

Algoritmo Baseado em Aprendizado de Máquina para Alocação de Núcleo em Redes Ópticas Elásticas com Multiplexação Espacial

Jurandir C. Lacerda Jr^{1,2}, Adolfo V. T. Cartaxo³, André C. B. Soares¹

¹ Programa de Pós-Graduação em Ciência da Computação em associação UFMA/UFPI
Universidade Federal do Piauí (UFPI)
Teresina-PI, Brasil

²Instituto Federal de Educação, Ciência e Tecnologia do Piauí (IFPI)
Corrente-PI, Brasil

³Instituto de Telecomunicações, Departamento de Ciências e Tecnologias da
Informação (DCTI), Iscte - Instituto Universitário de Lisboa
Lisboa, Portugal

jurandir.cavalcante@ifpi.edu.br

Abstract. *Spatial division multiplexing elastic optical networks (SDM-EON) using multicore fibers (MCF) are promising candidates for the future transport networks. In MCFs, a new dimension is added to the resource allocation problem: core allocation. In this paper, a machine learning algorithm for core allocation (AMN) in SDM-EONs is proposed. Compared with other solutions in the literature and a scenario with a low crosstalk level, AMN achieves at least 25.35% gain in terms of request blocking probability (RBP) and at least 24.81% for blocked data ratio (BDR). In a scenario with a high crosstalk level, AMN achieves at least 8.16% gain for RBP and at least 9.28% for BDR.*

Resumo. *Redes ópticas elásticas com multiplexação por divisão espacial (SDM-EON), usando fibras multi-núcleos (MCF), são promissoras para as futuras redes de transporte. Em MCFs, surge uma nova dimensão no problema de alocação de recursos: a alocação do núcleo. Este artigo propõe o algoritmo com aprendizado de máquina para escolha de núcleo (AMN) em SDM-EONs. Comparado com outras soluções e em cenário com baixa incidência de crosstalk, o AMN obteve ganhos de ao menos 25,35% em termos de probabilidade de bloqueio de requisição (PBR) e de ao menos 24,81% em termos de razão de dados bloqueados (RDB). Em cenário de alta incidência de crosstalk, o AMN obteve ganhos de ao menos 8,16% para PBR e de ao menos 9,28% para RDB.*

1. Introdução

A rede óptica elástica com multiplexação por divisão espacial (*spatial-division multiplexing elastic optical network* - SDM-EON), em particular usando fibras multi-núcleo (*multi-core fiber* - MCF), vem sendo estudada nos últimos anos pela comunidade científica para dar resposta às necessidades crescentes de capacidade nas redes de transporte. Neste tipo de rede, além da possibilidade de atendimento de vários clientes em uma única fibra óptica, pode-se enviar informação proveniente de vários clientes em cada

um dos núcleos. No entanto, este tipo de fibra apresenta desafios para o seu uso em EONs. Um destes desafios é o *crosstalk* (XT) inter-núcleo [Hayashi et al. 2011]. O XT é um tipo de interferência que ocorre quando a mesma faixa de frequência é utilizada por dois núcleos próximos. Quanto menor a distância entre os núcleos, maior o efeito do XT.

Outro desafio para o planejamento de uma SDM-EON é o problema de roteamento, escolha de modulação, alocação de núcleo e espectro (*routing, modulation, spectrum and core allocation* - RMSCA) [Muhammad et al. 2015] [Brasileiro et al. 2020]. Tal problema deve ser resolvido toda vez que o plano de controle da rede for alocar um novo caminho óptico. Os caminhos ópticos são usados para transportar informação entre dois pontos na rede. O problema RMSCA consiste em quatro subproblemas: *i*) roteamento, que consiste em escolher uma rota entre um nó de origem O e um nó de destino D na rede; *ii*) escolha da modulação, que consiste em definir qual o formato de modulação será usado pelo caminho óptico. A modulação é a forma de codificação da informação (representada por bits) em sinais digitais [Tanenbaum and Wetherall 2011]; *iii*) escolha do núcleo, onde o plano de controle deve escolher qual dos núcleos da fibra será usado pelo caminho óptico; e *iv*) alocação de espectro, que consiste definir qual porção espectral será usada pelo caminho óptico. O espectro óptico, em uma rede óptica elástica, é dividido em porções de 12,5 GHz denominadas *slots* de frequência [ITU-T G.694.1 2020].

O uso de aprendizado de máquina (*machine learning* - ML) mostra-se promissor para diversas subáreas das redes ópticas [Zhang et al. 2020]. Isso devido ao fato que os algoritmos de ML podem aprender padrões a partir do histórico de execução de outros algoritmos. Assim, elimina-se a necessidade de executar algoritmos RMSCA complexos no momento de operação da rede. O uso de ML para o problema específico de alocação de núcleo e espectro em SDM-EON ainda não foi amplamente estudado na literatura.

O objetivo deste artigo é propor uma solução para a alocação de núcleo em SDM-EON. Para isso, o algoritmo com aprendizado de máquina para escolha de núcleo (AMN) é proposto para SDM-EON. O AMN utiliza uma rede neural artificial para aprender comportamentos da rede e auxiliar na alocação de núcleo de forma a reduzir a ocorrência de XT. Como contribuições, o AMN oferece ganho em termos de probabilidade de bloqueio de requisição e razão de dados bloqueados, considerando as principais limitações de camada física, quando comparados a outros trabalhos. Além disso, o AMN inova ao introduzir o uso de técnicas de ML no contexto de alocação de núcleos em SDM-EONs.

O restante deste artigo está organizado da seguinte forma: A Seção 2 apresenta os trabalhos relacionados ao tema deste artigo. As limitações de camada física são discutidas na Seção 3. A Seção 4 apresenta a solução proposta neste artigo. A avaliação de desempenho do algoritmo proposto é apresentada na Seção 5. Por fim, as conclusões deste trabalho são apresentadas na Seção 6.

2. Trabalhos Relacionados

Tradicionalmente existem duas formas de considerar o *crosstalk* ao resolver o problema RMSCA em SDM-EONs. As estratégias *XT-aware* são cientes de *crosstalk* e utilizam os valores e níveis de *crosstalk* em tempo real para a tomada de decisão no problema RMSCA. Já as estratégias *XT-avoid* buscam alocar os recursos da rede de forma a evitar o *crosstalk* sem possuir os valores em tempo real. Apesar de bons níveis de eficiência, as estratégias *XT-aware* introduzem um alto custo computacional para serem executa-

das. Buscando eficiência e baixo custo computacional, este artigo aborda o problema de alocação de recursos em SDM-EON através de métodos *XT-avoid*.

Em [Fujii et al. 2014] é proposta uma estratégia *XT-avoid* de alocação de núcleo e espectro. Os autores propõem uma política de priorização de núcleo, nomeada de *core prioritization* (CP). Tal política busca evitar o XT entre núcleos ao balancear o uso de cada núcleo da fibra óptica. Os autores também propõem uma estratégia para mitigar a fragmentação espectral na rede.

Os autores em [Yaghubi-Namaad et al. 2018] apresentam uma solução para o problema de roteamento, nível de modulação, espaço e atribuição de espectro (RMLSSA). Os autores apresentaram um modelo de programação linear inteira e utilizaram uma matriz de tráfego estático para as simulações. Além disso, os autores apresentaram um algoritmo guloso com quatro políticas de ordenação para o problema RMLSSA. Por fim, o artigo avalia a eficácia das propostas através de diferentes métricas de avaliação de desempenho.

Em [Araújo et al. 2021] é proposto o algoritmo de distanciamento espectral inter-núcleos (ADEIN). Com o objetivo de evitar o XT, o ADEIN realiza um balanceamento no uso dos recursos através do uso de um sistema de pontuação e divisão de grupos de prioridades. Tal sistema de pontuação consiste na criação de uma tabela atualizada a cada alocação de um novo caminho óptico, onde tal tabela serve como referência para a escolha dos futuros caminhos ópticos candidatos.

Os autores em [Lacerda Jr et al. 2021] propõem duas estratégias para alocação de núcleo e espectro, nomeadas de *core balancing algorithm* (CBA) e *spectrum balancing algorithm* (SBA). Tais estratégias avaliam a condição de utilização dos núcleos vizinhos ao núcleo sob teste, e buscam alocar o novo caminho óptico em núcleos e regiões espectrais com menor probabilidade de sobreposição espectral e, conseqüentemente, reduzir o XT. Para isso, os autores propõem três métricas para avaliar a utilização dos núcleos: i) *total use in neighbors* (TUN), ii) *weighted use of neighbors* (WUN) e iii) *use in the candidate core* (UC). A Tabela 1 apresenta as características de alguns trabalhos para escolha de núcleo e espectro em SDM-EON.

Tabela 1. Comparação entre algoritmos de alocação de recursos em SDM-EONs.

Referência	Avaliação do XT	Tipo de Tráfego	Nº de Núcleos
[Fujii et al. 2014]	<i>XT-avoid</i>	dinâmico	7, 12 e 19
[Yaghubi-Namaad et al. 2018]	<i>XT-avoid</i>	estático	7, 12 e 19
[Araújo et al. 2021]	<i>XT-avoid</i>	dinâmico	7
[Lacerda Jr et al. 2021]	<i>XT-avoid</i>	dinâmico	7
[Klinkowski and Zalewski 2019]	<i>XT-aware</i>	dinâmico	3, 7 e 12
[Lobato et al. 2019]	<i>XT-aware</i>	dinâmico	7
[Moghaddam et al. 2020]	<i>XT-aware</i>	estático	3 e 7

Nos últimos anos, a comunidade científica vem utilizando técnicas de ML nas mais diversas áreas. Em redes ópticas elásticas, o uso de técnicas de ML também vem mostrando-se promissora. Em [Monteiro et al. 2020] redes neurais artificiais são utilizadas para o dimensionamento da banda de guarda. Em [Klinkowski et al. 2020] a técnica *k-nearest neighbors* (KNN) é utilizada para auxiliar na escolha do formato de modulação

utilizado. Já em [Yao et al. 2018] técnicas como a rede neural e a regularização Bayesiana são utilizadas para a predição de XT. Entretanto, segundo o conhecimento dos autores deste artigo, ainda é escasso o uso de ML para o problema específico de escolha de núcleo em SDM-EON. A investigação desta oportunidade de pesquisa é uma das contribuições deste artigo, que propõe o uso de redes neurais para definir o melhor núcleo a ser usado, sem o conhecimento dos níveis de XT (isto é, *XT-avoid*), em SDM-EONs.

3. Avaliação das Limitações da Camada Física em SDM-EONs

Devido a várias imperfeições da camada física, a qualidade de transmissão (*quality of transmission* - QoT) do caminho óptico se degrada enquanto o sinal se propaga ao longo da fibra e dos equipamentos que compõem a rede. Neste artigo são considerados três fatores limitadores de desempenho pela camada física: *i*) o ruído de emissão espontânea amplificada (*amplified spontaneous emission* - ASE); *ii*) os efeitos não-lineares; e *iii*) o *crosstalk* inter-núcleo.

A amplificação óptica geralmente é realizada por amplificadores de fibra dopada com érbio (*erbium doped fiber amplifier* - EDFA), que estão posicionados após cada nó da rede e após cada *span* (ex: a cada 80km). Os EDFAs adicionam ruído ASE ao sinal óptico [Yan et al. 2015]. Além do ruído ASE, os efeitos não-lineares também se manifestam devido à propagação ao longo da fibra óptica, fazendo com que um caminho óptico cause interferência em si mesmo (*self-phase modulation* - SPM) e também em outros caminhos ópticos, através da modulação de fase cruzada (*cross-phase modulation* - XPM) e mistura de quatro ondas (*four-wave mixing* - FWM). Neste artigo, o modelo apresentado em [Poggiolini and Jiang 2017], que é baseado em um modelo de ruído Gaussiano aprimorado (*enhanced Gaussian-noise* - EGN) [Carena et al. 2014], é usado para calcular a densidade espectral de potência (*power spectral density* - PSD) dos efeitos não lineares (SPM, XPM e FWM).

Uma maneira de medir os níveis de QoT da rede é por meio da relação sinal-ruído óptico (*optical signal to noise ratio* - OSNR). A OSNR estabelece uma relação entre a PSD do caminho óptico e a PSD do ruído ASE e da interferência não lineares que o afeta. A OSNR é usada como um dos critérios de QoT neste artigo e é dada por

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

onde G_m é a PSD do sinal usado no caminho óptico m . G_m^{ASE} é a PSD total de ruído ASE gerado por todos os EDFAs usados pelo caminho óptico m . G_m^{NLI} é a PSD total dos efeitos não lineares que afetam o caminho óptico m . Por limitações na quantidade de páginas deste artigo, as equações do cálculo de G_m^{ASE} e G_m^{NLI} não são apresentados. Entretanto, estas equações podem ser encontradas em [Habibi and Beyranvand 2019].

Outra importante característica de uma SDM-EON, considerada como segundo critério de QoT neste artigo, é o *crosstalk* inter-núcleos [Hayashi et al. 2011]. Em [Lobato et al. 2019] é apresentado um modelo para mensurar a potência média de XT (normalizada pela potência de sinal do caminho óptico) em um determinado caminho óptico m . Esta potência normalizada média de XT é dada por

$$XT_{\mu,m}^{(tot)} = \sum_{e=1}^{|E_m|} XT_{\mu,m,e}, \quad (2)$$

em que $|E_m|$ é a quantidade de enlaces que compõem o caminho óptico m e e é o índice que identifica um enlace deste conjunto. $XT_{\mu,m,e}$ é a potência normalizada média de XT gerada no enlace e do caminho óptico m dada por [Lobato et al. 2019]

$$XT_{\mu,m,e} = \frac{P_{XT_{m,e}}}{P_m}, \quad (3)$$

onde $P_{XT_{m,e}}$ é a potência média de XT (não normalizada) do caminho óptico m gerada no enlace e e P_m corresponde à potência de sinal do caminho óptico m . O valor de $P_{XT_{m,e}}$ é calculado por [Lobato et al. 2019]

$$P_{XT_{m,e}} = \sum_{n=1}^{N_{m,e}} (I_{SO_{m,e,n}} \cdot P_n \cdot h_e \cdot L_e), \quad (4)$$

em que $N_{m,e}$ é a quantidade de caminhos ópticos alocados em núcleos adjacentes ao núcleo do caminho óptico m , que utilizam a mesma fração do espectro (em todo ou em parte) do caminho óptico m no enlace e e n é o índice que identifica o caminho óptico interferente. P_n é a potência de sinal do n -ésimo caminho óptico adjacente de $N_{m,e}$ caminhos ópticos possíveis, L_e é o comprimento do enlace e e h_e representa o coeficiente de acoplamento de potência da fibra. $I_{SO_{m,e,n}}$ é o índice de sobreposição de *slots* entre os caminhos ópticos m e n no enlace e , dado por [Lobato et al. 2019]

$$I_{SO_{m,e,n}} = \frac{S_{SO_{m,e,n}}}{S_{e,n}}. \quad (5)$$

onde $S_{SO_{m,e,n}}$ é a quantidade de *slots* sobrepostos entre os caminhos ópticos m e n no enlace e , isto é, quantos dos *slots* do caminho óptico m possuem *slots* de mesmo índice alocados no caminho óptico n (desconsiderando banda de guarda) no enlace e , e $S_{e,n}$ é a quantidade de *slots* do caminho óptico n no enlace e .

Os critérios de QoT (OSNR e XT) são consideradas ao alocar um novo caminho óptico em uma SDM-EON. Quando o plano de controle recebe uma requisição para o estabelecimento de um novo caminho óptico, calcula-se uma rota entre o nó de origem e o nó de destino juntamente com o formato de modulação, o núcleo e o conjunto de *slots* a serem usados. Caso não existam recursos livres, a requisição será bloqueada. Existindo disponibilidade de recursos, o plano de controle analisa a OSNR (que engloba o ruído ASE e os efeitos não-lineares) e o nível de XT para o caminho óptico candidato. Caso a OSNR do caminho óptico candidato não esteja adequada, ocorrerá um bloqueio por ausência de QoT no novo caminho óptico (QoTN). Caso contrário, será analisado o impacto da possível alocação deste caminho óptico nos caminhos ópticos já estabelecidos. Se tal impacto afetar algum dos caminhos ópticos já estabelecidos de tal forma que a sua OSNR fique abaixo do limiar estabelecido, o caminho óptico candidato sofrerá um bloqueio por ausência de QoT para os outros caminhos ópticos (QoTO). Por fim, observa-se o XT para o caminho óptico candidato. Caso o valor de XT seja aceitável, o caminho óptico é estabelecido. Para avaliar se um determinado valor de OSNR ou XT é aceitável, verifica-se se o mesmo está de acordo com os seus limiares pré-estabelecidos de QoT. Tais limiares são listados na Tabela 2 da Seção 5.

4. Algoritmo Proposto

Neste artigo é proposto o algoritmo com aprendizado de máquina para escolha de núcleo (AMN) em SDM-EONs. O AMN utiliza uma rede neural artificial (RNA) para aprender o comportamento de outro algoritmo em determinados estados da rede e extrair características chaves para a alocação de núcleo. A RNA do AMN é treinada para aprender com o histórico de sucesso de outro algoritmo e produzir resultados melhores sem necessidade de execução deste algoritmo. O fluxo de funcionamento do AMN é composto de três passos: o primeiro passo constitui a criação de uma base de dados, o segundo passo corresponde ao treinamento da RNA e o terceiro passo constitui a execução do AMN durante a fase de funcionamento da rede. O fluxo do AMN é mostrado na Figura 1.

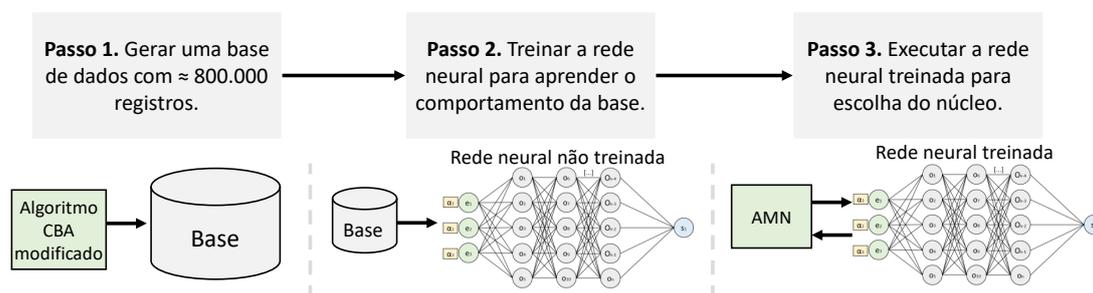


Figura 1. Fluxo de funcionamento do algoritmo AMN.

No processo de criação da base de dados, outro algoritmo é executado (via simulação) e os valores de alguns atributos são salvos para cada requisição feita ao plano de controle da rede. O algoritmo utilizado para a criação da base de dados é o CBA-SBA [Lacerda Jr et al. 2021]. Já os atributos considerados, em um total de dezessete, são: *i*) comprimento da rota, representado por um valor numérico; *ii*) número de saltos da rota, representado por um valor numérico; *iii*) formato de modulação utilizado, representado por um valor numérico; *iv*) a utilização espectral absoluta dos vizinhos de cada um dos sete núcleos (métrica TUN do algoritmo CBA), representado por sete valores numéricos; e *v*) a utilização espectral ponderada dos vizinhos de cada um dos sete núcleos (métrica WUN do algoritmo CBA), representado por sete valores numéricos. Estas duas formas de utilização (TUN e WUN) são descritas no algoritmo CBA [Lacerda Jr et al. 2021] e podem ser ajustadas para fibras com outras quantidades de núcleos. Tais atributos, como o comprimento da rota e a utilização espectral de cada núcleo, possuem ligação com a ocorrência de XT. Portanto, a escolha destes atributos justifica-se para que a RNA seja capaz de identificar situações propícias à ocorrência de XT, sem recorrer ao custoso processo de calcular o XT. Destaca-se que a base de dados é formada apenas com os casos em que a requisição é estabelecida, isto é, os casos em que não houve bloqueio. Isso garante que futuramente a RNA aprenda apenas os casos de sucesso do CBA-SBA.

A base gerada a partir do CBA-SBA possui 844.631 registros, que correspondem as requisições não bloqueadas de um total de 1.000.000 de requisições geradas em diferentes pontos de carga da rede. Cada registro salvo é composto pelos dezessete atributos em um determinado estado da rede (chegada da requisição) mais o núcleo escolhido pelo CBA para aquele estado da rede. O uso do CBA para criação da base de dados justifica-se devido aos critérios bem definidos de escolha de núcleo, através das métricas TUN, WUN e UC. Assim, o AMN alcança melhores níveis de acurácia no processo de treinamento.

O passo dois é onde a RNA é treinada a partir da base de dados gerada pelo algoritmo CBA-SBA. A RNA utilizada possui uma camada de entrada composta por dezessete neurônios, onde cada um representa um dos dezessete atributos. A RNA também possui três camadas ocultas de 128, 64 e 32 neurônios [Monteiro et al. 2020] com o modo de ativação *ReLU* [LeCun et al. 2015]. A última camada (camada de saída) é composta por sete neurônios com o modo de ativação *softmax* [Monteiro et al. 2020], onde cada um dos neurônios correspondem a um dos núcleos da fibra. A Figura 2 apresenta a arquitetura da rede neural do AMN.

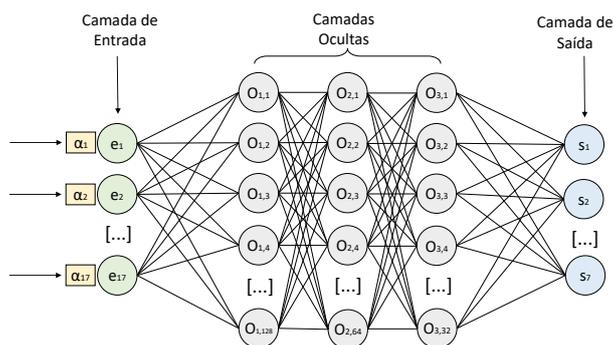


Figura 2. Arquitetura da rede neural artificial do AMN.

O processo de treinamento consiste no ajuste dos pesos da rede. Durante o treinamento, a base de dados é dividida na proporção de 80% dos dados para treinamento e 20% para testes. Isto é, os pesos são ajustados com um conjunto de 675.704 registros da base de dados. Após o treinamento, a performance da RNA é verificada com o conjunto de teste (168.926 registros) para apurar se a RNA é capaz de prever os núcleos em condições reais de utilização. No processo de teste, a RNA atingiu 98,93% de acurácia.

Os passos um e dois ocorrem em um momento *offline* da rede. Já o passo três é executado durante o funcionamento da rede para a alocação de núcleo. Nesta etapa, para cada requisição de novo caminho óptico que chega ao plano de controle, o AMN alimenta a sua RNA com os dezessete atributos (estado atual da rede) e executa a RNA já treinada. No processo de execução da RNA, a mesma retorna o núcleo a ser escolhido. O AMN então retorna o núcleo escolhido ao plano de controle da rede para que o mesmo seja alocado. Vale ressaltar que o AMN efetua a alocação de núcleo, podendo ser utilizado em conjunto com uma gama de algoritmos de roteamento e alocação de espectro da literatura.

5. Avaliação de Desempenho

Para o estudo de avaliação de desempenho deste trabalho, foi utilizado o simulador *SLICE Network Simulator* (SNetS) [Fontinele et al. 2017]. Para as simulações foram geradas 100.000 requisições de caminhos ópticos em cada simulação. A geração de requisições é um processo de *Poisson* com taxa média de λ e o tempo médio de retenção dos caminhos ópticos é distribuído exponencialmente com média $1/\mu$. A carga de tráfego é distribuída uniformemente entre todos os pares de nós origem e destino. São geradas requisições de 100, 200, 300, 400 e 500 Gbps, seguindo a proporção de chegadas de 5, 4, 3, 2, 1, respectivamente. Isto é, a cada chegada de requisição solicitando 500 Gbps, chegam cinco requisições solicitando 100 Gbps. A carga, em Erlangs, pode ser definida por $\rho = \lambda/\mu$.

Para cada cenário de avaliação foram realizadas 10 simulações com diferentes sementes de geração de variável aleatória. Todos os resultados possuem nível de confiança de 95%. As topologias consideradas nas simulações são a NSFNet e a EURO28 (Figura 3).

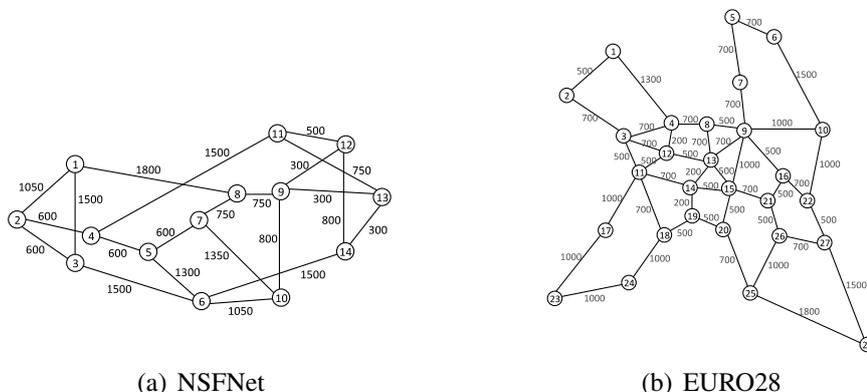


Figura 3. Topologias de rede com os comprimentos dos enlaces em km.

Em geral, a topologia EURO28 possui rotas mais longas que a topologia NSFNet. A rota de comprimento máximo na topologia EURO28 possui 5.700 km, contra 3.350 km da topologia NSFNet. O comprimento médio das rotas na topologia EURO28 é de 2.222 km, com desvio padrão de 1.126 km. Já na topologia NSFNet, o comprimento médio das rotas é de 1.840 km, com desvio padrão de 846 km. Portanto, as rotas mais longas na topologia EURO28 sofrem com maior incidência de XT quando comparado com as rotas mais longas da topologia NSFNet. Isso ocorre pois o comprimento da rota impacta diretamente no nível de XT, como apresentado na Equação 4.

São usados quatro formatos de modulação, sendo eles: BPSK, QPSK, 8-QAM e 16-QAM. A distância máxima suportada por cada formato de modulação, juntamente com seus respectivos limiares de OSNR por símbolo e de XT são apresentados na Tabela 2 [Gong et al. 2013], [Ives et al. 2015], [Moghaddam et al. 2020].

Tabela 2. Parâmetros de modulação e limiares de OSNR e XT.

	BPSK	QPSK	8-QAM	16-QAM
Distância	10.000 km	5.000 km	2.500 km	1.250 km
Limiar de OSNR	5,5 dB	8,5 dB	12,5 dB	15,1 dB
Limiar de XT	-14 dB	-18,5 dB	-21 dB	-25 dB

A largura de banda do caminho óptico i , B_i , com uma determinada taxa de bits de informação $R_{b,i}$, nível de modulação M (número de símbolos distintos do esquema de modulação) e sobrecarga FEC F é dada por: $B_i = 1,1R_{b,i} (1 + F) / (2 \log_2 M)$ [Gao et al. 2014]. Assim, um número inteiro de *slots* deve ser atribuído para cobrir esta demanda por largura de banda. No cenário simulado, cada fibra possui sete núcleos. Cada núcleo é dividido em 320 *slots* de frequência, em que cada *slot* possui 12,5 GHz. A banda de guarda possui largura de banda de um *slot*. Outros parâmetros utilizados estão listados na Tabela 3 [Beyranvand and Salehi 2013], [Zhao et al. 2015], [Lobato et al. 2019].

Os algoritmos são avaliados em termos de probabilidade de bloqueio de requisição (PBR) e razão de dados bloqueados (RDB). A PBR quantifica quantas requisições so-

Tabela 3. Parâmetros de camada física utilizados nas simulações.

Descrição	Valor
Atenuação da fibra (α)	0,2 dB/km
Parâmetro de dispersão da fibra (D)	16 ps/nm/km
Coefficiente de não-linearidade da fibra (γ)	$1,3 (\text{W}\cdot\text{km})^{-1}$
Comprimento de um <i>span</i> (L_s)	80 km
Coefficiente de acoplamento de potência (h_l)	$6,4 \times 10^{-9} \text{ m}^{-1}$ ou $1,5 \times 10^{-9} \text{ m}^{-1}$

freram bloqueio em relação ao total de requisições. A RDB é dada por $RDB = (\sum_{i(\text{c.o. bloqueados})} R_{b,i} \cdot T_i) / (\sum_{i(\text{c.o. requisitados})} R_{b,i} \cdot T_i)$, onde $R_{b,i}$ é a taxa de bits do i -ésimo caminho óptico solicitado e T_i é o tempo de retenção do i -ésimo caminho óptico solicitado. O objetivo da métrica RDB é avaliar a quantidade de dados que deixaram de ser transportados na rede devido ao bloqueio. Para todos os algoritmos avaliados nesta Seção, o algoritmo de menor caminho de *Dijkstra* [Dijkstra 1959] é utilizado para a escolha da rota. Para todos os algoritmos avaliados, o formato de modulação escolhido para cada caminho óptico é aquele com maior valor de M e que respeite o alcance máximo suportado por cada formato de modulação (Tabela 2). Para a avaliação do AMN, o algoritmo SBA [Lacerda Jr et al. 2021] é utilizado para a escolha dos *slots* de frequência. O AMN é comparado com outros três algoritmos *XT-avoid* propostos na literatura: *i*) o algoritmo CBA-SBA [Lacerda Jr et al. 2021] (que é usado para gerar a base de dados do AMN); *ii*) o algoritmo ADEIN [Araújo et al. 2021]; e *iii*) o algoritmo *core prioritization* [Fujii et al. 2014] em conjunto com a estratégia de alocação de espectro *random fit*, referenciado a seguir como CPRF.

A avaliação de desempenho é realizado em dois cenários: um com alta incidência de XT (AXT) e um com baixa incidência de XT (BXT). Para simular estes dois cenários, o coeficiente de acoplamento de potência da fibra (h_l) é ajustado para $6,4 \times 10^{-9} \text{ m}^{-1}$ no cenário de AXT [Lobato et al. 2019] e $1,5 \times 10^{-9} \text{ m}^{-1}$ no cenário de BXT [Lobato et al. 2019]. Esta abordagem verifica o desempenho das propostas em diferentes tipos de MCFs. A Figura 4 apresenta os resultados de PBR para o cenário AXT.

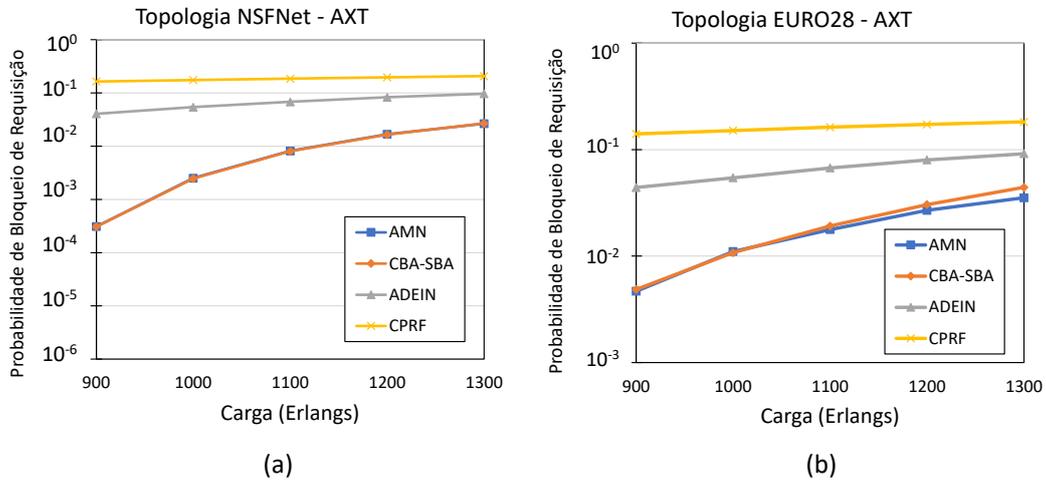


Figura 4. Probabilidade de bloqueio de requisição com alta incidência de XT.

O algoritmo AMN apresenta melhores resultados em termos de PBR quando comparado aos algoritmos CPRF e ADEIN em ambas as topologias. O ganho do AMN é calculado por $G = (R_n - R_{AMN})/R_n$, onde R_{AMN} é o resultado (PBR ou RDB) do AMN e R_n é o resultado (PBR ou RDB) dos concorrentes avaliados (CPRF, ADEIN ou CBA-SBA). O ganho do AMN em relação ao CPRF com uma carga de 1300 Erlangs (último ponto de carga) foi de 87,19% na topologia NSFNet (Figura 4 (a)) e 80,64% na topologia EURO28 (Figura 4 (b)). Em relação ao ADEIN, o AMN atingiu um ganho de 72,56% no último ponto de carga na topologia NSFNet e 61,42% na topologia EURO28. No cenário de alta incidência de XT, os resultados do AMN foram similares ao CBA-SBA. Na topologia NSFNet, os resultados são equivalentes considerando a margem de intervalo de confiança. Já na topologia EURO28, o AMN obteve um ganho em relação ao CBA-SBA de 20,19% no ponto de 1300 Erlangs. O ganho do AMN em relação ao CBA-SBA aumentou no cenário de baixo XT, como apresentado na Figura 5.

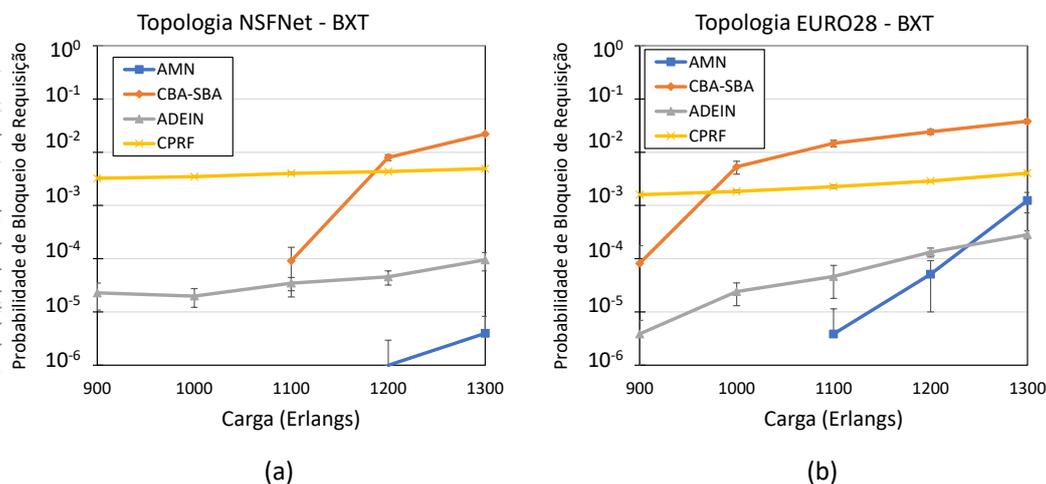


Figura 5. Probabilidade de bloqueio de requisição com baixa incidência de XT.

Na Figura 5 observa-se uma melhora do AMN em relação aos demais algoritmos, na mesma janela de cargas da Figura 4. O ganho do AMN em relação ao CPRF com uma carga de 1300 Erlangs (último ponto de carga) foi de 99,91% na topologia NSFNet (Figura 5 (a)) e 69,26% na topologia EURO28 (Figura 5 (b)). Em relação ao CBA-SBA, o AMN atingiu um ganho de 99,98% no último ponto de carga na topologia NSFNet e 96,75% na topologia EURO28. O ganho do AMN em relação ao ADEIN foi de 95,83% no último ponto de carga da topologia NSFNet. O algoritmo ADEIN obteve, de forma geral, o segundo melhor desempenho entre os algoritmos avaliados, chegando a obter melhor resultado que o AMN no ponto de 1300 Erlangs da topologia EURO28. Entretanto, o AMN alcançou melhores resultados médio em relação aos demais algoritmos no cenário de baixa incidência de XT em termos de probabilidade de bloqueio de requisição. Os resultados em termos de RDB, em cenário com alto XT, são mostrados na Figura 6.

O algoritmo AMN apresenta melhores resultados em termos de RDB quando comparado aos algoritmos CPRF e ADEIN em ambas as topologias. O ganho do AMN em relação ao CPRF com uma carga de 1300 Erlangs (último ponto de carga) foi de 82,56% na topologia NSFNet (Figura 6 (a)) e 76,37% na topologia EURO28 (Figura 6 (b)). Em relação ao ADEIN, o AMN atingiu um ganho de 68,32% no último ponto de carga na

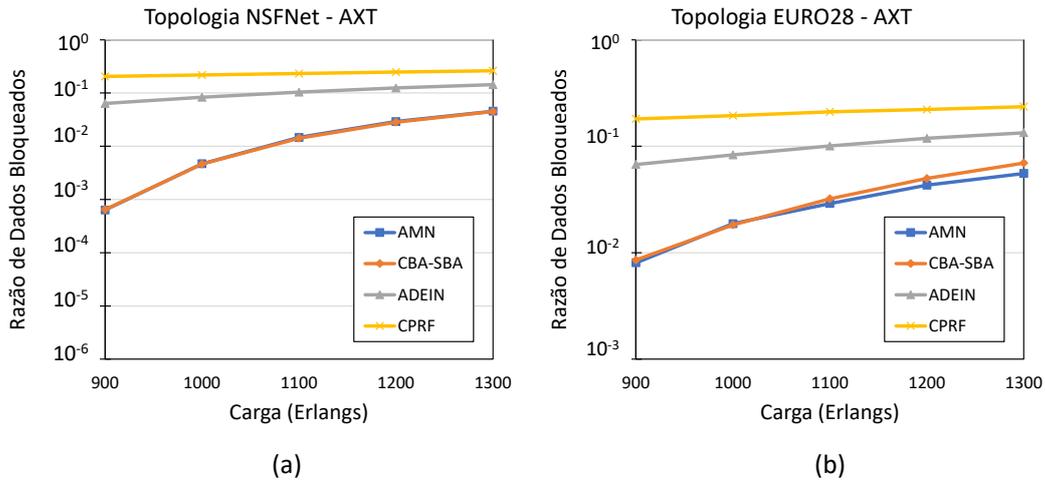


Figura 6. Razão de dados bloqueados com alta incidência de XT.

topologia NSFNet e 58,51% na topologia EURO28. Na métrica de RDB, assim como na métrica de PBR, os resultados do AMN foram similares ao CBA-SBA no cenário de alto XT. Entretanto, o AMN obteve um ganho em relação ao CBA-SBA de 20,05% no ponto de 1300 Erlangs da topologia EURO28. Em termos de RDB, o ganho do AMN em relação ao CBA-SBA aumentou no cenário de baixo XT, como mostrado na Figura 7.

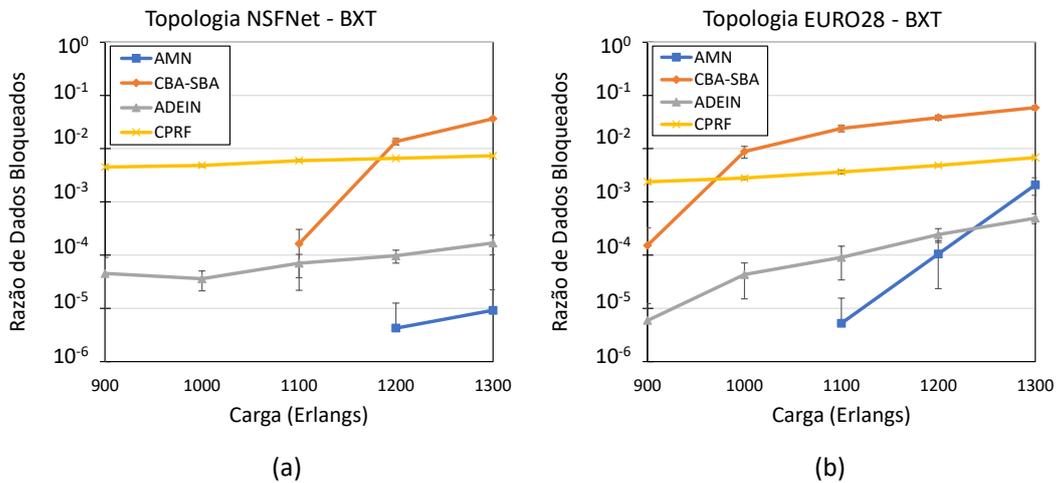


Figura 7. Razão de dados bloqueados com baixa incidência de XT.

Na Figura 7 observa-se uma melhora do AMN em relação aos demais algoritmos, na mesma janela de cargas da Figura 6. O ganho do AMN em relação ao CPRF com uma carga de 1300 Erlangs foi de 99,87% na topologia NSFNet (Figura 7 (a)) e 69,33% na topologia EURO28 (Figura 7 (b)). Em relação ao CBA-SBA, o AMN atingiu um ganho de 99,97% no último ponto de carga na topologia NSFNet e 96,46% na topologia EURO28. O ganho do AMN em relação ao ADEIN foi de 94,57% no último ponto de carga da topologia NSFNet. Novamente, o algoritmo ADEIN obteve um melhor resultado que o AMN no ponto de 1300 Erlangs da topologia EURO28 (no cenário BXT). Entretanto, o AMN alcançou melhores resultados nos demais pontos de carga. A Tabela 4 apresenta

o ganho médio do AMN em relação ao CPRF, ADEIN e CBA-SBA. O ganho médio consiste na média entre os ganhos obtidos nos cinco pontos de carga de cada gráfico (900, 1000, 1100, 1200 e 1300 Erlangs).

Tabela 4. Ganho médio do AMN em relação aos outros algoritmos avaliados.

	PBR				RDB			
	NSFNet		EURO28		NSFNet		EURO28	
	AXT	BXT	AXT	BXT	AXT	BXT	AXT	BXT
CPRF	94,52%	99,94%	88,70%	89,10%	92,40%	99,90%	85,81%	89,01%
ADEIN	86,98%	96,82%	74,11%	25,35%	84,82%	95,57%	71,76%	24,87%
CBA-SBA	1,17%*	99,98%	8,16%	98,83%	1,36%*	99,97%	9,28%	98,72%

De maneira geral, o AMN obteve melhores resultados quando comparado com todos os demais algoritmos. Nos cenários com alta incidência de XT, o desempenho do AMN é equivalente ao CBA-SBA na topologia NSFNet. Neste caso específico, os resultados estão sobrepostos pelo intervalo de confiança (marcado com um “*” na Tabela 4). Na topologia EURO28, o ganho médio do AMN (em relação ao CBA-SBA) é de 8,16% em termos de PBR. A similaridade entre o AMN e o CBA-SBA neste cenário dar-se pelo fato do AMN ser treinado a partir do CBA-SBA, o que acarreta em uma convergência de desempenho no cenário de AXT. Esta convergência de desempenho não ocorre no cenário de BXT, onde o ganho médio do AMN em relação ao CBA-SBA torna-se maior que 98% em todas as métricas e topologias. Tal melhora deve-se, entre outras razões, ao fato de que o treinamento do AMN considera atributos da rota e da modulação, que são negligenciados pelo CBA-SBA. Assim, a rede neural do AMN identifica padrões relacionados a estes atributos e aos casos de sucesso do CBA-SBA, melhorando o resultado geral do AMN em cenários de baixa incidência de XT.

6. Conclusão

Neste artigo é proposto o algoritmo com aprendizado de máquina para escolha de núcleo (AMN) em SDM-EONs. O AMN utiliza uma rede neural para aprender o comportamento de outro algoritmo, o CBA-SBA, e extrair características-chave e prever qual o melhor núcleo para ser alocado para cada requisição em um determinado estado da rede.

O AMN é avaliado em termos de probabilidade de bloqueio de requisição e razão de dados bloqueados. O AMN alcançou, em um cenário com alta incidência de XT, ganhos médios em relação a outros algoritmos *XT-avoid* de pelo menos 8,16% em termos de PBR e de pelo menos 9,28% em termos de RDB. Já no cenário de baixa incidência de XT, o AMN atingiu um ganho médio de pelo menos 25,35% em termos de PBR e 24,87% em termos de RDB em relação a outros algoritmos.

Para trabalhos futuros pretende-se investigar o desempenho do AMN sendo treinado por outras bases de dados, além da base gerada pelo algoritmo CBA-SBA. Também pretende-se estudar o uso de outras técnicas de ML para auxiliar na tomada de decisão da escolha de núcleo. Por fim, pretende-se aprofundar a investigação e utilizar a abordagem de ML para tratar a alocação de núcleo em conjunto com outros subproblemas do RMSCA, como alocação de espectro ou roteamento.

Referências

- Araújo, P., Lacerda Jr, J., and Soares, A. (2021). Um novo algoritmo de balanceamento espectral entre grupos de núcleos para redes ópticas elásticas com multiplexação por divisão espacial. In *Anais do XXXIX Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos*, pages 742–755, Uberlândia-MG.
- Beyranvand, H. and Salehi, J. (2013). A quality-of-transmission aware dynamic routing and spectrum assignment scheme for future elastic optical networks. *IEEE/OSA Journal of Lightwave Technology*, 31(18):3043–3054.
- Brasileiro, I., Costa, L., and Drummond, A. (2020). A survey on challenges of spatial division multiplexing enabled elastic optical networks. *Optical Switching and Networking*, 38:100584.
- Carena, A., Bosco, G., Curri, V., Jiang, Y., Poggiolini, P., and Forghieri, F. (2014). EGN model of non-linear fiber propagation. *Optics Express*, 22(13):16335–16362.
- Dijkstra, E. (1959). *A note on two problems in connexion with graphs*, volume 1. Numerische Mathematik.
- Fontinele, A., Santos, I., Neto, J. N., Campelo, D. R., and Soares, A. (2017). An efficient IA-RMLSA algorithm for transparent elastic optical networks. *Computer Networks*, 118:1–14.
- Fujii, S., Hirota, Y., Tode, H., and Murakami, K. (2014). On-demand spectrum and core allocation for reducing crosstalk in multicore fibers in elastic optical networks. *IEEE/OSA Journal of Optical Communications and Networking*, 6(12):1059–1071.
- Gao, G., Zhang, J., Wang, L., Gu, W., and Ji, Y. (2014). Influence of physical layer configuration on performance of elastic optical OFDM networks. *IEEE Communications Letters*, 18(4):672–675.
- Gong, L., Zhou, X., Liu, X., Zhao, W., Lu, W., and Zhu, Z. (2013). Efficient resource allocation for all-optical multicasting over spectrum-sliced elastic optical networks. *IEEE/OSA Journal of Optical Communications and Networking*, 5(8):836–847.
- 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.
- Hayashi, T., Taru, T., Shimakawa, O., Sasaki, T., and Sasaoka, E. (2011). Design and fabrication of ultra-low crosstalk and low-loss multi-core fiber. *Optics Express*, 19:16576–16592.
- ITU-T G.694.1 (2020). Spectral grids for WDM applications: DWDM frequency grid. Standard, International Telecommunication Union ITU.
- Ives, D., Bayvel, P., and Savory, S. (2015). Routing, modulation, spectrum and launch power assignment to maximize the traffic throughput of a nonlinear optical mesh network. *Photonic Network Communications*, 29(3):244–256.
- Klinkowski, M., Ksieniewicz, P., Jaworski, M., Zalewski, G., and Walkowiak, K. (2020). Machine learning assisted optimization of dynamic crosstalk-aware spectrally-spatially flexible optical networks. *IEEE/OSA Journal of Lightwave Technology*, 38(7):1625–1635.

- Klinkowski, M. and Zalewski, G. (2019). Dynamic crosstalk-aware lightpath provisioning in spectrally-spatially flexible optical networks. *IEEE/OSA Journal of Optical Communications and Networking*, 11(5):213–225.
- Lacerda Jr, J., Cartaxo, A., and Soares, A. (2021). New core and spectrum balancing algorithms for space division multiplexed elastic optical networks. In *2021 IEEE International Mediterranean Conference on Communications and Networking (MeditCom) (IEEE MeditCom 2021)*, pages 383–388, Athens, Greece.
- LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. *Nature (London)*, 521(7553):436–444.
- 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.
- Moghaddam, E. E., Beyranvand, H., and Salehi, J. A. (2020). Crosstalk-aware resource allocation in survivable space-division-multiplexed elastic optical networks supporting hybrid dedicated and shared path protection. *IEEE/OSA Journal of Lightwave Technology*, 38(6):1095–1102.
- Monteiro, N., Junior, W., Fontinele, A., Campelo, D., Paiva, A., Rabêlo, R., and Soares, A. (2020). Alocação de banda de guarda adaptativa utilizando redes neurais multi-layer perceptron em redes ópticas elásticas. In *Anais do XXXVIII Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos*, pages 770–783, Rio de Janeiro-RJ.
- Muhammad, A., Zervas, G., and Forchheimer, R. (2015). Resource allocation for space-division multiplexing: optical white box versus optical black box networking. *IEEE/OSA Journal of Lightwave Technology*, 33(23):4928–4941.
- Poggiolini, P. and Jiang, Y. (2017). Recent advances in the modeling of the impact of nonlinear fiber propagation effects on uncompensated coherent transmission systems. *IEEE/OSA Journal of Lightwave Technology*, 35(3):458–480.
- Tanenbaum, A. S. and Wetherall, D. (2011). *Redes de computadores: 5ª edição*. Pearson Prentice Hall.
- Yaghubi-Namaad, M., Rahbar, A. G., and Alizadeh, B. (2018). Adaptive modulation and flexible resource allocation in space division multiplexed elastic optical networks. *IEEE/OSA Journal of Optical Communications and Networking*, 10(3):240–251.
- Yan, L., Agrell, E., Wymeersch, H., Johannisson, P., Di Taranto, R., and Brandt-Pearce, M. (2015). Link-level resource allocation for flexible-grid nonlinear fiber-optic communication systems. *IEEE Photonics Technology Letters*, 27(12):1250–1253.
- Yao, Q., Yang, H., Zhu, R., Yu, A., Bai, W., Tan, Y., Zhang, J., and Xiao, H. (2018). Core, mode, and spectrum assignment based on machine learning in space division multiplexing elastic optical networks. *IEEE Access*, 6:15898–15907.
- Zhang, Y., Xin, J., Li, X., and Huang, S. (2020). Overview on routing and resource allocation based machine learning in optical networks. *Optical Fiber Technology*, 60:102355.
- Zhao, J., Wymeersch, H., and Agrell, E. (2015). Nonlinear impairment-aware static resource allocation in elastic optical networks. *IEEE/OSA Journal of Lightwave Technology*, 33(22):4554–4564.