., 2023).

O valor de MCC varia de -1 a +1, sendo que +1 indica predições perfeitas, 0 indica predições aleatórias, e -1 indica predições totalmente incorretas. Essa métrica é especialmente útil quando há um desequilíbrio entre as classes. A equação 4 abaixo descreve seu cálculo:

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP) \times (TP + FN) \times (TN + FP) \times (TN + FN)}} \quad (4)$$

RESULTADOS E DISCUSSÃO

A Tabela 1 demonstra as frequências de classificação obtidas a partir da matriz de confusão do modelo de ANN. Desses dados se obtém o desempenho da rede nos métodos de avaliação estabelecidos no tópico anterior, como pode ser observado na Tabela 2.

O modelo apresenta baixa acurácia (65,9%), isso se deve à desproporcionalidade das classes presentes no conjunto de dados (Mohammed, 2020) e não é um resultado preocupante, uma vez que ao olhar para os valores obtidos de PPV nota-se que a rede obteve um bom desempenho de 83,44%. Analisando os resultados de TPR e FPR observa-se que o modelo tende a classificar corretamente mais do que comete equívocos (52,08% para 14,58%) e, embora seu desempenho em F1-Score seja medíocre (abaixo de 70%), o MCC positivo indica que o uso da rede ainda é melhor do que um palpite.

TABELA 1. Resultados do algoritmo de classificação.

TP	FN	FP	TN
60.893	56.015	12.077	70.755

TABELA 2. Performance da ANN em métricas baseadas nas 4 características principais.

ACC (%)	PPV (%)	TPR (%)	FPR (%)	F1 (%)	MCC
65,90	83,44	52,08	14,58	64,13	0,38

Os resultados obtidos neste estudo sugerem que a hipótese inicial de que o uso de algoritmos de ML podem auxiliar o processo de RSA em simulações e, conseqüentemente em modelos físicos, está correta. Esses avanços estão alinhados com a literatura, que já sugere o potencial de algoritmos de ML para aprimorar a gestão de recursos em EONs (Chen et al., 2018; Klinkowski et al., 2012), bem como aplicações recentes no desenvolvimento de algoritmos de roteamento assistidos por previsões de tráfego (Wang et al., 2020) e desfragmentação de espectro (Trindade et al., 2021).

CONCLUSÕES

Conclui-se que a rede neural foi capaz de replicar as decisões do simulador razoavelmente e os resultados obtidos indicam que o modelo de inteligência artificial tem um potencial para complementar os simuladores tradicionais de redes ópticas elásticas no processo de gerenciamento de tráfego. Entretanto, futuras pesquisas são necessárias para explorar arquiteturas que apresentem maior desempenho e sejam capazes de atuar em cenários complexos, com distintos tipos de conexão, roteamento dinâmico e intensidades de tráfego variáveis, considerando outras características de estado das redes ópticas elásticas.

CONTRIBUIÇÕES DOS AUTORES

Todos os autores contribuíram com a escrita, desenvolvimento e com a revisão do trabalho e aprovaram a versão submetida.

AGRADECIMENTOS

Os autores agradecem ao Conselho Nacional de Pesquisa CNPq e ao Instituto Federal de Educação, Ciência e Tecnologia de São Paulo pela concessão da bolsa de Iniciação Científica (PIBIC) que originou este trabalho.

REFERÊNCIAS

- Angus, I. (2001). "An introduction to Erlang B and Erlang C". *Telemanagement*, 187, 8.
- Boateng, E., Otoo, J., Abaye, D. (2020). "Basic Tenets of Classification Algorithms K-Nearest-Neighbor, Support Vector Machine, Random Forest and Neural Network: A Review". *Journal of Data Analysis and Information Processing*, 8, 341-357
- Chatterjee, B. C., Ba, S., Oki, E. (2018). "Fragmentation Problems and Management Approaches in Elastic Optical Networks: A Survey". *IEEE Communications Surveys & Tutorials*, 20, 183-210.
- Chen, Y., Ji, F., Zhao, N., Yin, F. (2018). "Machine learning-based routing and spectrum allocation in elastic optical networks." *Optics Communications*, 410, 1-6.
- Oki, E., Chatterjee, B. C. (2017). "Design and control in elastic optical networks: Issues, challenges, and research directions," *International Conference on Computing, Networking and Communications (ICNC)*, 546-549.
- Jinno, M., Takara, H., Kozicki, B., Tsukishima, Y. (2009). "Spectrum-efficient and scalable elastic optical path network: architecture, benefits, and enabling technologies." *IEEE Communications Magazine*, 47(11), 66-73.
- Klinkowski, M., Jajszczyk, A. (2012). "Routing and spectrum assignment in spectrum-sliced elastic optical path networks." *IEEE Communications Magazine*, 50(8), 40-47.
- Mahesh, B. (2020). "Machine Learning Algorithms - A Review". *International Journal of Science and Research*, 9, 381-386.
- Mohammed, R., Rawashdeh, J., Abdullah, M. (2020). "Machine Learning with Oversampling and Undersampling Techniques: Overview Study and Experimental Results". *International Conference on Information and Communication Systems (ICICS)*, 243-248.
- Nesenbergs, M. (1979). "A Hybrid of Erlang B and C Formulas and Its Applications". *IEEE Transactions on Communications*, 27, 59-68.
- Pedregosa, F., Varoquaux, Gaël, Gramfort, A., Michel, V., Thirion, B., Grisel, O., et al. (2011). "Scikit-learn: Machine learning in Python". *Journal of Machine Learning Research*, 2825–2830.
- Salani, M., Rottondi, C., Tornatore, M. (2019). "Routing and Spectrum Assignment Integrating Machine-Learning-Based QoT Estimation in Elastic Optical Networks". *IEEE INFOCOM 2019 - IEEE Conference on Computer Communications*, 1738-1746.
- SANDVINE. 2024 Global Internet Phenomena Report - Sandvine. Waterloo: Sandvine, 12 Fev. 2024. Disponível em: <https://www.sandvine.com/phenomena>. Acesso em: 21 de out. 2024.
- Singh, P., Singh, N., Singh, K. K., Singh, A. (2021). "Machine Learning and the Internet of Medical Things in Healthcare". *Academic Press*, 89-111.
- Terven, J., M., D., A., E., A., J. (2023). "Loss Functions and Metrics in Deep Learning". *ArXiv*.
- Trindade, S., da Fonseca, N. L. S. (2021). "Machine Learning for Spectrum Defragmentation in Space-Division Multiplexing Elastic Optical Networks". *IEEE Network*, 35, 1, 326-332.
- Uhrig, R. E. (1995). "Introduction to artificial neural networks". *Proceedings of IECON '95 - 21st Annual Conference on IEEE Industrial Electronics*, 1, 33-37.
- Wang, Y., Cheng, B., Hang, C., Yu, J., Liu, S., Hu, Y., Shen, J. (2020). "Routing Algorithm for Elastic Optical Network Based on Machine Learning assisted Traffic Prediction". *Journal of Physics: Conference Series*.
- Zhang, Y., Xin, J., Li, X., Huang, S. (2020). "Overview on routing and resource allocation based machine learning in optical networks". *Optical Fiber Technology*.