



**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO PIAUÍ CAMPUS
CORRENTE
TECNOLOGIA EM ANÁLISE E DESENVOLVIMENTO DE SISTEMAS**

ANA VITÓRIA DIAS CARVALHO

**UM NOVO ALGORITMO BASEADO EM APRENDIZADO DE MÁQUINA PARA
REALOCAÇÃO ESPECTRAL EM REDES ÓPTICAS ELÁSTICAS MULTI-NÚCLEOS**

**CORRENTE, PIAUÍ
2025**

ANA VITÓRIA DIAS CARVALHO

UM NOVO ALGORITMO BASEADO EM APRENDIZADO DE MÁQUINA PARA REALOCAÇÃO
ESPECTRAL EM REDES ÓPTICAS ELÁSTICAS MULTI-NÚCLEOS

Trabalho de Conclusão de Curso apresentado como exigência parcial para obtenção do diploma do Curso de Análise e Desenvolvimento de Sistemas do Instituto Federal de Educação, Ciência e Tecnologia do Piauí, Campus Corrente.

Orientador: Prof. Jurandir Cavalcante Lacerda Júnior

Coorientador: Prof. Carlos Estevão Bastos Sousa

CORRENTE, PIAUÍ
2025

Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD

Carvalho, Ana Vitoria Dias

C331n Um novo algoritmo baseado em aprendizado de máquina para realocação espectral em redes ópticas elásticas multi – núcleos / Ana Vitoria Dias Carvalho. - 2025.
35 p.: il. color.

Trabalho de Conclusão de Curso (Tecnologia em Análise e Desenvolvimento de Sistemas) - Instituto Federal de Educação, Ciência e Tecnologia do Piauí, Campus Corrente, 2025.

Orientador : Prof Dr. Jurandir Cavalcante Lacerda Júnior.

Coorientador : Prof Me. Carlos Estevão Bastos Sousa

1. Análise e Desenvolvimento de Sistemas - estudo e ensino. 2. Redes ópticas.
3. Fibras multi - núcleos. I.Título.

CDD - 004

RESUMO

Este trabalho 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.

Palavras-chaves: redes ópticas elásticas; fibras multi-núcleos; rede neural profunda; imperfeições da camada física; realocação.

ABSTRACT

This work 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.

Keywords: elastic optical networks; multicore fiber; deep neural networks; physical layer impairments; reallocation.

LISTA DE ILUSTRAÇÕES

Figura 1 – Comparação entre redes WDM e redes EON.	14
Figura 2 – Representação da Multiplexação por divisão espacial.	15
Figura 3 – Exemplo de Rede Neural Profunda	18
Figura 4 – Fluxograma do algoritmo AROI.....	25
Figura 5 – Variação das métricas de desempenho ao longo das épocas	29
Figura 6 – Curva ROC	30
Figura 7 – Topologia NSFNet com os comprimentos dos enlaces em km.	31
Figura 8 – Probabilidade de bloqueio.	32
Figura 9 – Componentes da probabilidade de bloqueio.	33

LISTA DE TABELAS

Tabela 1 – Informações gerais dos trabalhos relacionados.....	21
Tabela 2 – Descrição dos atributos utilizados no modelo preditivo.....	24
Tabela 3 – Hiperparâmetros da DNN e seus intervalos testados.....	26
Tabela 4 – Matriz de Confusão.....	29
Tabela 5 – Relatório de Classificação do Treino	30
Tabela 6 – Limites dos formatos de modulação.....	31
Tabela 7 – Parâmetros de camada física utilizados nas simulações	32

LISTA DE ABREVIATURAS E SIGLAS

ABNE	Algoritmo de Balanceamento de Núcleo e Espectro
AM	Aprendizado de Máquina
ASE	<i>Amplified Spontaneous Emission</i>
CASR	<i>Contiguous Aligned Slot Ratio</i>
CISUR	<i>Clusterization-Driven Spectrum Rearrangement</i>
C-RMCSA	<i>Clusterization RMCSA</i>
DNN	<i>Deep Neural Network</i>
EONs	<i>Elastic Optical Networks</i>
FMDE	<i>Fragmentation-aware Multipath Distance-adaptive Energy-efficient</i>
FN	Falso Negativo
NLIs	<i>Nonlinear Impairments</i>
OSNR	<i>Optical Signal to Noise Ratio</i>
OSNRN	OSNR inadequada para o circuito candidato
OSNRO	OSNR inadequada para os circuitos já estabelecidos.
PBB	probabilidade de bloqueio de banda
PBC	probabilidade de bloqueio de circuito
PLIs	<i>Physical Layer Impairments</i>
QoT	Qualidade De Transmissão
ReLU	<i>Rectified Linear Unit</i>
RMCSA	<i>Routing, Modulation, Core, And Spectrum Allocation</i>
RMSA	<i>Routing, Modulation, Spectrum Assignment</i>
SBP-PMC	<i>Shared Backup Path Protection for MultiCore networks algorithm</i>
SDM	<i>Space-Division Multiplexed</i>
SDM-EON	<i>Space-Division Multiplexed Elastic Optical Networks</i>

SF	<i>Score Function</i>
SLA	<i>service level agreement</i>
SNetS	slice network simulator
VP	Verdadeiro Positivo
VF	Falso Positivo
WDM	<i>wavelength-division multiplexed optical networks</i>
XT	<i>Crosstalk</i>
XTN	XT inadequado para o circuito candidato
XTO	XT inadequado para os circuitos já estabelecidos.

LISTA DE SÍMBOLOS

α	Atenuação da fibra
γ	Coefficiente não linear da fibra
h_e	Coefficiente de acoplamento
β_2	Dispersão de velocidade de grupo da fibra
ν	Frequência óptica
D	Parâmetro de dispersão da fibra
W_n	Perda do nó
F	Sobrecarga FEC
L_s	Tamanho de um <i>span</i>

SUMÁRIO

1	INTRODUÇÃO	11
1.1	Contribuições	12
1.2	Publicações.....	13
1.3	Organização do Trabalho	13
2	CONCEITOS BÁSICOS	14
2.1	Redes Ópticas Elásticas	14
2.2	Aprendizado de Máquina.....	17
3	TRABALHOS RELACIONADOS.....	20
4	MODELAGEM DA CAMADA FÍSICA.....	22
5	ALGORITMO PROPOSTO	24
5.1	Seleção do Conjunto de Dados.....	24
5.2	Funcionamento do Algoritmo de Realocação Óptica Inteligente	25
6	RESULTADOS E DISCUSSÕES	28
6.1	Avaliação do modelo de Aprendizado de Máquina.....	28
6.2	Avaliação do Modelo de AM na Otimização da Realocação	31
7	CONSIDERAÇÕES FINAIS	34
	REFERÊNCIAS	35

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; SARMA; OKI, 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; COSTA; DRUMMOND, 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; SARMA; OKI, 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 (*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 (*Quality of Transmission* - QoT) e limitam o alcance do sinal óptico (RAVIPUDI; 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; 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; MANDLOI, 2024). Técnicas de AM, como Redes Neurais Profundas (*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; BRANDT- PEARCE, 2024).

Neste contexto, este trabalho 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.

1.1 CONTRIBUIÇÕES

Este trabalho visa propor uma abordagem com uso de AM para realocação de circuitos ópticos em SDM-EONs, considerando os efeitos da camada física. As principais contribuições deste estudo incluem:

- Proposição do Algoritmo de Realocação Óptica Inteligente (AROI), uma abordagem baseada em aprendizado de máquina para identificar o momento ideal de realizar a realocação de circuitos ópticos em SDM-EONs.
- Consideração conjunta de múltiplos efeitos físicos que impactam a QoT, como *crosstalk* (XT), ruído ASE e interferências não-lineares de forma integrada em soluções de realocação.
- Avaliação do impacto da realocação de circuitos na mitigação do XT, demonstrando a capacidade do AROI de melhorar o desempenho global da rede.
- Demonstração de que o AROI é capaz de reduzir a taxa de bloqueio de requisições e aumentar a eficiência espectral, realizando alterações em menos de 1% dos circuitos ativos por processo de realocação.

1.2 PUBLICAÇÕES

Ao longo do desenvolvimento deste trabalho de conclusão de curso, os resultados alcançados foram divulgados por meio de um artigo científico. O artigo diretamente relacionado ao conteúdo deste trabalho está apresentado a seguir:

• **CARVALHO, Ana V. D.**; MENDES, Raylline P.; SOUSA, Carlos E. B.; ARAÚJO, Selles G. F. C.; SOARES, André C. B.; LACERDA JR., Jurandir C.. Novo Algoritmo Baseado em Aprendizado de Máquina para Gerenciamento de Realocação Espectral em Redes Ópticas Elásticas Multi-Núcleos. In: WORKSHOP DE GERÊNCIA E OPERAÇÃO DE REDES E SERVIÇOS (WGRS), 30. , 2025, Natal/RN. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, 2025 . p. 99-112. ISSN 2595-2722. DOI: <https://doi.org/10.5753/wgrs.2025.8861>.

1.3 ORGANIZAÇÃO DO TRABALHO

O restante deste trabalho está organizado da seguinte maneira: A Seção 2 apresenta os conceitos fundamentais sobre redes ópticas e aprendizado de máquina. A Seção 3 aborda os trabalhos relacionados ao tema deste trabalho. O modelo da camada física é discutido na Seção 4. O algoritmo proposto é apresentado na Seção 5. Os resultados numéricos que avaliam o desempenho do algoritmo proposto são detalhados na Seção 6. Por fim, as considerações finais deste trabalho estão na Seção 7.

2 CONCEITOS BÁSICOS

Este capítulo tem como objetivo introduzir os principais conceitos que fundamentam o desenvolvimento deste trabalho. Inicialmente, são abordadas as características das Redes Ópticas Elásticas (*Elastic optical networks* - EONs) e sua evolução para as redes baseadas em Multiplexação por Divisão Espacial (Space-Division Multiplexed Elastic Optical Network - SDM-EON), destacando-se os ganhos em eficiência espectral e os desafios associados à alocação de recursos. Em seguida, discute-se a aplicação de técnicas de Aprendizado de Máquina (AM), com ênfase em Redes Neurais Profundas (*Deep Neural Networks* - DNNs), como ferramentas promissoras para a automação de decisões e otimização do desempenho.

2.1 REDES ÓPTICAS ELÁSTICAS

Redes Ópticas Elásticas (*Elastic optical networks* - EONs) têm sido amplamente pesquisadas na última década devido à sua melhor utilização do espectro em comparação com Redes Ópticas Multiplexadas por Divisão de Comprimento de Onda (*Wavelength-Division Multiplexed Optical Networks*) - WDM (RAVIPUDI; BRANDT-PEARCE, 2023). Na Figura 1 é possível observar a diferença na alocação das requisições em redes WDM e EON, enquanto na primeira, todas as requisições reservam a mesma quantidade de recursos, devido ao seu modelo de grade fixa, na segunda, o provisionamento é feito com base na demanda de cada requisição, pois o espectro óptico é particionado em *slots* de frequência, com tamanho de 12,5 GHz, otimizando a utilização dos recursos disponíveis.




Figura 1 – Comparação entre redes WDM e redes EON. Recentemente, a literatura tem investigado um modelo de multiplexação conhecido como Multiplexação por Divisão Espacial (*Space Division Multiplexing* - SDM) (OLIVEIRA; FONSECA, 2019). Conforme demonstrado na Figura 2, nesse modelo as redes ópticas integram múltiplos núcleos ópticos em uma única fibra, aumentando significativamente a capacidade de comunicação em comparação com as redes tradicionais de núcleo único (BRASILEIRO; COSTA; DRUMMOND, 2020).




Figura 2 – Representação da Multiplexação por divisão espacial.

Esse aumento na capacidade, no entanto, também exige uma evolução no processo de alocação de recursos, uma vez que a gestão de múltiplos núcleos ópticos torna-se mais complexa. Assim, o desafio de alocação de circuitos, denominado *Routing, Modulation, Spectrum Assignment* (RMSA) no contexto das redes EON, evolui para *Routing, Modulation, Core, and Spectrum Allocation* (RMCSA) quando aplicado às redes SDM-EON (KLINKOWSKI; LECHOWICZ; WALKOWIAK, 2018).

Além dessa complexidade adicional, para cada circuito candidato retornado por um algoritmo RMCSA, deve-se verificar se os níveis da Relação Sinal-Ruído Óptico (*Optical Signal to Noise Ratio* - OSNR) e XT estão de acordo com os limites de OSNR e XT 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 algoritmos tradicionais que abordam o problema RMCSA em SDM-EON frequentemente enfrentam dificuldades para equilibrar a eficiência no uso do espectro disponível com a QoT necessária para atender às requisições, devido à incidência das PLIs, especialmente o XT, principal fator limitante da camada física. Como resultado, o aproveitamento dos recursos torna-se inadequado, aumentando a probabilidade de bloqueio das requisições. Nesse contexto, diversas técnicas foram desenvolvidas para melhorar o estado da rede, com destaque para a realocação de circuitos, que visa otimizar a alocação de recursos e reduzir os bloqueios.

A realocação de circuitos em redes SDM-EON refere-se ao processo de migração do tráfego de um circuito ativo para uma nova solução RMCSA. Essa nova configuração pode envolver modificações na rota, no formato de modulação, no núcleo da fibra ou na alocação espectral do circuito em relação à sua solução original (ARAUJO; SOARES, 2024).

O processo de realocação ocorre em diversas fases, conforme descrito na literatura:

1. **Identificação do momento ideal para realocação** - A decisão de iniciar a realocação é baseada em eventos específicos, conhecidos como *gatilhos*, que podem incluir degradação do sinal óptico, congestionamento espectral ou otimizações de recursos (CHATTERJEE; BA; OKI, 2018).
2. **Seleção e ordenação dos circuitos a serem realocados** - A escolha dos circuitos a serem migrados pode seguir critérios como prioridade de serviço, eficiência espectral ou impacto na rede.
3. **Definição da estratégia de realocação** - Determina-se a nova configuração RMCSA para cada circuito realocado, considerando restrições físicas e de QoT.
4. **Execução da migração do tráfego** - A transição pode ser realizada por meio de diferentes técnicas, dependendo do impacto aceitável na continuidade da transmissão de dados (CHATTERJEE; BA; OKI, 2018).

Os métodos de realocação podem ser classificados em duas categorias principais, dependendo da técnica utilizada. A primeira, denominada *non-hitless*, engloba abordagens que interrompem temporariamente o tráfego de dados do circuito durante a migração, resultando em perda de dados (ARAUJO; SOARES, 2024). Já a segunda, conhecida como *hitless*, compreende técnicas que realizam a realocação sem interrupção do tráfego (ARAUJO; SOARES, 2024). Dentre as principais abordagens *hitless* descritas na literatura, destacam-se:

- **Hop Retuning** (PROIETTI CHUAN QIN, 2012) – Esta técnica envolve o ajuste incremental da frequência de um canal óptico para uma nova posição espectral. O processo é realizado de forma gradual, permitindo que o sinal seja movido para uma nova frequência sem interrupção perceptível no serviço.

- **Push-Pull** (CUGINI et al., 2013) – Nesta abordagem, a realocação é realizada através da movimentação coordenada de múltiplos circuitos. Especificamente, um novo caminho é estabelecido para o tráfego, enquanto o caminho original é mantido até que a transição seja concluída. Após a confirmação de que o novo caminho está operando corretamente, o antigo é desativado. Esta técnica garante que não haja interrupção no serviço durante a migração do tráfego.

- **Fast-Switching** (MELONI et al., 2016) – Esta técnica utiliza comutação rápida para minimizar o tempo de transição entre canais ou caminhos ópticos. Ao empregar mecanismos de comutação de alta velocidade, é possível realocar o tráfego de maneira quase instantânea, reduzindo significativamente a latência e evitando interrupções perceptíveis no serviço.

• **Make-Before-Break** (TAKAGI et al., 2011) – Nesta abordagem, uma nova conexão é estabelecida antes da desativação da antiga. Isso garante que o tráfego seja transferido para o novo caminho sem qualquer interrupção no serviço. Após a confirmação de que a nova conexão está funcionando corretamente, a conexão original é desativada. Esta técnica é amplamente utilizada para garantir a continuidade do serviço durante processos de manutenção ou otimização da rede.

As realocações são geralmente utilizadas na literatura para desfragmentar o espectro ou reduzir os impactos da camada física, especialmente os efeitos não lineares. No entanto, conforme demonstrado em (ARAUJO; SOARES, 2024), essa técnica também se mostrou eficaz na mitigação dos efeitos do XT. Ainda assim, um dos principais desafios é definir com precisão o gatilho para iniciar o processo de realocação, uma vez que essa definição é essencial para assegurar que a realocação irá gerar efeitos positivos na rede.

2.2 APRENDIZADO DE MÁQUINA

O Aprendizado de Máquina (AM) tem se consolidado como uma ferramenta estratégica na automação de decisões complexas em redes de telecomunicações, especialmente em contextos que exigem otimização dinâmica de recursos, como ocorre na realocação de circuitos em redes SDM-EON (YADAV; BIDNYK; BALAKRISHNAN, 2024). Diferentemente das abordagens tradicionais baseadas em regras fixas e modelos determinísticos, os algoritmos de AM apresentam a capacidade de aprender padrões e comportamentos a partir de dados históricos, adaptando-se a variações dinâmicas na demanda, nos parâmetros de qualidade de serviço e nas condições operacionais da rede (ZHANG et al., 2020).

O campo do AM compreende diferentes paradigmas de aprendizagem: supervisionado (o modelo aprende mapeamentos de entrada-saída a partir de exemplos rotulados), não-supervisionado (encontra estruturas em dados não rotulados, como agrupamentos) e aprendizado por reforço (um agente aprende a tomar ações em um ambiente para maximizar uma recompensa) (VASUNDHARA; MANDLOI, 2024).

Dentro desse contexto, as Redes Neurais Profundas (*Deep Neural Networks* - DNNs) representam um dos pilares mais promissores do AM, especialmente devido à sua notável capacidade de modelar funções complexas e extrair representações hierárquicas de dados de alta dimensionalidade. Inspiradas na arquitetura do cérebro humano, as DNNs são compostas por camadas interconectadas de neurônios artificiais organizadas em três níveis principais: camadas de entrada, responsáveis por receber os dados brutos; camadas ocultas, que realizam transformações sucessivas, extraíndo características cada vez mais abstratas; e a camada de saída, que fornece a predição ou classificação final (FARIAS; ROSSI, 2021), conforme representado na Figura 3.




Figura 3 – Exemplo de Rede Neural Profunda

O treinamento de redes neurais profundas usualmente é realizado por meio de aprendizado supervisionado, onde a rede recebe pares de entrada e saída (rótulos) e ajusta seus pesos internos para minimizar o erro de previsão. Esse processo geralmente ocorre em duas etapas principais, na primeira, conhecida como *feedforward*, os pesos sinápticos que conectam os neurônios são inicialmente definidos com valores aleatórios. A partir disso, os dados de entrada são propagados sequencialmente pelas camadas da rede até gerar uma saída. Essa etapa não envolve ainda aprendizado efetivo, mas sim o cálculo da predição inicial da rede (FARIAS; ROSSI, 2021).

Na segunda etapa, denominada retropropagação do erro (*backpropagation*), ocorre o processo de aprendizagem propriamente dito. A saída gerada é comparada com a saída esperada, e a diferença (erro) entre elas é utilizada para ajustar os pesos sinápticos da rede. Esse ajuste é feito propagando o erro de forma reversa, desde a saída até a entrada, atualizando os pesos de acordo com o gradiente da função de erro em relação a cada peso. Essa técnica permite que a rede "aprenda" com os erros cometidos, refinando seus parâmetros a cada iteração (YADAV; BIDNYK; BALAKRISHNAN, 2024).

O processo de treinamento se repete por múltiplos ciclos, também chamados de épocas, até que a função de erro alcance um valor mínimo aceitável ou até que se atinja um número predefinido de iterações. Para isso, é fundamental o uso de uma função objetivo, que quantifica o erro global da rede. O algoritmo de otimização, normalmente baseado em variações do Gradiente Descendente, é responsável por atualizar os pesos no sentido de minimizar a função de custo (LECUN YOSHUA BENGIO, 2015).

Em suma, o grande diferencial das DNNs está na sua capacidade de representação hierárquica e abstrata de dados. Camadas iniciais da rede tendem a aprender características básicas, enquanto camadas mais profundas aprendem combinações mais complexas e semânticas dessas características. Essa capacidade as torna especialmente adequadas para lidar com problemas envolvendo grandes volumes de dados não estruturados (LECUN YOSHUA BENGIO, 2015).

Apesar dos avanços, treinamentos de DNNs exigem grandes quantidades de dados rotulados e poder computacional. Além disso, são modelos de “caixa-preta” menos interpretáveis comparados a heurísticas fixas. Por outro lado, uma vez treinados, modelos baseados em aprendizado profundo costumam fazer previsões em tempo real mais rapidamente do que algoritmos de otimização exaustiva. Em síntese, as DNNs oferecem grande capacidade de modelagem de funções complexas, mas requerem cuidado no preparo dos dados e na garantia de que permanecerão válidas se o cenário de rede mudar.

3 TRABALHOS RELACIONADOS

A literatura apresenta estudos com estratégias para alocar eficientemente os recursos espectrais, visando melhorar o desempenho das SDM-EONs (LACERDA-JR; CARTAXO; SOARES, 2023; OLIVEIRA; FONSECA, 2020). Outros estudos focam em desenvolver técnicas de realocação espectral (ARAUJO; SOARES, 2024; TRINDADE; FONSECA, 2020) ou mesmo modelos de AM para auxiliar na realocação dos recursos ópticos (TRINDADE; FONSECA, 2020; VASUNDHARA; 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; 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 demonstram que o algoritmo reduz a probabilidade de bloqueio em pelo menos 44% na topologia NSFNet e 33% na topologia EON.

O estudo em (RAVIPUDI; 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; 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; 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).

Diferentemente dos trabalhos mencionados, conforme demonstrado na Tabela 1, este estudo propõe um método de realocação baseado em AM que trata, de forma integrada, os principais efeitos físicos que impactam as SDM-EONs: XT, ruído ASE e NLIs. Enquanto a maioria dos trabalhos considera apenas o XT (ZHAO et al., 2018; RAVIPUDI; BRANDT-PEARCE, 2022), ou não utiliza técnicas de AM (LACERDA- JR et al., 2020; ARAUJO; SOARES, 2024), esta proposta se destaca por empregar DNNs, integrando múltiplos efeitos físicos e considerando sete núcleos ópticos, o que contribui para uma avaliação mais completa e eficiente na realocação de circuitos no cenário apresentado.

Tabela 1 – Informações gerais dos trabalhos relacionados.

Referência	PLIs	Qtd. Núcleos	Modelos de AM
(ZHAO et al., 2018)	XT	7	Não utiliza
(TRINDADE; FONSECA, 2020)	nenhum	7	<i>K-Means clustering</i>
(LACERDA-JR et al., 2020)	ASE, NLIs e XT	7	Não utiliza
(RAVIPUDI; BRANDT-PEARCE, 2022)	XT	7	Não utiliza
(ARAUJO; SOARES, 2024)	ASE, NLIs e XT	7	Não utiliza
(VASUNDHARA; MANDLOI, 2024)	XT	3	DNN
Este trabalho	ASE, NLIs e XT	7	DNN

4 MODELAGEM DA 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 à 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; 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

$$OSNR_m = \frac{G_m}{G_m^{ASE} + G_m^{NLI}}, \quad (4.1)$$

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; 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

$$XT_{\mu,m}^{(tot)} = \sum_{e=1}^{|E_m|} XT_{\mu,m,e}, \quad (4.2)$$

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)

$$P_{XT_{m,e}} = \sum_{n=1}^{N_{m,e}} (ISO_{m,e,n} \cdot P_n \cdot h_e \cdot L_e), \quad (4.3)$$

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. $ISO_{m,e,n}$ é o índice de sobreposição de *slots* entre os circuitos m e n no enlace e , dado por $ISO_{m,e,n} = (S_{SO_{m,e,n}})/(S_{e,n})$, 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 *crosstalk* 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 6 do Capítulo 6.

5 ALGORITMO PROPOSTO

Diante das limitações dos algoritmos tradicionais de RMCSA, especialmente no que diz respeito ao equilíbrio entre a eficiência espectral e a QoT, este trabalho propõe o Algoritmo de Realocação Óptica Inteligente (AROI). A abordagem é baseada em AM, utilizando DNN como mecanismo para determinar se a requisição será aceita ou recusada, bem como o tipo de bloqueio que pode ocorrer.

O AROI busca mitigar os efeitos das PLIs, com foco especial no XT, um dos principais responsáveis pelo aumento da taxa de bloqueio em redes SDM-EON. Com base na predição do comportamento de um algoritmo RMCSA de referência (ABNE (LACERDA-JR et al., 2020)), o AROI identifica situações em que a realocação de circuitos pode evitar falhas futuras e melhorar o desempenho geral da rede.

5.1 SELEÇÃO DO CONJUNTO DE DADOS

Para a criação do modelo de AM, foi necessário gerar uma base de dados representativa das condições operacionais da rede. Para isso, o algoritmo ABNE é executado através de simulação computacional por meio do *SLICE Network Simulator* (SNetS) (FONTINELE et al., 2017) em diferentes níveis de carga da rede, e os valores de determinados atributos são registrados para cada requisição feita ao plano de controle da rede, totalizando 564.126 registros. Os atributos considerados, em um total de onze (dez atributos mais o atributo alvo), são descritos na Tabela 2.

Tabela 2 – Descrição dos atributos utilizados no modelo preditivo.

Atributo	Descrição
Banda requisitada	Largura de banda solicitada pela conexão.
Formato da modulação	Tipo de modulação empregado na transmissão.
Nó de origem	Ponto inicial da rota de comunicação.
Nó de destino	Ponto final da rota de comunicação.
Comprimento da rota	Extensão total do caminho percorrido.
Núcleo escolhido	Núcleo da fibra óptica selecionado.
Núcleos adjacentes	Quantidade de núcleos vizinhos ao núcleo utilizado.
Número de saltos	Total de enlaces da rota.
Nível de XT	Nível de interferência por <i>crosstalk</i> .
Nível de OSNR	Relação sinal-ruído óptica.
Status da conexão (atributo alvo)	Classes numéricas de 1 a 5 representando tipos de bloqueio.

Conforme descrito na Tabela 2, os atributos utilizados no modelo preditivo incluem dez atributos que representam o estado da rede e o atributo alvo, chamado *status* da conexão, que é dividido em cinco classes numéricas de 1 à 5, onde: 1 representa conexão estabelecida, 2 conexão não estabelecida por OSNRN, 3 conexão não estabelecida por OSNRO, 4 conexão não estabelecida por XTN e 5 conexão não estabelecida por XTO. Esta base é utilizada tanto para treinar quanto para avaliar o modelo preditivo responsável pela ativação da etapa de realocação.

5.2 FUNCIONAMENTO DO ALGORITMO DE REALOCAÇÃO ÓPTICA INTELIGENTE

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 4 ilustra esse fluxo.

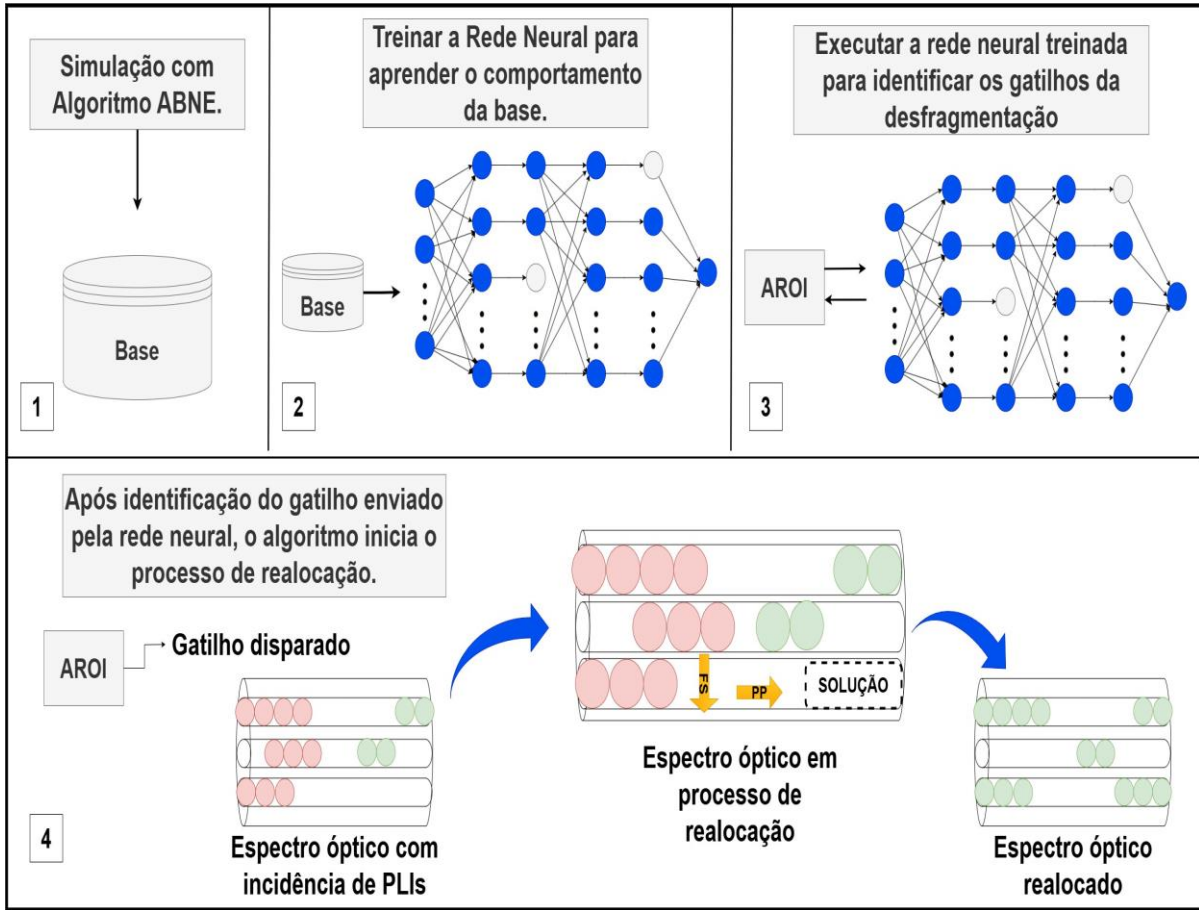


Figura 4 – Fluxograma do algoritmo AROI.

Após a criação da base de dados, conforme descrito na Seção 5.1, foi desenvolvido um modelo de DNN utilizando as bibliotecas Keras e TensorFlow. A definição da arquitetura da rede foi realizada de forma empírica, por meio de experimentações com diferentes combinações de hiperparâmetros, conforme detalhado na Tabela 3. Foram testadas variações na taxa de aprendizagem, na estrutura da rede, nas funções de ativação, nas estratégias de regularização, na inicialização dos pesos, bem como nos critérios de parada antecipada e de redução adaptativa da taxa de aprendizagem. A combinação de hiperparâmetros que resultou no melhor desempenho, com base na acurácia de validação, está apresentada na coluna “Valor escolhido” da Tabela 3.

Conforme ilustrado na Figura 4, 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; SOARES, 2024).

Tabela 3 – Hiperparâmetros da DNN e seus intervalos testados.

Hiperparâmetros	Valores testados	Valor escolhido
Taxa de aprendizagem inicial	10^{-2} , 10^{-3} , 10^{-4}	10^{-3}
Número de camadas ocultas	1, 2, 3	2
Número de neurônios na primeira camada oculta	32, 64, 128	64
Número de neurônios na segunda camada oculta	16, 32, 64	32
Função de ativação na camada oculta	ReLU, Sigmoid	ReLU
Função de ativação na camada de saída	Softmax	Softmax
Regularizador	Nenhum, L2, Dropout	Dropout
Inicializador	He Normal, Glorot Uniform	Glorot Uniform
Critério de parada antecipada (EarlyStopping)	Patience = 3, 5, 7	Patience = 5
Redução da taxa de aprendizagem (ReduceLROnPlateau)	Factor = 0.1, 0.5; Patience = 2, 3, 5	Factor = 0.5, Patience = 3

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; SOARES, 2024), onde apenas é realizado reatribuição nuclear e/ou reatribuição espectral. Este trabalho assim como a proposta de (ARAUJO; SOARES, 2024) não realiza uma nova escolha de rota pelo fato do 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 predominante 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 em relação aos PLIs.

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; SOARES, 2024), onde apenas é realizado reatribuição nuclear e/ou reatribuição espectral. Este trabalho assim como a proposta de (ARAUJO; SOARES, 2024) não realiza uma nova escolha de rota pelo fato do 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 predominante 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 em relação aos 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 o *crosstalk* em cada núcleo. Este procedimento é realizado para cada circuito selecionado.

6 RESULTADOS E DISCUSSÕES

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.

6.1 AVALIAÇÃO DO MODELO DE APRENDIZADO DE MÁQUINA


A primeira etapa de avaliação do AROI tem início já na fase de treinamento do modelo de AM. Durante esse processo, foi empregada a estratégia de *callback*, uma função auxiliar que monitora métricas de desempenho e ajusta automaticamente parâmetros do modelo. Dentre essas funções, destaca-se a técnica de *EarlyStopping*, que atuou de forma crucial ao interromper o treinamento assim que foi detectada estagnação da métrica de interesse, neste caso a perda de validação, por 20 épocas consecutivas. A escolha pela perda de validação como critério de parada justifica-se por refletir o desempenho do modelo em dados não vistos durante o treinamento, sendo, portanto, um indicador da capacidade de generalização.

A Figura 5(a) apresenta a evolução da função de perda (*Loss*) ao longo das épocas. O treinamento foi concluído na 40ª época, com a função de perda progressivamente minimizada durante o processo de otimização. O gráfico revela que, após a 20ª 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.


A Figura 5(b) 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).

Na Tabela 4, é apresentada a matriz de confusão do algoritmo AROI. Ela foi utilizada para avaliar a performance do modelo no conjunto de dados de treino. Cada valor na tabela 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) Loss durante o treinamento



(b) Acurácia Durante o Treinamento.

Figura 5 – Variação das métricas de desempenho ao longo das épocas.

Tabela 4 – 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						


Conforme ilustrado na Tabela 5, que apresenta o desempenho do algoritmo AROI em relação às diferentes classes de status da conexão, observa-se um desempenho global satisfatório, com uma acurácia total de 89%. A métrica F1-score, que representa a média harmônica entre precisão e recall, apresentou valores equilibrados entre as classes, variando de 0,86 a 0,95. Esse comportamento indica que o modelo manteve um equilíbrio adequado entre identificar corretamente as instâncias de cada classe e minimizar os erros de classificação.

Entretanto, ao analisar os resultados por classe, é possível observar algumas variações que mostram potenciais fontes de erro. A Classe 3, por exemplo, obteve um recall de 0,79, o menor entre todas as categorias, o que sugere que o modelo teve maior dificuldade em reconhecer corretamente as instâncias pertencentes a essa classe, resultando em um número mais elevado de falsos negativos. Da mesma forma, a Classe 4 apresentou a menor precisão (0,82), o que pode indicar que o modelo frequentemente confundiu instâncias de outras classes como pertencentes a essa, gerando mais falsos positivos. Apesar dessas limitações pontuais, os resultados obtidos indicam que o modelo apresenta uma performance satisfatória e coerente com o objetivo deste trabalho.

Tabela 5 – Relatório de Classificação do Treino.

Classe	Precisão	recall	F1-score
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

A Figura 6 apresenta as curvas *Receiver Operating Characteristic* (ROC) para cada uma das cinco classes do modelo de classificação treinado. Observa-se um desempenho expressivo, com destaque para as Classes 1, 2 e 3, que atingiram uma Área Sob a Curva (AUC) de 1,00, evidenciando uma capacidade de discriminação entre os exemplos positivos e negativos dessas classes. A Classe 0 também apresentou bom desempenho, com AUC de 0,98, enquanto a Classe 4, embora levemente inferior às demais, manteve um resultado elevado, com AUC de 0,97. Esses valores indicam que o modelo é eficaz na tarefa de classificação multiclasse, sendo capaz de distinguir com precisão os diferentes tipos de resposta (estabelecida ou recusada por diferentes causas).

**Figura 6** – Curva ROC

Em síntese, a análise dos resultados obtidos durante o treinamento do modelo AROI evidencia sua capacidade de aprendizado e generalização diante da tarefa de classificação multiclasse. As métricas de desempenho, incluindo acurácia, precisão, *recall*, *F1-score*, além da análise da matriz de confusão e das curvas ROC, demonstraram que o modelo é capaz de distinguir adequadamente as diferentes classes de status da conexão, mesmo com pequenas variações no desempenho entre elas.

6.2 AVALIAÇÃO DO MODELO DE AM NA OTIMIZAÇÃO DA REALOCAÇÃO

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 6 (IVES; BAYVEL; SAVORY, 2015; MOGHADDAM; BEYRANVAND; SALEHI, 2019).

Tabela 6 – 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. A topologia considerada nas simulações é a NSFNet, apresentada na Figura 7.




Figura 7 – Topologia NSFNet com os comprimentos dos enlaces em km.

Na Tabela 7 estão listados outros parâmetros utilizados (BEYRANVAND; SALEHI, 2013; ZHAO; WYMEERSCH; AGRELL, 2015; LOBATO et al., 2019).

Tabela 7 – Parâmetros de camada física utilizados nas simulações.

Descrição	Valor
Atenuação da fibra (α)	0,2 dB/km
Coeficiente não linear da fibra (γ)	$1,3 (W \cdot km)^{-1}$
Coeficiente de acoplamento (h_e)	$1,5 \times 10^{-9} m^{-1}$
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 trabalho 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 8.




Figura 8 – Probabilidade de bloqueio.

A Figura 8 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 8 (a), e probabilidade de bloqueio de banda (PBB), na Figura 8 (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 9.




Figura 9 – Componentes da probabilidade de bloqueio.

Ne Figura 9 é possível observar que os principais fatores que geram bloqueios para o algoritmo ABNE são os relacionados ao *crosstalk* (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.

7 CONSIDERAÇÕES FINAIS

Neste trabalho, 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, *recall* 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, testado-o em outras topologias e aplicando-o à outros algoritmos RMCSA para uma análise mais abrangente de sua capacidade.

REFERÊNCIAS

- ARAUJO, S.; SOARES, A. 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*. Porto Alegre, RS, Brasil: SBC, 2024. p. 127–140. ISSN 2177-9384. Disponível em: <<https://sol.sbc.org.br/index.php/sbrc/article/view/29788>>. Citado 6 vezes nas páginas 12, 16, 17, 20, 21 e 26.
- BEYRANVAND, H.; SALEHI, J. A quality-of-transmission aware dynamic routing and spectrum assignment scheme for future elastic optical networks. *IEEE/OSA Journal of Lightwave Technology*, v. 31, n. 18, p. 3043–3054, Sept 2013. Citado na página 32.
- BRASILEIRO, I.; COSTA, L.; DRUMMOND, A. A survey on challenges of spatial division multiplexing enabled elastic optical networks. *Optical Switching and Networking*, v. 38, p. 100584, 2020. ISSN 1573-4277. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1573427720300461>>. Citado 2 vezes nas páginas 11 e 15.
- CHATTERJEE, B.; SARMA, N.; OKI, E. Routing and spectrum allocation in elastic optical networks: A tutorial. *IEEE Communications Surveys Tutorials*, v. 17, n. 3, p. 1776 – 1800, thirdquarter 2015. ISSN 1553-877X. Citado na página 11.
- CHATTERJEE, B. C.; BA, S.; OKI, E. Fragmentation problems and management approaches in elastic optical networks: A survey. *IEEE Communications Surveys Tutorials*, v. 20, n. 1, p. 183–210, 2018. Citado na página 16.
- CUGINI, F. et al. Push-pull defragmentation without traffic disruption in flexible grid optical networks. *Journal of Lightwave Technology*, v. 31, n. 1, p. 125–133, 2013. Citado 2 vezes nas páginas 16 e 26.
- FARIAS, T.; ROSSI, R. Estudo comparativo de arquiteturas de redes neurais em análise de sentimentos. 07 2021. Citado na página 18.
- FONTINELE, A. et al. An efficient IA-RMLSA algorithm for transparent elastic optical networks. *Computer Networks*, v. 118, p. 1–14, 2017. ISSN 1389-1286. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1389128617300634>>. Citado 2 vezes nas páginas 24 e 31.
- HABIBI, M.; BEYRANVAND, H. Impairment-aware anycast routing, modulation level, and spectrum assignment in elastic optical networks. *IEEE/OSA Journal of Optical Communications and Networking*, v. 11, n. 5, p. 179–189, 2019. Citado na página 22.
- HAYASHI, T. et al. Design and fabrication of ultra-low crosstalk and low-loss multi-core fiber. *Optics Express*, v. 19, p. 16576–16592, 08 2011. Citado 3 vezes nas páginas 11, 12 e 22.
- IVES, D.; BAYVEL, P.; SAVORY, S. Routing, modulation, spectrum and launch power assignment to maximize the traffic throughput of a nonlinear optical mesh network. *Photonic Network Communications*, 2015. Citado na página 31.
- KLINKOWSKI, M.; LECHOWICZ, P.; WALKOWIAK, K. Survey of resource allocation schemes and algorithms in spectrally-spatially flexible optical networking. *Optical Switching and Networking*, v. 27, p. 58–78, 2018. ISSN 1573-4277. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S157342771730053X>>. Citado na página 15.

LACERDA-JR, J. et al. 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: [s.n.], 2020. Disponível em: <<https://sol.sbc.org.br/index.php/sbrc/article/view/12306>>. Citado 5 vezes nas páginas 11, 20, 21, 24 e 32.

LACERDA-JR, J. C.; CARTAXO, A. V.; SOARES, A. C. Novel dynamic impairment-aware algorithm for modulation, core, and spectrum assignment in SDM-EONs. *Optical Switching and Networking*, v. 51, p. 100763, 2023. ISSN 1573-4277. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1573427723000346>>. Citado na página 20.

LECUN YOSHUA BENGIO, G. E. H. Y. Deep learning. *EBSCOhost Academic Search Premier*, v. 521, n. 7553, 2015. Citado na página 19.

LOBATO, F. R. et al. Inter-core crosstalk aware greedy algorithm for spectrum and core assignment in space division multiplexed elastic optical networks. *Optical Switching and Networking*, v. 33, p. 61–73, 2019. ISSN 1573-4277. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1573427718301589>>. Citado 4 vezes nas páginas 11, 22, 23 e 32.

MELONI, G. et al. Software-defined defragmentation in space-division multiplexing with quasi-hitless fast core switching. *Journal of Lightwave Technology*, v. 34, n. 8, p. 1956–1962, 2016. Citado 2 vezes nas páginas 17 e 26.

MOGHADDAM, E. E.; BEYRANVAND, H.; SALEHI, J. A. 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*, p. 1–1, 2019. ISSN 1558-2213. Citado na página 31.

OLIVEIRA, H.; FONSECA, N. Proteção e roteamento multicaminho em redes ópticas elásticas com multiplexação por divisão espacial. In: *Anais do XXXVII Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos*. Gramado, RS, Brasil: SBC, 2019. p. 487–500. ISSN 2177-9384. Disponível em: <<https://sol.sbc.org.br/index.php/sbrc/article/view/7381>>. Citado na página 14.

OLIVEIRA, H. M.; FONSECA, N. L. da. Protection in elastic optical networks using failure-independent path protecting p-cycles. *Optical Switching and Networking*, v. 35, p. 100535, 2020. ISSN 1573-4277. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S157342771730245X>>. Citado na página 20.

POGGIOLINI, P.; JIANG, Y. Recent advances in the modeling of the impact of nonlinear fiber propagation effects on uncompensated coherent transmission systems. *IEEE/OSA Journal of Lightwave Technology*, v. 35, n. 3, p. 458–480, 2017. Citado na página 22.

PROIETTI CHUAN QIN, B. G. Y. Y. R. P. S. R. Y. S. J. B. Y. R. *Rapid and complete hitless defragmentation method using a coherent RX LO with fast wavelength tracking in elastic optical networks*. 2012. Citado na página 16.

RAVIPUDI, J. L.; BRANDT-PEARCE, M. 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)*. [S.l.: s.n.], 2022. p. 83–87. Citado 2 vezes nas páginas 20 e 21.

RAVIPUDI, J. L.; BRANDT-PEARCE, M. Impairment- and fragmentation-aware, energy-efficient dynamic RMSCA for SDM-EONs. *IEEE/OSA Journal of Optical Communications and Networking*, v. 15, n. 9, p. D10–D22, 2023. Citado na página 14.

RAVIPUDI, J. L.; BRANDT-PEARCE, M. Machine-learning-based impairment-aware dynamic rmsca in multi-core elastic optical networks. *J. Opt. Commun. Netw.*, Optica Publishing Group, v. 16, n. 10, p. F26–F39, Oct 2024. Disponível em: <<https://opg.optica.org/jocn/abstract.cfm?URI=jocn-16-10-F26>>. Citado 2 vezes nas páginas 11 e 12.

TAKAGI, T. et al. Disruption minimized spectrum defragmentation in elastic optical path networks that adopt distance adaptive modulation. In: *2011 37th European Conference and Exhibition on Optical Communication*. [S.l.: s.n.], 2011. p. 1–3. Citado na página 17.

TRINDADE, S.; FONSECA, N. L. S. d. Machine learning for spectrum defragmentation in space-division multiplexing elastic optical networks. *IEEE Network*, p. 1–7, 2020. Citado 2 vezes nas páginas 20 e 21.

VASUNDHARA; MANDLOI, A. 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)*. [S.l.: s.n.], 2024. p. 1–5. Citado 4 vezes nas páginas 12, 17, 20 e 21.

YADAV, K.; BIDNYK, S.; BALAKRISHNAN, A. Artificial intelligence and machine learning in optics: tutorial. *J. Opt. Soc. Am. B*, Optica Publishing Group, v. 41, n. 8, p. 1739–1753, Aug 2024. Disponível em: <<https://opg.optica.org/josab/abstract.cfm?URI=josab-41-8-1739>>. Citado 2 vezes nas páginas 17 e 18.

YAN, L. et al. Link-level resource allocation for flexible-grid nonlinear fiber-optic communication systems. *IEEE Photonics Technology Letters*, v. 27, n. 12, p. 1250–1253, June 2015. ISSN 1941-0174. Citado na página 22.

ZHANG, C. et al. Covert fault detection with imbalanced data using an improved autoencoder for optical networks. *IEEE/OSA Journal of Optical Communications and Networking*, Optica Publishing Group, v. 15, n. 11, p. 913–924, Nov 2023. Disponível em: <<https://opg.optica.org/jocn/abstract.cfm?URI=jocn-15-11-913>>. Citado na página 28.

ZHANG, Y. et al. Overview on routing and resource allocation based machine learning in optical networks. *Optical Fiber Technology*, v. 60, p. 102355, 2020. ISSN 1068-5200. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S106852002030345X>>. Citado na página 17.

ZHAO, J.; WYMEERSCH, H.; AGRELL, E. Nonlinear impairment aware resource allocation in elastic optical networks. In: *2015 Optical Fiber Communications Conference and Exhibition (OFC)*. [S.l.: s.n.], 2015. p. 1–3. Citado na página 32.

ZHAO, Y. et al. Crosstalk-aware spectrum defragmentation based on spectrum compactness in space division multiplexing enabled elastic optical networks with multicore fiber. *IEEE Access*, v. 6, p. 15346–15355, 2018. Citado 3 vezes nas páginas 20, 21 e 32.