

Uso de Modelos de Classificação Binária para Controle de Admissão em Redes Ópticas Elásticas

Mauro G. M. Barros¹, Jurandir C. Lacerda Jr¹

¹Instituto Federal de Ciência, Educação e Tecnologia do Piauí (IFPI)
Corrente, Piauí, Brasil

mgmbarros2006@gmail.com, jurandir.cavalcante@ifpi.edu.br

Abstract. Admission control in Multi-Core Fiber Elastic Optical Networks aims to optimize resources and anticipate blockages caused by physical impairments, such as crosstalk. This work models admission as a binary classification problem and compares two Machine Learning models: a linear kernel Support Vector Machine (SVM-L) and a Multilayer Perceptron Artificial Neural Network (MLP-ANN). The results indicated that the MLP-ANN model achieved an accuracy of 77.75%, superior to the SVM-L model (74.33%), proving capable of capturing the nonlinearities of the admission process. Using a dataset of over 1 million requests, we applied a progressive methodology across three phases (5%, 20%, and 100% of the data), reducing the feature set from 10 initial routing and physical attributes to 6 core variables to eliminate noise and evaluate the impact of dimensionality.

Resumo. O controle de admissão em Redes Ópticas Elásticas com Fibras Multinúcleo visa otimizar recursos e antecipar bloqueios devido a degradações físicas, como o crosstalk. Este trabalho modela a admissão como classificação binária e compara dois modelos de aprendizado de máquina: Máquina de Vetores de Suporte de kernel linear (Support Vector Machine Linear - SVM-L) e Rede Neural Artificial do tipo Perceptron de Múltiplas Camadas (Multilayer Perceptron - RNA-MLP). Os resultados apontaram que o modelo RNA-MLP obteve uma acurácia de 77,75%, superior ao modelo SVM-L (74,33%), se provando capaz de capturar não linearidades da admissão. A metodologia aplicou uma escala progressiva em três fases (5%, 20% e 100%), reduzindo a dimensionalidade de 10 atributos topológicos e físicos iniciais para 6 variáveis centrais a fim de eliminar ruídos computacionais e avaliar seu impacto na predição.

1. Introdução

Nas Redes Ópticas Elásticas (*Elastic Optical Networks* - EONs), o controle de admissão atua como o principal tomador de decisão para o estabelecimento de novas conexões [Araújo et al. 2025]. Mais do que um simples verificador de disponibilidade de banda, esse mecanismo é responsável por resolver um problema multidimensional: ele deve alocar uma rota e um bloco de espectro contíguo e contínuo, assegurando simultaneamente que o sinal óptico mantenha uma Qualidade de Transmissão (*Quality of Transmission* - QoT) viável da origem ao destino. Portanto, torna-se um componente crítico, pois uma decisão imprecisa pode tanto desperdiçar recursos espectrais quanto admitir conexões que degradem os circuitos vizinhos. O bloqueio de uma requisição ocorre justamente quando

a rede falha em encontrar essa harmonia, seja por escassez de espectro ou pelo acúmulo inaceitável de ruídos na camada física.

Para atender à crescente demanda por capacidade de tráfego, essas redes têm evoluído com a adoção da Multiplexação por Divisão Espacial (*Space Division Multiplexing* - SDM), utilizando Fibras Multinúcleo (*Multi-Core Fibers* - MCF) [Oliveira and Fonseca 2020] [Ravipudi and Brandt-Pearce 2024]. Apesar de multiplicarem a capacidade de transmissão do enlace, as MCFs introduzem um severo desafio restritivo na camada física: o *crosstalk* inter-núcleo (XT). Esse fenômeno ocorre devido ao vazamento indesejado de ruído de um núcleo para os núcleos adjacentes durante a propagação do sinal [Heera et al. 2024].

O acúmulo dessa interferência ao longo da rota degrada a QoT e a Relação Sinal-Ruído Óptica (*Optical Signal-to-Noise Ratio* - OSNR), limitando o alcance máximo do sinal e forçando o uso de formatos de modulação mais robustos e espectralmente menos eficientes [Zhang and Yeung 2023]. Consequentemente, o XT atua como o principal gargalo físico, sendo muitas vezes o fator determinante para o bloqueio direto de novas requisições em cenários de alta ocupação.

Devido à complexidade de equacionar matematicamente e em tempo real essas restrições físicas dinâmicas, abordagens tradicionais baseadas puramente em heurísticas têm dado espaço a soluções baseadas em aprendizado de máquina (*Machine Learning* - ML) [Petale and Subramaniam 2024] [Lacerda Jr et al. 2025]. Neste contexto, o presente trabalho investiga o uso de algoritmos de ML para classificar antecipadamente o estado de uma requisição de circuito de rede em duas categorias: aceito ou bloqueado. O objetivo central é propor uma metodologia progressiva de seleção de atributos e escala de dados para avaliar o desempenho preditivo de uma Máquina de Vetores de Suporte (*Support Vector Machine* - SVM) e uma Rede Neural Artificial do tipo Perceptron de Múltiplas Camadas (*Multilayer Perceptron* - MLP). Como contribuição, este estudo mostra a viabilidade do uso de ML na previsão de admissão de novas conexões e sedimenta um caminho para o aprimoramento de algoritmos de alocação de recursos em trabalhos futuros.

O restante deste artigo está organizado da seguinte forma: A Seção 2 apresenta conceitos básicos sobre as degradações de camada física da rede. A Seção 3 descreve a metodologia adotada neste trabalho. Os resultados são apresentados na Seção 4. E, por fim, conclusões e trabalhos futuros são apresentados na Seção 5.

2. Contextualização das Degradações de Camada Física

Nas EONs, segundo [Araújo et al. 2025], a garantia da QoT de um caminho óptico (*lightpath*) é um requisito fundamental para o estabelecimento de conexões viáveis. A degradação da QoT é classicamente avaliada por meio da OSNR, que quantifica a proporção entre a potência do sinal óptico e as interferências presentes no interior do núcleo da fibra. Em cenários de núcleo único, os limitadores predominantes são a Emissão Espontânea Amplificada (*Amplified Spontaneous Emission* - ASE) — um ruído adicionado progressivamente pelos Amplificadores de Fibra Dopada com Érbio (EDFA) — e as interferências não lineares (*Non-Linear Interference* - NLI). Matematicamente, a OSNR de um caminho óptico m pode ser expressa por [Habibi and Beyranvand 2019]

$$OSNR_m = \frac{G_m}{G_m^{(ASE)} + G_m^{(NLI)}} \quad (1)$$

onde G_m é a Densidade Espectral de Potência (*Power Spectral Density* - PSD) do sinal, enquanto $G_m^{(ASE)}$ e $G_m^{(NLI)}$ representam as PSDs referentes ao ruído ASE e aos efeitos não lineares, respectivamente. A descrição completa das expressões de $G_m^{(ASE)}$ e $G_m^{(NLI)}$ está disponível em [Habibi and Beyravand 2019].

Com a expansão da capacidade via SDM, a adoção das MCFs trouxe a nova degradação do XT. Diferente dos ruídos intra-núcleo, o XT aumenta substancialmente sempre que sinais ocupam espectros de frequência sobrepostos (mesmos *slots*) em núcleos vizinhos no mesmo enlace. O acúmulo total de XT em um caminho óptico m ao longo de sua rota pode ser quantificado através do somatório das interferências sofridas em cada enlace e . O valor de XT no caminho óptico m é dado por [Lobato et al. 2019]:

$$P_{XT_{m,e}} = \sum_{n=1}^{N_{m,e}} \left(I_{SO_{m,e,n}} \cdot P_n \cdot h_e \cdot L_e \right), \quad (2)$$

onde $N_{m,e}$ é o número de circuitos alocados em núcleos adjacentes ao núcleo do circuito m que utilizam a mesma fração de espectro, total ou parcialmente, no enlace e . O índice n identifica cada um desses circuitos interferentes. P_n corresponde à potência do sinal do n -ésimo circuito adjacente, L_e é o comprimento do enlace e , e h_e denota o coeficiente de acoplamento de potência da fibra. $I_{SO_{m,e,n}}$ representa o índice de sobreposição de *slots* entre os circuitos m e n no enlace e , sendo definido como $I_{SO_{m,e,n}} = (S_{SO_{m,e,n}})/(S_{e,n})$, em que $S_{SO_{m,e,n}}$ é o número de *slots* do circuito m que compartilham o mesmo índice espectral com o circuito n (desconsiderando a banda de guarda). Por sua vez, $S_{e,n}$ corresponde ao número total de *slots* alocados ao circuito n no enlace e .

Para viabilizar uma operação sem interrupções, o sistema de controle deve calcular essas métricas utilizando modelos analíticos robustos. Contudo, processar toda essa base matemática para todas as conexões da rede demanda um alto tempo computacional. É este obstáculo que alicerça a integração de modelos de aprendizado de máquina, que abstraem a complexidade aprendendo diretamente com os dados operacionais, sem a necessidade de recalculas as formulações físicas a cada instante.

3. Metodologia

Modelou-se o problema como classificação binária (1: aceito, 0: bloqueado) usando 1.084.215 instâncias simuladas conforme [Lacerda Jr. et al. 2024]. Dos 12 atributos originais (*saltos, núcleo, modulação, comprimento, primeiro slot, último slot, XT, OSNR, banda, consumo de energia, peso, resultado*), derivou-se a variável alvo *aceito* e a *feature slots_usados* (diferença entre *slots* extremos). Removendo as redundâncias espectrais, restaram 10 atributos de entrada. A base apresentou desbalanceamento natural: 34,6% das requisições bloqueadas e 65,4% aceitas. Para otimizar o custo computacional e garantir a robustez do modelo, adotou-se uma metodologia progressiva de escala de dados estruturada em três fases de treinamento com partições estratificadas (70% treino e 30% teste). Inicialmente, a Fase Exploratória utilizou 5% dos dados para mapear a Importância de Permutação (*Permutation Importance*) do conjunto completo de 10 atributos e identificar potenciais variáveis ruidosas. Em seguida, a Fase de Validação aplicou 20% dos

dados utilizando apenas as 6 *features* de maior relevância (*XT*, *OSNR*, *slots_usados*, *compressão*, *modulação*, *banda*) extraídas da etapa anterior, a fim de certificar que a redução dimensional não causaria perda de desempenho preditivo e confirmar os papéis de explicabilidade física dos algoritmos. Por fim, a Fase de Teste Final executou o treinamento com 100% da base mantendo as 6 *features* otimizadas para a avaliação definitiva da volutmetria e consolidação das matrizes de confusão.

O pré-processamento seguiu um rigoroso protocolo para evitar o vazamento de dados (*data leakage*). Apenas com base no conjunto de treino, realizou-se a normalização de escala utilizando o *StandardScaler*. Além disso, aplicou-se a técnica de balanceamento via subamostragem aleatória (*RandomUnderSampler*) exclusivamente no conjunto de treino, igualando o volume de ambas as classes para mitigar o viés algorítmico em favor da classe majoritária. Cabe ressaltar que, embora essa escolha metodológica seja válida, ela implica possíveis limitações, como a perda de informação útil presente nas amostras descartadas e a alteração da representatividade do cenário real da rede, que é caracterizado por um desbalanceamento natural do tráfego.

Os algoritmos avaliados englobaram duas abordagens distintas. A primeira consistiu em uma Máquina de Vetores de Suporte de *kernel* linear (SVM Linear), estabelecida como modelo de referência (*baseline*) com parâmetro $C = 1.0$. A segunda abordagem utilizou uma Rede Neural Artificial do tipo Perceptron de Múltiplas Camadas (RNA-MLP), projetada com uma arquitetura contendo duas camadas ocultas de (64, 32) neurônios, função de ativação ReLU, otimizador Adam e mecanismo de parada antecipada (*early stopping*) para prevenção de sobreajuste (*overfitting*). O SVM otimiza eficientemente fronteiras de decisão binárias, e as RNAs modelam não linearidades via camadas ocultas. Em EONs, [Nourmohammadi et al. 2024] utilizaram com sucesso ambos os modelos para prever bloqueios, e [Carvalho et al. 2025] aplicaram SVM no roteamento e alocação espectral adaptativos. Neste artigo, o desempenho e a generalização preditiva dos modelos de ML foram avaliados pelas seguintes métricas: Acurácia, Precisão, *Recall* e *F1-Score*.

4. Resultados e Discussões

Esta Seção apresenta os resultados e é dividida em duas subseções: o estudo preliminar com a base de dados em porções menores e o estudo com a base completa.

4.1. Análise de Dimensionalidade (Fases 5% e 20%) e Abstração Física

Na fase exploratória inicial (5% da base, ou 54.210 instâncias), os classificadores foram treinados com o conjunto original completo de 10 atributos. A extração das métricas (Tabela 1) revelou que a RNA atingiu 79,57% de *F1-Score* e 75,87% de Acurácia.

Tabela 1. Resultados da Fase Exploratória (5% dos Dados, 10 *features*).

Modelo	Acurácia	Precisão	Recall	F1-Score
SVM Linear	74,75%	89,73%	69,33%	78,22%
RNA (MLP)	75,87%	89,18%	71,83%	79,57%

A avaliação de *Permutation Importance* nesta etapa com as 10 variáveis (Figuras 1(a) e 1(b)) elucidou a relevância de cada atributo frente às não linearidades. A análise

indica que atributos de roteamento e topologia, como o peso do enlace, o índice do núcleo e o consumo de energia, apresentaram forte dispersão de importância. Eles atuaram predominantemente como ruído no treinamento, não contribuindo significativamente para refinar as fronteiras de separação.

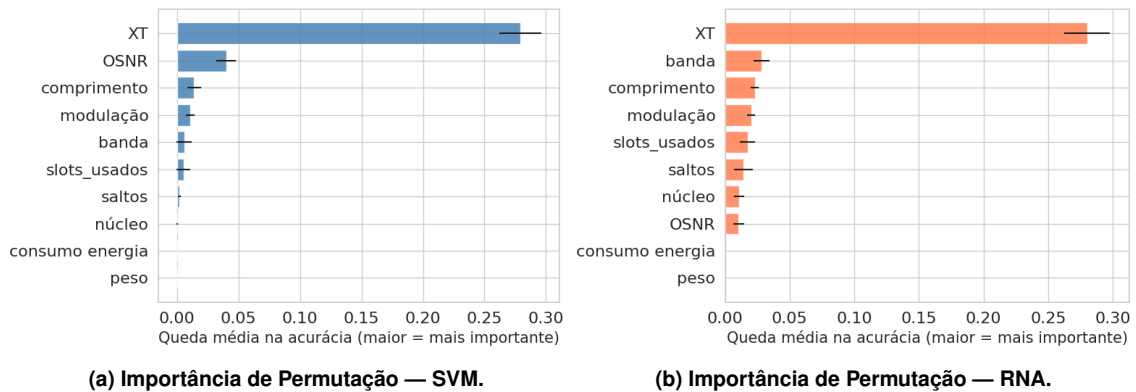


Figura 1. Avaliação exploratória de atributos (amostra de 5%).

Aplicou-se um corte de dimensionalidade de 40% (de 10 para 6 variáveis), isolando as features de maior ganho de informação (XT, OSNR, slots usados, comprimento da rota, formato de modulação e largura de banda). A validação (Fase 2) com 20% dos dados (216.843 amostras) confirmou a estabilidade preditiva do conjunto reduzido. O MLP atingiu 81,69% de F1-Score e 77,63% de Acurácia, provando que a remoção de ruídos manteve intacta a capacidade analítica da rede.

Além da validação dimensional, a extração de importância na fase de 20% com as 6 features (Figura 2) evidenciou o comportamento analítico central dos classificadores de forma mais limpa.

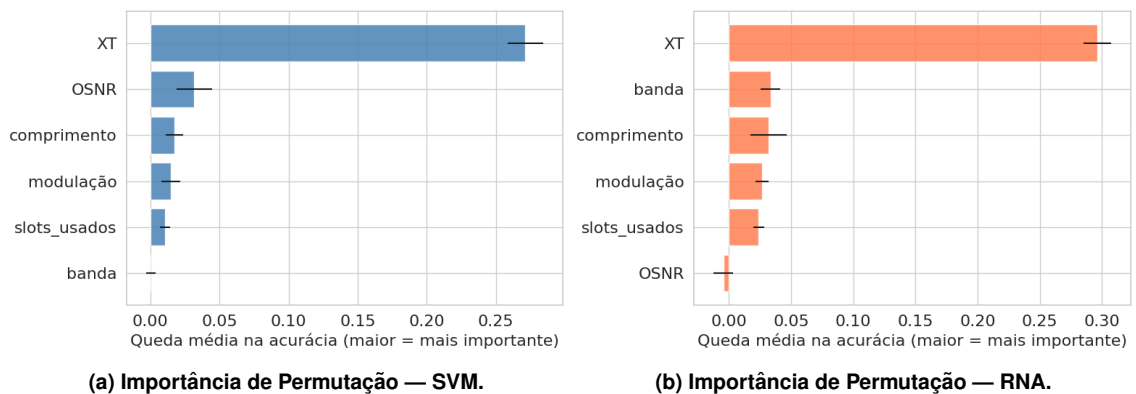


Figura 2. Diferença na abstração de regras físicas com o conjunto reduzido (20%).

Conforme a Figura 2(a), o SVM Linear apresentou forte dependência contínua das métricas diretas de degradação da camada física (XT e OSNR). Em contrapartida, a Figura 2(b) demonstra que, para a arquitetura MLP, a importância analítica explícita da OSNR cai drasticamente em face dos outros parâmetros de rota estruturais, como os slots usados, a banda e o comprimento.

A Rede Neural, via camadas ocultas, comprovou sua capacidade de abstrair não linearidades físicas cruzando parâmetros básicos, reduzindo a dependência da métrica pré-calculada de OSNR. Restrito à sua geometria plana, o SVM não alcançou essa abstração. Reforçando a teoria de redes MCF, o *Crosstalk* confirmou-se como o principal limitador físico em ambos os modelos.

4.2. Desempenho no Conjunto Completo (100% dos Dados)

Validadas as 6 *features* fundamentais, os modelos foram submetidos ao conjunto de teste final, composto por 325.265 amostras, com os resultados apresentados na Tabela 2.

Tabela 2. Comparação de Métricas de Avaliação no Conjunto Completo (6 Features).

Modelo	Acurácia	Precisão	Recall	F1-Score
SVM Linear	74,33%	90,06%	68,29%	77,68%
RNA (MLP)	77,75%	87,79%	76,64%	81,84%

A análise revela que a Rede Neural capturou o comportamento preditivo global de maneira mais eficiente. A RNA superou o SVM na Acurácia geral e impôs uma vantagem considerável no *Recall* e no *F1-Score*. É crucial notar que o SVM apresentou uma Precisão superior (90,06% contra 87,79%). Em termos operacionais, isso indica que o hiperplano linear assume um comportamento excessivamente conservador: raramente erra ao admitir uma conexão, mas, para manter essa margem, bloqueia indevidamente uma quantidade maciça de requisições viáveis (baixo *Recall* de 68,29%).

Esse impacto no controle de admissão é detalhado pelas matrizes de confusão (Figura 3). O modelo RNA admitiu corretamente mais de 163 mil conexões viáveis no teste (Verdadeiros Positivos), minimizando a taxa de cortes indevidos (Falsos Negativos). A alta taxa de *Recall* da rede assegura que ela otimize a utilização espectral da EON sem rejeitar indevidamente clientes, justificando seu *F1-Score* superior.

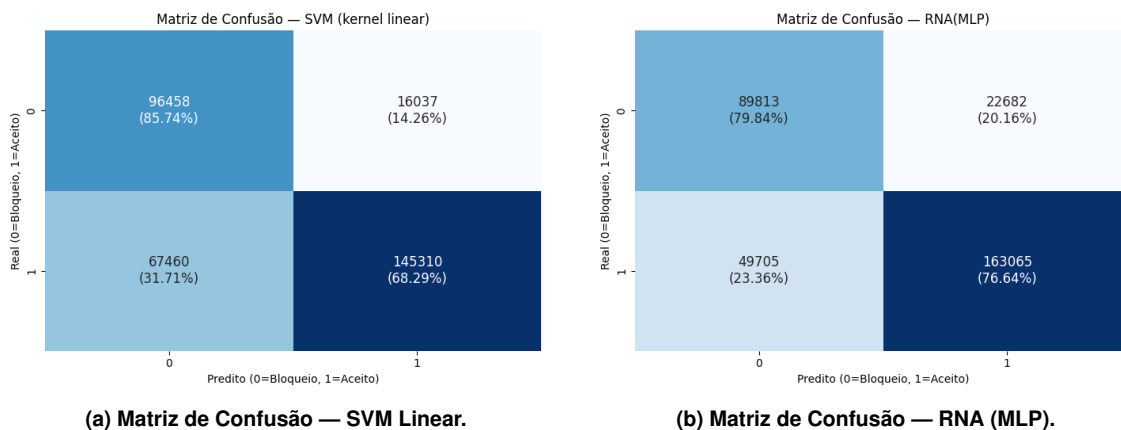


Figura 3. Impacto volumétrico no controle de admissão (Amostras de Teste, 100%).

5. Conclusão e Trabalhos Futuros

A metodologia estruturou-se em escala progressiva (5%, 20% e 100% de 1 milhão de instâncias) para controle de admissão em SDM-EON via aprendizado de máquina. A fase exploratória (5%) provou empiricamente que variáveis topológicas atuavam como ruído computacional. Conseqüentemente, a redução de 10 para as 6 variáveis físicas essenciais otimizou o treinamento nas fases posteriores, preservando integralmente a precisão dos modelos.

A arquitetura MLP superou o classificador linear ao capturar as não linearidades físicas. Na explicabilidade, a RNA abstraiu a complexidade da OSNR a partir de características estruturais da rota, mantendo o XT como limitador dominante. Com F1-Score de 81,84% e Recall de 76,64%, a rede mitigou o bloqueio excessivamente conservador do SVM, sendo a melhor escolha para evitar o desperdício de recursos viáveis da operadora.

Para os trabalhos futuros, o foco migrará da validação de modelos isolados para a integração operacional em funcionamento contínuo. O objetivo é incorporar a arquitetura MLP otimizada diretamente em algoritmos de alocação de recursos em redes ópticas, avaliando o ganho prático de latência computacional em comparação às formulações de camada física e observando a flexibilidade da rede na operação dinâmica em resposta a flutuações severas de tráfego.

Disponibilidade de Artefatos

Os códigos fontes e *notebooks* utilizados neste trabalho estão disponíveis publicamente no repositório GitHub:

https://github.com/MauroGutMB/PROAGRUPAR/tree/otimizacao/notebooks/SVM_RNA

Uso de Inteligência Artificial Generativa

Em conformidade com o Código de conduta da Sociedade Brasileira de Computação (SBC), a utilização de modelos de Inteligência Artificial (IA) Generativa foi empregada para auxiliar nas seguintes etapas deste trabalho:

- **Padronização Textual e Formatação:** O Modelo *Gemini 3.1*(Google) foi utilizado para padronização textual, correção ortográfica e formatação do código LaTeX.
- **Codificação de scripts** O Modelo *Claude Sonnet 4.6*(Anthropic) foi utilizado para a otimização de scripts em Python para o treinamento dos modelos de ML.

Os autores ressaltam que a concepção da pesquisa, a seleção das fontes bibliográficas, a análise crítica dos resultados e a redação final do conteúdo são de autoria humana. As ferramentas de IA foram empregadas exclusivamente como instrumentos de apoio à produtividade, e os autores assumem integral responsabilidade pela originalidade, veracidade e integridade de todo o conteúdo aqui apresentado.

Agradecimento

Este trabalho foi realizado com apoio financeiro da Fundação de Amparo à Pesquisa do Estado do Piauí (FAPEPI) - Edital N° 005/2025, do Programa de Bolsas de Iniciação Científica da FAPEPI - PBIC.

Referências

- Araújo, S. G., Lacerda Jr, J. C., and Soares, A. C. (2025). Circuit reallocation to avoid crosstalk in elastic optical networks with space division multiplexing. In *International Conference on Transparent Optical Networks (ICTON)*.
- Carvalho, R., Pinheiro, D., Dinarte, H., Almeida Jr, R., and Bastos-Filho, C. (2025). Hybrid routing and spectrum allocation in elastic optical networks by machine learning and topological metrics. *Optics*, 6(4):57.
- Habibi, M. and Beyranvand, H. (2019). Impairment-aware manycast routing, modulation level, and spectrum assignment in elastic optical networks. *IEEE/OSA Journal of Optical Communications and Networking*, 11(5):179–189.
- Heera, B. S., Sharma, A., Lohani, V., and Singh, Y. N. (2024). Routing, modulation, core and spectrum assignment techniques for crosstalk management in multi-core fiber based spatially multiplexed elastic optical networks. *Photonic Network Communications*, 48(1-3):35–50.
- Lacerda Jr, J. C., Cartaxo, A. V., and Soares, A. C. (2024). Novel dynamic impairment-aware algorithm for modulation, core, and spectrum assignment in sdm-eons. *Optical Switching and Networking*, 51:100763.
- Lacerda Jr, J. C., Sousa, C. E., Morais, A. G., Cartaxo, A. V., and Soares, A. C. (2025). Machine learning-based algorithm for core allocation in spatial division multiplexing elastic optical networks. *Optical Fiber Technology*, 91:104155.
- Lobato, F. R., Jacob, A., Rodrigues, J., Cartaxo, A. V., and Costa, J. (2019). Inter-core crosstalk aware greedy algorithm for spectrum and core assignment in space division multiplexed elastic optical networks. *Optical Switching and Networking*, 33:61–73.
- Nourmohammadi, F., Parmar, C., Wings, E., and Comellas, J. (2024). Using convolutional neural networks for blocking prediction in elastic optical networks. *Applied Sciences*, 14(5):2003.
- Oliveira, H. and Fonseca, N. (2020). Uma estratégia de proteção eficiente em eons-sdm utilizando p-cycle fipp. In *Anais do XXXVIII Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos*, pages 155–168, Porto Alegre, RS, Brasil. SBC.
- Petale, S. and Subramaniam, S. (2024). Clara+: dual machine learning optimized resource assignment for translucent sdm-eons. *Journal of Optical Communications and Networking*, 16(10):F1–F12.
- Ravipudi, J. L. and Brandt-Pearce, M. (2024). Machine-learning-based impairment-aware dynamic rmsca in multi-core elastic optical networks. *Journal of Optical Communications and Networking*, 16(10):F26–F39.
- Zhang, S. and Yeung, K. L. (2023). Revisiting the modulation format selection problem in crosstalk-aware sdm-eons. *Computer Networks*, 221:109524.