

Novo Algoritmo Baseado em Aprendizado de Máquina para Gerenciamento de Realocação Espectral em Redes Ópticas Elásticas Multi-Núcleos

Ana V. D. Carvalho¹, Rayline P. Mendes^{1,2}, Carlos E. B. Sousa¹,
Selles G. F. C. Araújo^{2,3}, André C. B. Soares², Jurandir C. Lacerda Jr.¹

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

²Departamento de Computação – Universidade Federal do Piauí (UFPI)
Teresina, PI – Brasil

³Instituto Federal de Educação, Ciência e Tecnologia do Piauí (IFPI)
Paulistana, PI – Brasil

ana.diascarvalh@gmail.com, jurandir.cavalcante@ifpi.edu.br

Abstract. *This paper proposes a new machine learning (ML)-based algorithm to generate efficient triggers for circuit reallocation in multi-core elastic optical networks. The proposed approach processes network state information and determines the most appropriate moment for optical circuit reallocation, aiming to optimize network performance and minimize the impact of physical layer effects. The results show that the ML model achieves an accuracy of 89% during training. Furthermore, when applying the proposed approach together with another resource management algorithm, an average reduction of 96.6% in circuit blocking probability and 97.3% in bandwidth blocking probability was obtained, with only 0.14% of circuits reallocated per reallocation process.*

Resumo. *Este artigo propõe um novo algoritmo baseado em aprendizado de máquina (AM) para gerar gatilhos eficientes para a realocação de circuitos em redes ópticas elásticas multi-núcleos. A proposta processa as informações do estado da rede e determina o momento mais apropriado para a realocação de circuitos ópticos, com o objetivo de otimizar o desempenho da rede e minimizar os impactos dos efeitos da camada física. Os resultados demonstram que modelo de AM atinge uma acurácia de 89% no treinamento. Além disso, ao aplicar a proposta em conjunto com outro algoritmo de gerenciamento de recursos, obteve-se uma diminuição média de 96,6% na probabilidade de bloqueio de circuito e de 97,3% na probabilidade de bloqueio de banda, com apenas 0,14% de circuitos realocados por processo de realocação.*

1. Introdução

O crescimento acelerado do número de usuários da Internet, aliado ao surgimento de novas tecnologias e aplicações, impõe desafios cada vez mais complexos à infraestrutura de redes de comunicação. Entre esses desafios, destaca-se a necessidade de atender à crescente demanda por altas taxas de transmissão de dados de forma eficiente e sustentável.

Nesse cenário, as Redes Ópticas Elásticas com Multiplexação por Divisão Espacial (*Space-Division Multiplexed Elastic Optical Networks* - (SDM-EON)) têm emergido como uma alternativa promissora em relação aos modelos de grade fixa, pois o espectro óptico é dividido em pequenas partes chamadas *slots* de frequência, com tamanho de 12,5 GHz, tornando mais eficiente o gerenciamento dos recursos da rede [Chatterjee et al. 2015]. Além disso, no modelo de multiplexação por divisão espacial, o espectro óptico é particionado espacialmente utilizando núcleos distintos em uma única fibra, permitindo que elas suportem volumes maiores de tráfego [Brasileiro et al. 2020]. Contudo, sua utilização traz consigo o desafio da resolução do problema de roteamento, modulação, alocação de núcleo e espectro (*Routing, Modulation, Core, and Spectrum Allocation* - (RMCSA)).

O problema RMCSA consiste, para cada requisição, em: i) Determinar o trajeto que um circuito óptico seguirá, partindo do nó de origem até alcançar o nó de destino; ii) Escolher o formato da modulação para o circuito óptico; iii) Escolher o núcleo da fibra que será utilizado para o transporte dos dados; e iv) Definir quais *slots* serão alocados para o circuito óptico [Lobato et al. 2019]. Essa alocação deve obedecer às restrições de contiguidade e continuidade, que exigem, respectivamente, que os *slots* alocados sejam adjacentes no espectro e que o mesmo conjunto de *slots* seja utilizado ao longo de todo o caminho entre os nós origem e destino [Chatterjee et al. 2015]. Havendo recursos disponíveis na rede, o requisitante receberá um circuito óptico dedicado. Na ausência de recursos, a requisição será negada, configurando um bloqueio de requisição [Lacerda-Jr et al. 2020].

Além disso, uma solução RMCSA precisa levar em conta os efeitos da camada física ou *physical layer impairments* (PLIs) presentes, como emissão espontânea amplificada (*amplified spontaneous emission* - (ASE)), *crosstalk* inter-núcleos (XT) e Interferências Não-Lineares (*Nonlinear Impairments* - (NLIs)). Esses efeitos degradam a qualidade da transmissão (QoT) e limitam o alcance do sinal óptico [Ravipudi and Brandt-Pearce 2024]. Dentre os fatores limitantes da camada física, o *crosstalk* se destaca como principal responsável pelas limitações de desempenho em redes com multi-núcleos devido a sua capacidade de gerar bloqueio de requisições e degradar a qualidade do serviço [Hayashi et al. 2011]. Esse efeito ocorre quando dois caminhos ópticos localizados em núcleos adjacentes compartilham o mesmo *slot* de frequência, resultando em uma sobreposição espectral [Hayashi et al. 2011].

O estabelecimento e desativação de circuitos ópticos resultam na fragmentação do espectro, situação em que existem *slots* disponíveis para atender a uma requisição de largura de banda, mas que não estão organizados de maneira contígua e contínua, o que torna inviável sua alocação. Esse problema pode ser mitigado através de algoritmos cientes de fragmentação ou por algoritmos de desfragmentação, que utilizam a técnica de realocação de circuitos. A realocação de circuitos, embora utilizada na literatura como uma solução para o problema de fragmentação, também demonstrou eficiência na mitigação dos efeitos do XT [Araujo and Soares 2024]. Contudo, definir de forma precisa um gatilho para iniciar o processo de realocação representa um desafio significativo, pois tal definição é crucial para garantir que a realocação irá gerar efeitos positivos na rede.

Diante desses desafios, o aprendizado de máquina (AM) tem se consolidado como uma ferramenta poderosa no domínio das redes de comunicação, oferecendo soluções inovadoras para problemas complexos e dinâmicos. Sua aplicação em redes ópticas, em

particular, tem demonstrado grande potencial para otimizar o gerenciamento de recursos, melhorar o desempenho e garantir a escalabilidade diante do aumento exponencial do tráfego de dados [Vasundhara and Mandloi 2024]. Técnicas de AM, como a *deep neural network* (DNN), auxiliam na captura de relações desconhecidas da rede óptica para uma tomada de decisão inteligente, a fim de melhorar o desempenho da rede e acelerar os cálculos [Ravipudi and Brandt-Pearce 2024].

Neste contexto, o presente artigo propõe o Algoritmo de Realocação Óptica Inteligente (AROI) para mapear os dados de entrada das requisições e identificar o momento ideal para a realização da realocação dos circuitos ópticos, considerando os efeitos da camada física, em especial o XT, para otimizar o gerenciamento das SDM-EONs. O AROI reduz a probabilidade de bloqueio das requisições, aumenta a eficiência espectral e realiza mínimas alterações (menos de 1%) no estado da rede por processo de realocação.

O restante deste artigo está organizado da seguinte maneira: a Seção 2 aborda os trabalhos relacionados ao tema deste artigo. O modelo da camada física é discutido na Seção 3. O algoritmo proposto é apresentado na Seção 4. Os resultados numéricos que avaliam o desempenho do algoritmo proposto são detalhados na Seção 5. Por fim, as considerações finais deste trabalho estão na Seção 6.

2. Trabalhos Relacionados

A literatura apresenta estudos com estratégias para alocar eficientemente os recursos espectrais, visando melhorar o desempenho das SDM-EONs [Lacerda-Jr et al. 2024, Oliveira and da Fonseca 2020]. Outros estudos focam em desenvolver técnicas de realocação espectral [Araujo and Soares 2024, Trindade and d. Fonseca 2020] ou mesmo modelos de AM para auxiliar na realocação dos recursos ópticos [Trindade and d. Fonseca 2020, Vasundhara and Mandloi 2024].

Em [Zhao et al. 2018] é proposto um algoritmo de realocação de circuitos chamado *Crosstalk-Aware Spectrum Defragmentation* (CASD), no qual é acionado sempre que uma requisição está na iminência de ser bloqueada. O algoritmo realiza reatribuições de núcleos e espectros de forma a compactar os circuitos, gerando blocos de *slots* contíguos e contínuos na rede. Para a compactação do espectro é utilizada a métrica *Spectrum Compactness* (SC). As realocações ocorrem para que os núcleos da fibra atendam limiares preestabelecidos de medida de SC.

Os autores em [Trindade and d. Fonseca 2020] apresentam o algoritmo reativo *Clusterization-Driven Spectrum Rearrangement* (CISUR), que utiliza aprendizado de máquina não supervisionado para agrupar espectros ópticos com base em suas características, auxiliando na reorganização da rede. Esse algoritmo é combinado ao proativo *Clusterization RMCSA* (C-RMCSA), que utiliza as informações do agrupamento e das solicitações de entrada para direcionar novas requisições às classes formadas, reduzindo a fragmentação futura do espectro.

Em [Lacerda-Jr et al. 2020] é proposto o Algoritmo de Balanceamento de Núcleo e Espectro para Redes SDM (ABNE), que visa mitigar os efeitos do *crosstalk* na rede ao equilibrar a alocação de núcleo e espectro. O *crosstalk* afeta *slots* com o mesmo índice em núcleos adjacentes, e, para contornar esse problema, o ABNE prioriza a utilização de porções de *slots* distintas entre núcleos vizinhos. Os resultados das simulações demons-

tram que o algoritmo reduz a probabilidade de bloqueio em pelo menos 44% na topologia NSFNet e 33% na topologia EON.

O estudo em [Ravipudi and Brandt-Pearce 2022] propõe um algoritmo que utiliza uma *Score Function* (SF) para classificar blocos de espectro candidatos, selecionando o bloco, rota, modulação e núcleo mais adequados para minimizar a fragmentação. A SF avalia a resistência de um bloco ao XT previsto e seu impacto nos sinais existentes, considerando XT e fragmentação. A proposta apresentou redução na probabilidades de bloqueio de banda e fragmentação em comparação aos métodos *Worst Case XT First Fit*, *XT-aware First Fit* e *XT-aware Best Fit*.

No estudo apresentado em [Araujo and Soares 2024], é proposto um algoritmo reativo para SDM-EONs com foco na mitigação do XT, visando diminuir os bloqueios na rede utilizando a desfragmentação do espectro. A solução emprega as técnicas de *push-pull* e *fast-switching* para realocar o tráfego de dados de maneira não disruptiva. Os testes realizados indicaram uma redução de até 30% na probabilidade de bloqueio, com impacto mínimo, realocando apenas 0,25% dos circuitos ativos em cada processo.

O estudo em [Vasundhara and Mandloi 2024] apresenta um algoritmo baseado em DNN para selecionar o núcleo mais adequado e reduzir a fragmentação. O algoritmo identifica as k rotas mais curtas e a métrica *Contiguous Aligned Slot Ratio* (CASR) para avaliar a fragmentação, alimentando o modelo que decide pela aceitação ou rejeição de um núcleo. O método apresentou menores níveis de fragmentação e bloqueio em comparação aos algoritmos *Shared Backup Path Protection for MultiCore networks algorithm* (SBP-PMC) e *Fragmentation-aware Multipath Distance-adaptive Energy-efficient* (FMDE).

Tabela 1. Informações gerais dos trabalhos relacionados.

Referência	PLIs	Qtd. Núcleos	Modelos de AM
[Zhao et al. 2018]	XT	7	Não utiliza
[Trindade and d. Fonseca 2020]	nenhum	7	<i>K-Means clustering</i>
[Lacerda-Jr et al. 2020]	ASE, NLIs e XT	7	Não utiliza
[Ravipudi and Brandt-Pearce 2022]	XT	7	Não utiliza
[Araujo and Soares 2024]	ASE, NLIs e XT	7	Não utiliza
[Vasundhara and Mandloi 2024]	XT	3	DNN
Este artigo	ASE, NLIs e XT	7	DNN

Diferentemente dos trabalhos mencionados (resumidos na Tabela 1), este estudo propõe um método de realocação baseado em AM com abordagem integrada para lidar simultaneamente com o XT, o ruído ASE e os efeitos não-lineares, fatores que impactam de forma significativa o desempenho das SDM-EONs.

3. Modelo Camada Física

Este estudo avalia três dos principais fatores que restringem o desempenho da camada física da rede: *i*) o ruído ASE; *ii*) as interferências não-lineares; e *iii*) o *crosstalk* inter-núcleo.

Os ruídos ASE e NLI pertencem a categoria de ruídos intra-núcleo, ou seja, ocorrem dentro do mesmo núcleo da fibra óptica. O ruído ASE é inserido na fibra por meio do processo de amplificação óptica, frequentemente realizado por amplificadores de fibra dopada com érbio (*erbium doped fiber amplifier* (EDFA)) [Yan et al. 2015]. Já as interferências não-lineares são geradas pela propagação do sinal óptico ao longo da fibra, resultando em efeitos como a modulação de fase cruzada (*cross-phase modulation*

(XPM)), a auto-modulação da fase (*self-phase modulation* (SPM)) e a mistura de quatro ondas (*four-wave mixing* (FWM)) [Poggiolini and Jiang 2017], que interferem não apenas no próprio canal óptico, mas também em outros canais adjacentes. Por outro lado, o *crosstalk* inter-núcleo é um tipo de interferência que ocorre entre os núcleos da fibra, sendo mais degradante entre núcleos adjacentes [Hayashi et al. 2011]. Este artigo avalia a QoT de cada circuito na rede considerando conjuntamente os efeitos intra e inter núcleos.

Para quantificar os impactos dos efeitos intra-núcleo a relação sinal-ruído óptico (*optical signal to noise ratio* (OSNR)) é frequentemente usada. A OSNR estabelece uma comparação entre a densidade espectral da potência (*power spectral density*(PSD)) do circuito e a PSD do ruído ASE e das NLIs que o afeta, sendo

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

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

Existem também as interferências inter-núcleos, como o *crosstalk* inter-núcleos [Hayashi et al. 2011]. Em [Lobato et al. 2019] é apresentado um modelo para mensurar a potência média de *crosstalk* (normalizada pela potência de sinal do circuito) em um determinado circuito m . Esta potência normalizada média de *crosstalk* é dada por

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

onde $|E_m|$ é a quantidade de enlaces que compõem o circuito m e e é o índice que identifica um enlace deste conjunto. $XT_{\mu,m,e}$ é a potência normalizada média de *crosstalk* gerada no enlace e do circuito m , dada por $XT_{\mu,m,e} = \frac{P_{XT_{m,e}}}{P_m}$ [Lobato et al. 2019]. Em que $P_{XT_{m,e}}$ é a potência média de *crosstalk* (não normalizada) do circuito m gerada no enlace e e P_m corresponde à potência de sinal do circuito m . O valor de $P_{XT_{m,e}}$ é calculado por [Lobato et al. 2019]

$$P_{XT_{m,e}} = \sum_{n=1}^{N_{m,e}} (I_{SO_{m,e,n}} \cdot P_n \cdot h_e \cdot L_e), \quad (3)$$

onde $N_{m,e}$ é a quantidade de circuitos alocados em núcleos adjacentes ao núcleo do circuito m , que utilizam a mesma fração do espectro (em todo ou em parte) do circuito m no enlace e e n é o índice que identifica o circuito interferente. P_n é a potência de sinal do n -ésimo circuito adjacente de $N_{m,e}$ circuitos 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 circuitos m e n no enlace e , dado por $I_{SO_{m,e,n}} = (S_{SO_{m,e,n}})/(S_{e,n})$, em que $S_{SO_{m,e,n}}$ é a quantidade de *slots* sobrepostos entre os circuitos m e n no enlace e , isto é, quantos dos *slots* do circuito m possuem *slots* de mesmo índice alocados no circuito n (desconsiderando banda de guarda) no enlace e , e $S_{e,n}$ é a quantidade de *slots* do circuito n no enlace e .

Neste artigo, a QoT é avaliada através do impacto dos efeitos intra e inter-núcleos (OSNR e XT). Para cada circuito candidato retornado por um algoritmo RMCSA, deve-se verificar se os níveis de OSNR e XT estão de acordo com os limites de OSNR e *cross-talk* definidos pelo *service level agreement* (SLA) da rede. Caso contrário, a requisição é bloqueada. Um circuito candidato pode ser bloqueado por cinco fatores: i) bloqueio por ausência de recursos para o estabelecimento do circuito candidato; ii) bloqueio por OSNR inadequada para o circuito candidato (OSNRN); iii) bloqueio por o circuito candidato impactar nos circuitos já ativos de modo que algum destes venham a ter OSNR inadequada (OSNRO); iv) bloqueio por XT inadequado para o circuito candidato (XTN); e v) bloqueio por o circuito candidato impactar nos circuitos já ativos de modo que algum destes venham a ter o nível de XT inadequado (XTO). Os limites de OSNR e XT adotados neste artigo estão listados na Tabela 4 da Seção 5.

4. Algoritmo Proposto

Os algoritmos tradicionais de RMCSA frequentemente encontram dificuldades em equilibrar a eficiência no uso do espectro disponível com a QoT necessária para atender as requisições, devido à incidência das PLIs, em especial o XT. Como consequência, ocorre um aproveitamento inadequado dos recursos e um aumento na probabilidade de bloqueio. O presente artigo propõe uma solução com uso de AM para trazer equilíbrio entre essas duas demandas. O Algoritmo de Realocação Óptica Inteligente (AROI) utiliza uma rede neural profunda para compreender o comportamento do algoritmo ABNE [Lacerda-Jr et al. 2020] em diferentes estados da rede e identificar características essenciais para determinar se a requisição será aceita ou recusada. Caso seja recusada, a rede neural é capaz de identificar o tipo de bloqueio (OSNRN, OSNRO, XTN, XTO) que, por sua vez, será usado como gatilho para iniciar a realocação do espectro óptico. O fluxo de funcionamento do AROI é dividido em quatro etapas principais: a primeira etapa consiste na criação de uma base de dados para treinar a DNN, a segunda etapa refere-se ao treinamento da DNN, a terceira etapa corresponde à execução do AROI durante a fase operacional da rede e a quarta será executada quando for identificado um gatilho para a realização da realocação do espectro óptico. A Figura 1 ilustra esse fluxo.

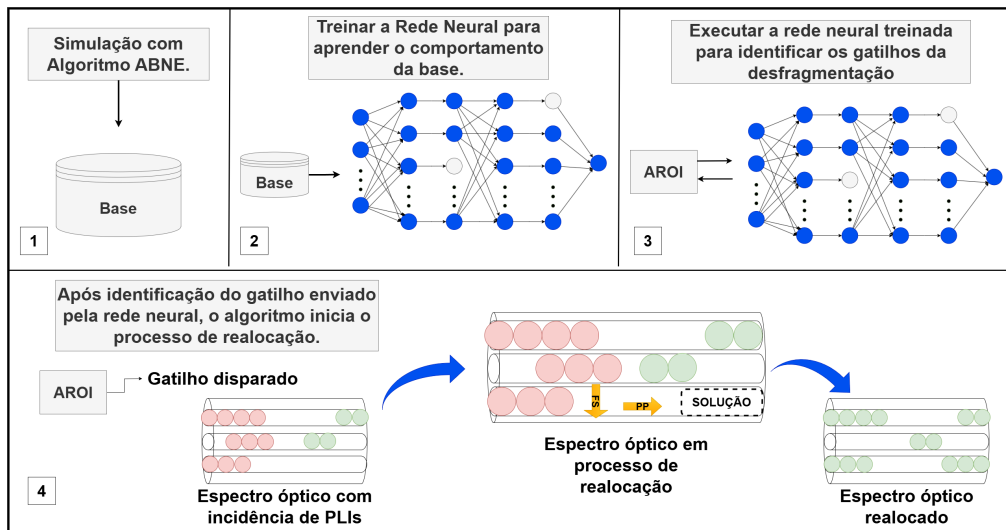


Figura 1. Fluxograma do algoritmo AROI.

No processo de criação da base de dados, o ABNE é executado por meio de simulação computacional, e os valores de determinados atributos são registrados para cada requisição feita ao plano de controle da rede. Os atributos considerados, em um total de onze (dez atributos mais o atributo alvo), são: i) a banda requisitada; ii) o formato da modulação; iii) o nó de origem; iv) o nó de destino; v) o comprimento da rota; vi) o núcleo escolhido; vii) a quantidade de núcleos adjacentes ao núcleo usado pela requisição; viii) o número de saltos da rota; ix) o nível de XT; x) o nível da OSNR; e xi) o atributo alvo, *status* da conexão, que é dividido em cinco classes numéricas de 1 à 5, onde: 1 representa conexão estabelecida, 2 conexão não estabelecida por OSNR, 3 conexão não estabelecida por OSNR, 4 conexão não estabelecida por XT e 5 conexão não estabelecida por XT. Portanto, a base gerada a partir do ABNE contém 564.126 registros, correspondentes às requisições geradas pela simulação em diferentes pontos de carga da rede. Cada registro armazenado é composto por onze atributos, representando um determinado estado da rede no momento da chegada da requisição, além de informar se aquela requisição foi aceita ou recusada, seja por OSNR ou XT inadequados.

Após a criação da base de dados, foi desenvolvido um modelo DNN utilizando as bibliotecas Keras e TensorFlow. A arquitetura escolhida é composta por duas camadas ocultas de neurônios interligados, sendo que a primeira camada oculta contém 64 neurônios e a segunda camada oculta, 32 neurônios, empregando a função de ativação ReLU (*Rectified Linear Unit*) [LeCun et al. 2015]. A última camada, também chamada de camada de saída, é formada por cinco neurônios com função de ativação *Softmax*, onde cada neurônio representa um dos tipos *status* da requisição. Para prevenir o *overfitting*, aplica-se a técnica de regularização por *dropout* no treinamento, que elimina aleatoriamente uma fração de neurônios. A taxa de aprendizagem é iniciada em 10^{-3} .

As etapas um e dois são realizadas em um momento *offline* da rede. Já as etapas três e quatro ocorrem durante o funcionamento da rede, tendo o objetivo de definir um momento ideal para a realocação de alguns circuitos ativos de forma a melhorar a QoT e reduzir os efeitos negativos dos PLIs. Na terceira etapa, para cada requisição de um novo circuito que chega ao plano de controle, um algoritmo RMCSA define um circuito candidato e então o AROI extrai os dez atributos (estado atual da rede) para este circuito candidato e alimenta a DNN (já treinada). Durante a execução, o AROI prediz se aquela requisição será aceita ou o tipo de bloqueio que ela terá, representado pelas classes numéricas do atributo alvo. Se a classe retornada pela DNN for diferente de 1, O AROI inicia o processo de realocação, no qual são aplicadas as técnicas de migração de dados *push-pull* [Cugini et al. 2013] e *fast-switching* [Meloni et al. 2016]. Tais técnicas são caracterizadas como *hitless*, isto é, têm a capacidade de realizar a realocação de circuitos sem interromper o tráfego de dados [Araujo and Soares 2024].

Com a decisão de iniciar as realocações, é necessário selecionar os circuitos ativos que serão realocados e definir uma nova solução RMCSA para estes circuitos. Vale ressaltar que nestas etapas de seleção e definição foram baseadas no artigo proposto por [Araujo and Soares 2024], onde apenas é realizado reatribuição nuclear e/ou reatribuição espectral. Este trabalho assim como a proposta de [Araujo and Soares 2024] não realiza reroteamento pelo o custo operacional da realocação aumentar.

Os circuitos a serem realocados são aqueles que interferem no circuito candidato no qual foi prevista que seria um bloqueio. Como neste cenário o tipo de bloqueio pre-

dominante está relacionado ao *crosstalk* inter-núcleos, entende-se que os circuitos que interferem na requisição são os responsáveis por inviabilizar seu atendimento. Vale lembrar que a definição de circuitos interferentes consiste dos circuitos em núcleos vizinhos que apresentam intersecção de seus espectros com o espectro da requisição. Dessa forma, a seleção fica restrita à busca de circuitos apenas nos núcleos vizinhos, diminuindo consideravelmente o número de circuitos possivelmente a serem realocados. Tal estratégia faz com que as alterações no estado da rede sejam mínimas, mas com impactos relevantes para a melhoria do desempenho da rede no que tange aos efeitos das PLIs.

Com relação à definição da nova posição dos circuitos selecionados, para cada circuito selecionado será buscado 1 solução por núcleo, totalizando no máximo 7 possíveis soluções de realocações. A decisão de 1 solução por núcleo é para reduzir o número de possíveis lugares para realocar e restringir o espaço de busca. Além disso, dentre as soluções encontradas, será aplicado um critério de ordenação dessas soluções no intuito de definir as soluções prioritárias. O critério utilizado foi o de maior valor de ΔXT , com o objetivo de realocar um circuito para um destino que proporcione maior QoT. O valor de ΔXT é definido como a diferença entre o valor de XT do circuito candidato e o limite de XT para o formato de modulação usado pelo circuito candidato. Cada possível solução é definida realizando uma busca gulosa observando a variável *crosstalk* no espectro de cada núcleo. Este procedimento é realizado para cada circuito selecionado.

5. Resultados Numéricos

Nesta seção, o desempenho do AROI é avaliado em duas etapas: i) o quanto o modelo de AM do AROI é capaz de aprender o comportamento da rede. ii) o quanto este modelo de AM treinado pode melhorar o desempenho da rede a partir da escolha inteligente de quando executar uma realocação de circuitos já ativos na rede.

A primeira etapa de avaliação do AROI começa desde a fase de treinamento do modelo de AM. Durante o treinamento do modelo de AM, foi empregada a estratégia de *callback*, uma função auxiliar que facilita o aprendizado ao monitorar métricas e ajustar parâmetros automaticamente. Entre as técnicas utilizadas, o *EarlyStopping* desempenhou um papel essencial ao interromper o treinamento assim que foi detectada estagnação, ou seja, perda de validação por 20 épocas consecutivas, restaurando os pesos associados ao melhor desempenho do modelo.




Figura 2. Variação da Loss durante o treinamento.

A Figura 2 apresenta a evolução da função de perda (*Loss*) ao longo das épocas. O treinamento foi concluído na 37ª época, com a função de perda progressivamente minimizada durante o processo de otimização. O gráfico revela que, após a 17ª época, a perda estabilizou, indicando que o modelo alcançou um ponto onde melhorias adicionais se tornaram menos expressivas. Esse comportamento sugere que o algoritmo atingiu um nível de desempenho adequado, atendendo aos objetivos propostos para o treinamento.

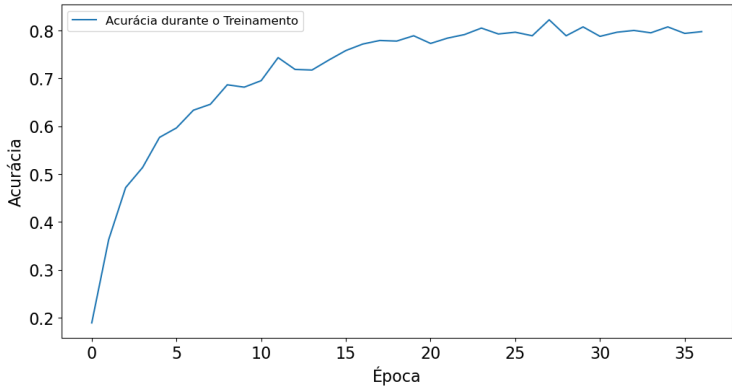


Figura 3. Variação da Acurácia Durante o Treinamento.

A Figura 3 ilustra a evolução da acurácia, métrica que indica a proporção de previsões corretas realizadas pelo modelo em relação ao total de instâncias avaliadas. O gráfico evidencia o aprimoramento gradual da acurácia ao longo das épocas, até atingir um platô. Esse padrão reflete o processo de aprendizado do modelo, no qual as previsões tornam-se progressivamente mais precisas. Além da acurácia, o AROI também foi avaliado com base nas métricas precisão, *recall* e *F1-score*. As definições e fórmulas das métricas adotadas são bem conhecidas na literatura de aprendizado de máquina, podendo ser encontradas em [Zhang et al. 2023]. Os resultados de acurácia, precisão, *recall* e *F1-score* do modelo de AM do algoritmo AROI são mostrados na Tabela 2.

Tabela 2. Relatório de Classificação do Treino.

Classe	Precisão	<i>recall</i>	<i>F1-score</i>
1	1,00	0,90	0,95
2	0,85	0,94	0,90
3	0,93	0,79	0,86
4	0,82	0,94	0,88
5	0,86	0,86	0,86
Acurácia	0,89		

Conforme apresentado na Tabela 2, que detalha o desempenho do algoritmo por classe de *status* da conexão em cada métrica de avaliação, o algoritmo AROI demonstrou um desempenho geral satisfatório, alcançando uma acurácia de 89%. A métrica *F1-score*, que combina precisão e sensibilidade, apresentou valores consistentes entre as diferentes classes, indicando que o modelo manteve um equilíbrio adequado entre identificar corretamente as instâncias de cada classe e minimizar os erros de classificação.

A Tabela 3, que exibe a matriz de confusão do algoritmo AROI, é utilizada para avaliar a performance do modelo no conjunto de dados de treino. Cada valor na tabela

Tabela 3. Matriz de Confusão.

Classes Reais	1	146	0	0	3	13
	2	0	153	9	0	0
	3	0	26	128	8	0
	4	0	0	0	153	9
	5	0	0	0	22	140
		1	2	3	4	5
Classes Preditas						

indica o número de instâncias de uma classe real que foram classificadas na classe predita correspondente. A diagonal principal (em cinza) contém os valores corretos, representando os casos em que a classe real coincide com a classe predita. Já os valores fora da diagonal refletem erros de classificação. Como pode ser observado, o AROI apresenta, predominantemente, valores na diagonal principal, evidenciando sua eficácia na classificação das requisições e sua capacidade de identificar corretamente as instâncias.

A segunda etapa desta seção consiste em avaliar o quanto o modelo de AM treinado pode melhorar o desempenho da rede a partir da escolha inteligente de quando executar uma realocação de circuitos já ativos na rede. Para avaliar o desempenho do algoritmo proposto no âmbito das redes ópticas, a técnica de simulação foi empregada. O simulador utilizado foi o *SLICE Network Simulator* (SNetS) [Fontinele et al. 2017]. Para cada simulação foram geradas 100.000 requisições. A geração de requisições é um processo de *Poisson*, caracterizado por uma taxa média de chegadas de λ e tempo médio de retenção dos caminhos ópticos que segue uma distribuição exponencial com média $1/\mu$. A distribuição da carga de tráfego foi realizada de maneira uniforme entre todos os pares de nós, considerando origem e destino. Foram geradas requisições de 100, 150, 200, 250, 300, 350 e 400 Gbps, com proporções de chegada de 7, 6, 5, 4, 3, 2 e 1, respectivamente. Assim, para cada solicitação de 400 Gbps, por exemplo, são geradas sete de 100 Gbps. A carga, em Erlangs, pode ser definida pela relação $\rho = \lambda/\mu$. Foram geradas cinco simulações com diferentes sementes para geração de variáveis aleatórias. Os resultados obtidos têm um nível de confiança de 95%. Neste estudo, são considerados cinco formatos de modulação: BPSK, 4-QAM, 8-QAM, 16-QAM e 32-QAM. Os limites de OSNR por símbolo e de *crosstalk* são apresentados na Tabela 4 [Ives et al. 2015, Moghaddam et al. 2019].

Tabela 4. Limites dos formatos de modulação.

Limite	BPSK	4-QAM	8-QAM	16-QAM	32-QAM
OSNR (dB)	5,5	8,5	12,5	15,1	18,1
XT (dB)	-14,0	-18,5	-21,0	-25,0	-27,0

Nas simulações, cada fibra é composta por sete núcleos, sendo que cada núcleo é subdividido em 320 *slots* de frequência, com cada *slots* tendo uma largura de banda de 12,5 GHz. Os ganhos dos amplificadores são ajustados para compensar as perdas dos dispositivos e da fibra. Na Tabela 5 estão listados outros parâmetros utilizados

[Beyranvand and Salehi 2013, Zhao et al. 2015, Lobato et al. 2019].

Tabela 5. Parâmetros de camada física utilizados nas simulações.

Descrição	Valor
Atenuação da fibra (α)	0,2 dB/km
Coefficiente não linear da fibra (γ)	$1,3 \text{ (W}\cdot\text{km)}^{-1}$
Coefficiente de acoplamento (h_e)	$1,5 \times 10^{-9} \text{ m}^{-1}$
Dispersão de velocidade de grupo da fibra (β_2)	-20 ps ² /km
Figura de ruído do amplificador (N_F)	5 dB
Frequência óptica (ν)	193 THz
Parâmetro de dispersão da fibra (D)	16 ps/nm/km
Perda do nó (W_n)	15 dB
Sobrecarga FEC (F)	12%
Tamanho de um <i>span</i> (L_s)	80 km

Neste artigo é verificado o desempenho do algoritmo de gerenciamento de recursos ABNE [Lacerda-Jr et al. 2020] e em seguida o desempenho do ABNE em conjunto com o algoritmo de realocação AROI (proposta). Além disso, para efeito de comparação com outro algoritmo de realocação, também foram realizadas simulações do ABNE em conjunto com o algoritmo de realocação CASD [Zhao et al. 2018]. Os resultados para a topologia de rede NSFNet são apresentados na Figura 4.




Figura 4. Probabilidade de bloqueio.

A Figura 4 apresenta o comparativo entre os algoritmos ABNE, ABNE em conjunto com o algoritmo CASD e ABNE em conjunto com o algoritmo AROI. As métricas utilizadas são a probabilidade de bloqueio de circuito (PBC), na Figura 4 (a), e probabilidade de bloqueio de banda (PBB), na Figura 4 (b). Para as duas métricas é possível observar uma melhora significativa do desempenho do algoritmo ABNE em conjunto com o AROI. Em média, a adoção da estratégia AROI reduziu o bloqueio do ABNE em 96,6% na métrica de PBC e 97,3% na PBB. Já em relação ao algoritmo de realocação CASD, o algoritmo proposto atingiu uma redução na PBC de 95,5% e uma redução na PBB de 96,8%. Neste contexto, é importante destacar dois fatores: o primeiro consiste em que o AROI realiza relativamente poucas realocações de circuitos ativos (em contraste com outros mecanismos de realocação). Neste estudo, ocorreu uma média de 0,14% de circuitos

realocados por processo de realocação, sendo estas realizadas de forma precisa devido a acurácia do modelo de AM, proporcionando uma redução na probabilidade de bloqueio. O segundo fator consiste em que, apesar de neste estudo o AROI ter sido usado em conjunto com o ABNE, a proposta pode ser incorporada a qualquer outro algoritmo RMCSA da literatura. Para investigar como o AROI é capaz de reduzir a probabilidade de bloqueio do ABNE, são apresentadas as causas dos bloqueios para os algoritmos ABNE e ABNE+AROI na Figura 5.

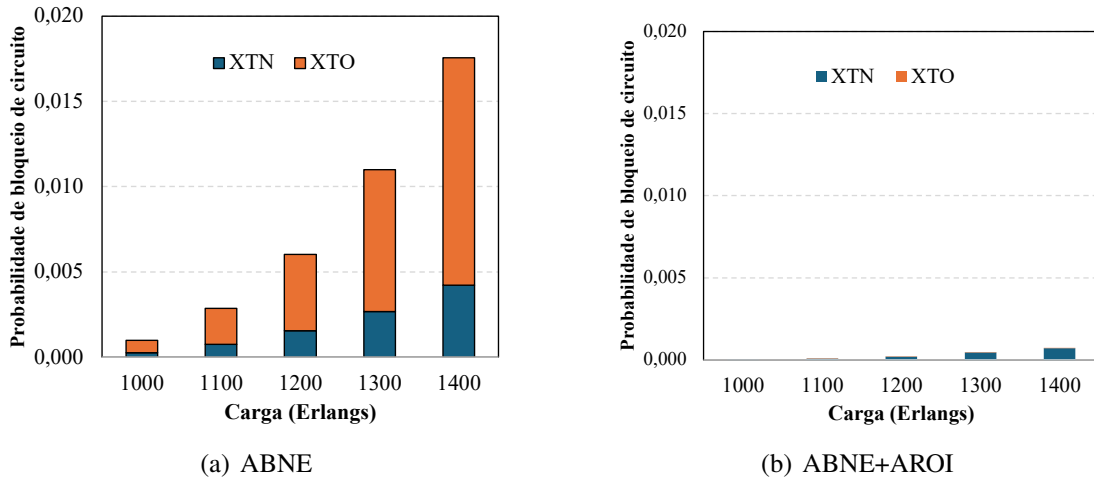


Figura 5. Componentes da probabilidade de bloqueio.

Ne Figura 5 é possível observar que os principais fatores que geram bloqueios para o algoritmo ABNE são os relacionados ao *crossstalk* (XTN e XTO). Ao usar o AROI, o modelo de AM é capaz de identificar que o estado da rede é propício à ocorrência de bloqueios e, de forma proativa, é ativado um processo de realocação que evita uma quantidade significativa dos bloqueios. A Figura mostra também que o AROI é capaz de diminuir a ocorrência de bloqueios XTO, que são mais complexos de identificar para os algoritmos que não usam AM, pois necessita-se de uma análise profunda na vizinhança do circuito candidato.

6. Considerações Finais

Neste artigo, foi apresentado o Algoritmo de Realocação Óptica Inteligente (AROI), cujo objetivo é gerar gatilhos que aprimorem o processo de realocação de circuitos, mitigando os efeitos da camada física e reduzindo a probabilidade de bloqueio. Os resultados demonstraram que o AROI alcançou uma acurácia de 89%, com uma média de precisão e *F1-score* de 89%. Além disso, ao aplicar a proposta em conjunto com o algoritmo ABNE na topologia NSFNet, obteve-se um ganho médio de 96,6% na PBC e de 97,3% na PBB. Já em comparação ao ABNE com outro algoritmo de realocação, o CASD, a proposta atingiu uma redução na PBC de 95,5% e uma redução na PBB de 96,8%. Tais ganhos são atingidos com uma média de 0,14% de circuitos realocados por processo de realocação.

Em trabalhos futuros, pretende-se avaliar o desempenho do AROI em diferentes cenários, explorando outras técnicas de AM, testando-o em outras topologias e aplicando-o à outros algoritmos RMCSA para uma análise mais abrangente de sua capacidade.

Referências

- Araujo, S. and Soares, A. (2024). Realocação de circuito ciente de crosstalk para redução de bloqueios em redes Ópticas elásticas com multiplexação espacial. In *Anais do XLII Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos*, pages 127–140, Porto Alegre, RS, Brasil. SBC.
- 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.
- Chatterjee, B., Sarma, N., and Oki, E. (2015). Routing and spectrum allocation in elastic optical networks: A tutorial. *IEEE Communications Surveys Tutorials*, 17(3):1776 – 1800.
- Cugini, F., Paolucci, F., Meloni, G., Berrettini, G., Secondini, M., Fresi, F., Sambo, N., Poti, L., and Castoldi, P. (2013). Push-pull defragmentation without traffic disruption in flexible grid optical networks. *Journal of Lightwave Technology*, 31(1):125–133.
- 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.
- Habibi, M. and Beyranvand, H. (2019). Impairment-aware anycast 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.
- 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*.
- Lacerda-Jr, J., Fontinele, A., Santos, I., Leão, E., Campelo, D., Monteiro, J. A., and Soares, A. (2020). Algoritmo de balanceamento inter-núcleos para redes Ópticas elásticas com multiplexação por divisão espacial. In *Anais do XXXVIII Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos*, Rio de Janeiro, RJ, Brasil.
- 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.
- 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.

- Meloni, G., Fresi, F., Imran, M., Paolucci, F., Cugini, F., D'Errico, A., Giorgi, L., Sasaki, T., Castoldi, P., and Pot, L. (2016). Software-defined defragmentation in space-division multiplexing with quasi-hitless fast core switching. *Journal of Lightwave Technology*, 34(8):1956–1962.
- Moghaddam, E. E., Beyranvand, H., and Salehi, J. A. (2019). 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*, pages 1–1.
- Oliveira, H. M. and da Fonseca, N. L. (2020). Protection in elastic optical networks using failure-independent path protecting p-cycles. *Optical Switching and Networking*, 35:100535.
- 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.
- Ravipudi, J. L. and Brandt-Pearce, M. (2022). A score function heuristic for crosstalk- and fragmentation-aware dynamic routing, modulation, core, and spectrum allocation in sdm-eons. In *2022 IEEE Future Networks World Forum (FNWF)*, pages 83–87.
- Ravipudi, J. L. and Brandt-Pearce, M. (2024). Machine-learning-based impairment-aware dynamic rmsca in multi-core elastic optical networks. *J. Opt. Commun. Netw.*, 16(10):F26–F39.
- Trindade, S. and d. Fonseca, N. L. S. (2020). Machine learning for spectrum defragmentation in space-division multiplexing elastic optical networks. *IEEE Network*, pages 1–7.
- Vasundhara and Mandloi, A. (2024). Deep learning and heuristic approach assisted dynamic spectrum assignment with fragmentation minimization in eon-sdm. In *2024 First International Conference on Electronics, Communication and Signal Processing (ICECSP)*, pages 1–5.
- Yan, L., Agrell, E., Wymeersch, H., Johannisson, P., Taranto, R. D., 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.
- Zhang, C., Zhang, M., Liu, S., Liu, Z., and Wang, D. (2023). Covert fault detection with imbalanced data using an improved autoencoder for optical networks. *IEEE/OSA Journal of Optical Communications and Networking*, 15(11):913–924.
- Zhao, J., Wymeersch, H., and Agrell, E. (2015). Nonlinear impairment aware resource allocation in elastic optical networks. In *2015 Optical Fiber Communications Conference and Exhibition (OFC)*, pages 1–3.
- Zhao, Y., Hu, L., Zhu, R., Yu, X., Wang, X., and Zhang, J. (2018). Crosstalk-aware spectrum defragmentation based on spectrum compactness in space division multiplexing enabled elastic optical networks with multicore fiber. *IEEE Access*, 6:15346–15355.