



**INSTITUTO
FEDERAL**
Ceará

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO CEARÁ
IFCE CAMPUS FORTALEZA
PROGRAMA PÓS-GRADUAÇÃO EM ENGENHARIA DE
TELECOMUNICAÇÕES**

VANESSA BARBOSA DINIZ

**MODELAGEM DE REDES ÓPTICAS COM COMPENSAÇÕES DE PERDAS E
DISPERSÃO UTILIZANDO APRENDIZADO DE MÁQUINA**

**FORTALEZA
2023**

VANESSA BARBOSA DINIZ

MODELAGEM DE REDES ÓPTICAS COM COMPENSAÇÕES DE PERDAS E
DISPERSÃO UTILIZANDO APRENDIZADO DE MÁQUINA

Dissertação apresentada à Coordenação de Pós-Graduação em Engenharia de Telecomunicações do Instituto Federal do Ceará (IFCE) - Campus Fortaleza, como requisito parcial para obtenção do grau de Mestre em Engenharia de Telecomunicações. Área de concentração: Micro-Ondas e Óptica Integrada.

Orientador: Prof. Dr. Glendo de Freitas Guimarães

Coorientador: Dr. Yosdan Martínez Camejo

FORTALEZA

2023

Dados Internacionais de Catalogação na Publicação

Instituto Federal do Ceará - IFCE

Sistema de Bibliotecas - SIBI

Ficha catalográfica elaborada pelo SIBI/IFCE, com os dados fornecidos pelo(a) autor(a)

D585m Diniz, Vanessa Barbosa Diniz.

 MODELAGEM DE REDES ÓPTICAS COM COMPENSAÇÕES DE PERDAS E
 DISPERSÃO UTILIZANDO APRENDIZADO DE MÁQUINA / Vanessa Barbosa Diniz Diniz. -
 2024.

 84 f. : il. color.

 Dissertação (Mestrado) - Instituto Federal do Ceará, Mestrado em Engenharia de
 Telecomunicações, Campus Fortaleza, 2024.

 Orientação: Prof. Dr. Glendo de Freitas Guimarães.

 Coorientação: Prof. Dr. Yosdan Martínez Camejo.

 1. WDM. 2. OptiSystem. 3. Aprendizado de Máquina. I. Título.

CDD 621.382



INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO CEARÁ
Av. 13 de maio, 2081 , - Bairro Benfica - CEP 60040-531 - Fortaleza - CE - www.ifce.edu.br

AVALIAÇÃO

Processo: 23256.014207/2023-60

Interessado: Vanessa Barbosa Diniz

VANESSA BARBOSA DINIZ

MODELAGEM DE REDES ÓPTICAS COM COMPENSAÇÕES DE PERDAS E DISPERSÃO UTILIZANDO APRENDIZADO DE MÁQUINA

Dissertação apresentada ao curso de Pós-Graduação em Engenharia de Telecomunicações do Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE) - *Campus Fortaleza*, como requisito parcial para obtenção do Título de Mestre em Engenharia de Telecomunicações.

Área de concentração: Sistemas de Telecomunicações

Aprovado em: **06 / 10 / 2023**

BANCA EXAMINADORA

Prof. Dr. **Glendo de Freitas Guimarães** (orientador)
Instituto Federal de Educação, Ciência e Tecnologia do Ceará - IFCE

Prof. Dr. **Yosdan Martínez Camejo** (coorientador)
Instituto Federal de Educação, Ciência e Tecnologia do Ceará - IFCE

Prof. Dr. **Francisco Tadeu De Carvalho Belchior Magalhães**
Instituto Federal de Educação, Ciência e Tecnologia do Ceará - IFCE

Prof. Dr. **Mário Wedney de Lima Moreira**
Instituto Federal de Educação, Ciência e Tecnologia do Ceará - IFCE

Prof. Dr. **Cícero Saraiva Sobrinho**
Universidade da Integração Internacional da Lusofonia Afro-Brasileira - UNILAB



Documento assinado eletronicamente por **Cícero Saraiva Sobrinho, Usuário Externo**, em 06/10/2023, às 21:30, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Mário Wedney de Lima Moreira, Professor do Ensino Básico, Técnico e Tecnológico**, em 06/10/2023, às 22:19, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Yosdan Martínez Camejo, Usuário Externo**, em 06/10/2023, às 22:28, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Glendo de Freitas Guimaraes, Coordenador(a) do PPGET**, em 09/10/2023, às 14:26, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Francisco Tadeu de Carvalho Belchior Magalhaes, Professor do Ensino Básico, Técnico e Tecnológico**, em 10/10/2023, às 18:16, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade do documento pode ser conferida no site https://sei.ifce.edu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0 informando o código verificador **5409689** e o código CRC **A2B47736**.

Este trabalho é dedicado à minha
família e amigos.

AGRADECIMENTOS

Desejo expressar meus mais sinceros agradecimentos a todas as pessoas que, de alguma forma, tornaram possível a realização deste trabalho, especialmente:

Agradeço a Deus, por guiar meus passos, iluminar meu caminho e me dar força e sustentação durante essa jornada e aos meus pais, que me incentivaram na busca por melhorias e me encorajaram a priorizar os estudos.

Ao Instituto Federal do Ceará (IFCE), que proporcionou um ambiente propício para a troca de conhecimento e a construção do saber ao longo da minha trajetória acadêmica.

Ao meu orientador, Glendo de Freitas, que desde o início acreditou em mim e apoiou minha vontade de cursar o mestrado. Sua orientação, referência profissional e humana, bem como suas críticas construtivas, contribuíram para aprimorar a estrutura deste trabalho. Suas sugestões e questionamentos foram de grande valia.

Aos participantes da banca examinadora e a todos os professores que me receberam em suas salas de aula, compartilhando conhecimento e contribuindo para o meu desenvolvimento como profissional competente.

A todos os meus amigos, cujas colaborações foram inestimáveis. Especial agradecimento a Valeska Fernandes, Yosdan Martínez e Rogean Silva que me apoiaram durante todo o processo.

Sem o auxílio, incentivo e apoio de todas essas pessoas, este trabalho não teria sido possível. Minha gratidão a todos vocês.

“Você se torna o que você acredita”
(Oprah Winfrey)

RESUMO

O contínuo crescimento das redes de comunicações ópticas é impulsionado pelo avanço dos serviços de internet e pelo aumento substancial na geração de dados. Diante desse cenário, é fundamental que essas redes tenham a capacidade de gerenciar eficazmente os dados, a fim de otimizar seu desempenho e evitar a aplicação de margens excessivas que frequentemente levam à subutilização dos recursos da rede. Nesse contexto, a aplicação de algoritmos de aprendizado de máquina emerge como uma abordagem promissora, pois tem o potencial de compreender o comportamento do sistema e melhorar significativamente seu desempenho. Neste trabalho, uma simulação utilizando o software *OptiSystem* foi realizada para investigar uma rede óptica ponto a ponto. Durante essa simulação, foram testados diversos parâmetros de entrada a fim de analisar como estes afetam os parâmetros de saída e a qualidade global do sistema. Os parâmetros de entrada submetidos a variações incluíram a potência do sistema WDM (*Wavelength Division Multiplexing*), a potência de bombeamento do amplificador de fibra dopada com érbio (EDFA) e o comprimento da fibra compensadora de dispersão (DCF). As métricas de saída consideradas foram a potência total, o ganho total, o máximo Fator Q e o mínimo BER (*Bit Error Rate*). Após a coleta dos dados provenientes dessas simulações, algoritmos de aprendizado de máquina foram empregados para avaliar qual deles produziu o melhor desempenho na análise dos resultados. A avaliação da eficácia dos modelos de aprendizado de máquina treinados baseou-se no coeficiente de determinação (R^2) e nas métricas de erro MAE (*Mean Absolute Error*) e MSE (*Mean Squared Error*). Os resultados mostram que, dentre os modelos analisados, o *Histogram Gradient Boosting Regression* (HGBR) obteve a melhor estimativa para a maioria das saídas avaliadas. No entanto, é importante destacar que apenas o modelo *Gradient Boosting Regression* (GBR) demonstrou uma estimativa mais precisa para o mínimo BER, um indicador crucial de qualidade em sistemas de comunicação óptica. Esses resultados destacam como o uso de algoritmos de aprendizado desempenha um papel crucial na análise de redes ópticas, permitindo uma gestão mais eficiente, otimizando o desempenho e fornecendo previsões precisas para a melhora da capacidade de tomada de decisões além de uma abordagem proativa para a manutenção e otimização das redes ópticas complexas.

Palavras-chave: WDM. OptiSystem. Aprendizado de Máquina. Algoritmos de Regressão.

ABSTRACT

The continued growth of optical communications networks is driven by the advancement of internet services and the substantial increase in data generation. Given this scenario, it is essential that these networks have the ability to effectively manage data in order to optimize their performance and avoid applying excessive margins that often lead to underutilization of network resources. In this context, an application of machine learning algorithms emerges as a promising approach, as it has the potential to understand the system's behavior and significantly improve its performance. In this work, a simulation using OptiSystem software was carried out to investigate a point-to-point optical network. During this simulation, several input parameters were tested to analyze how they affect the output parameters and the overall quality of the system. The input options presented included the power of the WDM (Wavelength Division Multiplexing) system, the pumping power of the erbium-doped fiber amplifier (EDFA), and the length of the dispersion compensating fiber (DCF). The output measurements considered were total power, total gain, maximum Q Factor and minimum BER (Bit Error Rate). After collecting data from these simulations, machine learning algorithms were used to evaluate which one produced the best performance in analyzing the results. The evaluation of the effectiveness of the trained machine learning models was based on the coefficient of determination (R^2) and the error metrics MAE (Mean Absolute Error) and MSE (Mean Square Error). The results show that, among the models analyzed, the Histogram Gradient Boosting Regression (HGBR) obtained the best estimate for the majority of the outputs evaluated. However, it is important to highlight that only the Gradient Boosting Regression (GBR) model declared a more accurate estimate for the minimum BER, a crucial quality indicator in optical communication systems. These results highlight how the use of learning algorithms plays a crucial role in the analysis of optical networks, enabling more efficient management, optimizing performance and providing precise integration for improved decision-making capabilities in addition to a proactive approach to maintenance. and optimization of complex optical networks.

Keywords: WDM. OptiSystem. Machine Learning. Regression Algorithms.

LISTA DE FIGURAS

Figura 1 - Estrutura de uma fibra óptica	23
Figura 2 - Tipos de fibras	24
Figura 3 - Dispersão total D e as contribuições relativas da dispersão de material D_M e da dispersão de guia de onda D_W para uma fibra monomodo convencional	27
Figura 4 - Janelas de transmissão de baixa perda em fibras de sílica com detalhe de aplicação da técnica WDM nas regiões de comprimentos de onda próximas de 1.3 e 1.55 μ m	33
Figura 5 - Excitação de um elétron da banda de valência para a banda de condução	35
Figura 6 - Esquema de um multiplexador/demultiplexador	36
Figura 7 - Grades de difração para (a) multiplexação e (b) demultiplexação	37
Figura 8 - Espectro de absorção e ganho de um EDFA com núcleo dopado com germânia	39
Figura 9 - Taxa de erro de bit (BER) em função do Fator Q	41
Figura 10 - Padrão de olho (a) ideal e (b) degradado para pulsos no formato NRZ..	42
Figura 11 - Modelos de regressão utilizados no aprendizado de máquina	44
Figura 12 - Esquemático funcionamento do aprendizado de máquina.....	45
Figura 13 - Esquemático de predição de valores com novos dados	45
Figura 14 - Estrutura da árvore de decisão	46
Figura 15 - Esquemático da simulação da rede	50
Figura 16 - Rede óptica real simulada no <i>Optisystem</i>	50
Figura 17 - Gráfico das curvas para a saída ganho total correlacionando as entradas potência WDM e bombeamento dos amplificadores para o comprimento da DCF em 3, 5, 7 e 9 km	59
Figura 18 - Gráfico das curvas para a saída potência total correlacionando as entradas potência WDM e bombeamento dos amplificadores para o comprimento da DCF em 3, 5, 7 e 9 km	60
Figura 19 - Gráfico das curvas para a saída mínimo BER correlacionando as entradas potência WDM e bombeamento dos amplificadores para o comprimento da DCF em 3, 5, 7 e 9 km	61

Figura 20 - Gráfico das curvas para a saída máximo Fator Q correlacionando as entradas potência WDM e bombeamento dos amplificadores para o comprimento da DCF em 3, 5, 7 e 9 km.....	62
Figura 21 - Mapa de calor da correlação entre o ganho total e os dados de entrada para os coeficientes a) Pearson e b) Spearman	63
Figura 22 - Mapa de calor da correlação entre a potência total e os dados de entrada para os coeficientes a) Pearson e b) Spearman	64
Figura 23 - Mapa de calor da correlação entre o mínimo BER e os dados de entrada para os coeficientes a) Pearson e b) Spearman	64
Figura 24 - Mapa de calor da correlação entre o máximo fator Q e os dados de entrada para os coeficientes a) Pearson e b) Spearman	65
Figura 25 - Mapa de calor da correlação consolidada dos dados de entrada e saída para os coeficientes a) Pearson e b) Spearman.....	66
Figura 26 - Coeficiente de determinação R^2 para a saída ganho total	67
Figura 27 - Erro Médio Absoluto (MAE) para a saída ganho total	68
Figura 28 - Erro Quadrático Médio (MSE) para a saída ganho total	68
Figura 29 - Coeficiente de determinação R^2 para a saída potência total	69
Figura 30 - Erro Médio Absoluto (MAE) para a saída potência total	70
Figura 31 - Erro Quadrático Médio (MSE) para a saída potência total	70
Figura 32 - Coeficiente de determinação R^2 para a saída mínimo BER.....	72
Figura 33 - Coeficiente de determinação R^2 para a saída máximo fator Q.....	73
Figura 34 - Erro Médio Absoluto (MAE) para a saída máximo fator Q	74
Figura 35 - Erro Quadrático Médio (MSE) para a saída máximo fator Q.....	74
Figura 36 - Gráfico das curvas para a saída ganho total correlacionando as entradas potência WDM e bombeamento dos amplificadores para o comprimento da DCF em 3, 5, 7 e 9 km para os valores simulados e preditos.....	76
Figura 37 - Gráfico das curvas para a saída potência total correlacionando as entradas potência WDM e bombeamento dos amplificadores para o comprimento da DCF em 3, 5, 7 e 9 km para os valores simulados e preditos.....	77
Figura 38 - Gráfico das curvas para a saída mínimo BER correlacionando as entradas potência WDM e bombeamento dos amplificadores para o	

comprimento da DCF em 3, 5, 7 e 9 km para os valores simulados e
preditos.....79

Figura 39 - Gráfico das curvas para a saída máximo fator Q correlacionando as
entradas potência WDM e bombeamento dos amplificadores para o
comprimento da DCF em 3, 5, 7 e 9 km para os valores simulados e
preditos.....81

LISTA DE TABELAS

Tabela 1 - Parâmetros do transmissor WDM	51
Tabela 2 - Parâmetros da fibra SMF e DCF	52
Tabela 3 - Interpretação dos coeficientes de correlação Pearson e Spearman	54
Tabela 4 - Melhores parâmetros de saída simulados e a sua configuração	57
Tabela 5 - Configurações dos parâmetros de saída selecionados	58

LISTA DE ABREVIATURAS E SIGLAS

APD	do inglês, avalanche photo diode
ASE	do inglês, amplified spontaneous emission
BER	do inglês, bit error rate
DCF	do inglês, dispersion compensating fiber
DFA	do inglês, doped fiber amplifier
DTR	do inglês, decision tree regression
DWDM	do inglês, dense wavelength division multiplexing
EDFA	do inglês, erbium doped fiber amplifier
GBR	do inglês, gradient boosting regression
GVD	do inglês, group velocity dispersion
HGBR	do inglês, histogram gradient boosting regression
IA	do inglês, artificial intelligence
IOT	do inglês, internet of things
ISP	do inglês, internet service provider
Laser	do inglês, light amplification by stimulated emission of radiation
LED	do inglês, light emitting diode
MAE	do inglês, mean absolute error
ML	do inglês, machine learning
MSE	do inglês, mean squared error
OSNR	do inglês, optical signal to noise ratio
PMD	do inglês, polarization mode dispersion
QOT	do inglês, quality of transmission
RFR	do inglês, random forest regression
SMF	do inglês, single mode fiber
SOA	do inglês, semiconductor optical amplifier
WDM	do inglês, wavelength division multiplexing

LISTA DE SÍMBOLOS

α	Coeficiente de atenuação
ω	Frequência do sinal
n	Índice de refração do meio
D	Parâmetro de dispersão
c	Velocidade da luz no vácuo

SUMÁRIO

1. INTRODUÇÃO	18
1.1 OBJETIVOS	20
1.1.1 OBJETIVO GERAL.....	20
1.1.2 OBJETIVOS ESPECÍFICOS.....	21
1.2 ORGANIZAÇÃO DA DISSERTAÇÃO	21
2. FUNDAMENTAÇÃO TEÓRICA	23
2.1. FIBRA ÓPTICA	23
2.1.1. EFEITOS LINEARES.....	25
2.1.1.1. Dispersão em Fibras Monomodo.....	25
2.1.1.2. Técnicas de Compensação de Dispersão.....	29
2.1.1.3. Atenuação	30
2.1.2. EFEITOS NÃO LINEARES.....	32
2.2. REDE WDM.....	32
2.2.1. TRANSMISSOR ÓPTICO.....	34
2.2.1.1. Bandas de Energia.....	34
2.2.1.2. Multiplexador e Demultiplexador.....	35
2.2.2. AMPLIFICADORES ÓPTICOS	37
2.2.3. RECEPTOR ÓPTICO	39
2.3. MACHINE LEARNING.....	42
2.3.1. APRENDIZADO NÃO SUPERVISIONADO E SUPERVISIONADO	42
2.3.2. ALGORITMOS DE MACHINE LEARNING.....	45
2.3.2.1. Decision Tree Regression	45
2.3.2.2. Random Forest Regression.....	46
2.3.2.3. Gradient Boosting Regression.....	47
2.3.2.4. Histogram Gradient Boosting Regression.....	47
3. METODOLOGIA	49
3.1. SIMULAÇÃO E TOPOLOGIA DA REDE ÓPTICA	49
3.2. CONFIGURAÇÃO DOS PARÂMETROS.....	51
3.3. TREINAMENTO DOS DADOS	52
3.3.1. COEFICIENTES DE CORRELAÇÃO	52
3.3.1.1. Pearson.....	53
3.3.1.2. Spearman.....	53
3.3.2. MÉTRICAS DE AVALIAÇÃO DOS MODELOS	54
3.3.2.1. Coeficiente de determinação (R^2)	54
3.3.2.2. Erro Médio Absoluto (MAE)	55
3.3.2.3. Erro Quadrático Médio (MSE).....	56
4. RESULTADOS E DISCURSÕES	57
4.1. RESULTADOS OPTISYSTEM	57
4.1.1. GANHO TOTAL	58
4.1.2. POTÊNCIA TOTAL	59
4.1.3. MÍNIMO BER	60
4.1.4. MÁXIMO FATOR Q	61

4.2. ANÁLISE DE CORRELAÇÃO	62
4.2.1. GANHO TOTAL	62
4.2.2. POTÊNCIA TOTAL	63
4.2.3. MÍNIMO BER	64
4.2.4. MÁXIMO FATOR Q	65
4.3. AVALIAÇÃO DO TREINAMENTO DOS MODELOS	66
4.3.1. GANHO TOTAL	66
4.3.2. POTÊNCIA TOTAL	69
4.3.3. MÍNIMO BER	71
4.3.4. MÁXIMO FATOR Q	72
4.4. CONFRONTAÇÃO: SIMULADO x PREDITO	75
4.4.1. GANHO TOTAL	75
4.4.2. POTÊNCIA TOTAL	77
4.4.3. MÍNIMO BER	78
4.4.4. MÁXIMO FATOR Q	81
 5. CONCLUSÕES	 83
 REFERÊNCIAS	 85

1. INTRODUÇÃO

Com o avanço dos serviços de internet, a tecnologia 5G e a Internet das Coisas (IoT), testemunha-se uma explosão sem precedentes na demanda por tráfego de dados. Essa avalanche de dados é alimentada por diversas fontes, incluindo transmissões de vídeo em alta definição, a proliferação de dispositivos conectados à Internet e a crescente dependência de aplicativos em nuvem. No Brasil, o IX.br, sistemas de ponto de troca de tráfego ligado ao Comitê Gestor da Internet, em 2023, atingiu 31 Tbit/s de dados, um salto de 25% em relação ao mesmo período do ano anterior (NIC.BR, 2023).

Para atender a essa voracidade por transmissão de dados, a infraestrutura de comunicações precisa estar à altura do desafio. Neste contexto, as comunicações ópticas emergem como uma solução crucial, oferecendo uma capacidade incomparável para transmitir grandes volumes de dados a longas distâncias. Ao utilizar pulsos de luz para transmitir informações, elas proporcionam larguras de banda significativamente superiores às tecnologias tradicionais de transmissão.

Para garantir o funcionamento contínuo e confiável das redes ópticas, é imperativo contar com uma infraestrutura robusta. Isso envolve a implementação de componentes de alta qualidade, manutenção preventiva e redundâncias estratégicas. No entanto, o aumento exponencial do tráfego de dados também apresenta desafios substanciais na gestão e otimização das redes ópticas. Estudar fibras por modelos analíticos são difíceis, computacionalmente pesados e introduzem altas margens que levam à subutilização dos recursos da rede.

Neste cenário, o aprendizado de máquina (ML – *Machine Learning*), um ramo da Inteligência Artificial (IA), é altamente adequado para lidar com problemas complexos em curto intervalo de tempo, sendo uma área promissora a ser estudada em redes de comunicações ópticas. Ao processar extensos volumes de dados em tempo real, o aprendizado de máquina tem a habilidade de aprender e ajustar-se de acordo com o comportamento do sistema. Por exemplo, podem ser aprimoradas rotas de transmissão, detecção de padrões de tráfego e antecipação de necessidades de manutenção, contribuindo para a confiabilidade e disponibilidade da infraestrutura.

A capacidade das linhas de transmissão de fibra melhorou consideravelmente nas últimas décadas. Como os dados são transmitidos majoritariamente por redes ópticas, os estudos devem aprimorar a adequação da rede minimizando qualquer interrupção do serviço que leva a prejuízos ao consumidor. A introdução da aprendizagem de máquina traz uma alternativa promissora, visto que a inteligência artificial pode ser adaptada ao sistema dinâmico, além de ser ideal para projetos complicados fornecendo novas maneiras de solucionar esses problemas. A inteligência artificial possui maior precisão ou melhor confiabilidade do que modelos analíticos em diversos cenários. O trabalho publicado em 2022 pelos autores R. Saloni e A. Garg (2022) revisou várias aplicações baseadas em redes ópticas com técnicas de ML, destacando-se o uso da tecnologia da multiplexação por divisão de comprimento de onda (WDM - *Wavelength Division Multiplexing*), que fornece grande largura de banda utilizando a transmissão por fibra óptica.

O rápido crescimento das necessidades de demandas de tráfego faz com que as operadoras de serviços tenham metas mais desafiadoras e analisem soluções para melhorar a capacidade de transmissão óptica e suas velocidades, portanto o objetivo dos sistemas de comunicação é aumentar a distância de transmissão por fibra óptica e manter o acordo de nível de serviço entre o usuário e o provedor, que envolve manter a qualidade de transmissão (QoT - *Quality of Transmission*). No trabalho desenvolvido pelos autores H. Bo-ning et al. (2010), foram estudados a dispersão da fibra óptica e seu efeito no sistema de transmissão óptica onde a tecnologia de fibra compensadora de dispersão (DCF) foi utilizada, propondo três esquemas de compensação (pré-compensação, pós-compensação e compensação mista) de dispersão através de simulações em rede WDM baseado no *Optisystem* tendo como parâmetros de análise de qualidade o fator de qualidade (Fator Q) e a taxa de erro de bit (BER – *bit error rate*).

S. Gaurav e K. Rupinderjit. (2014) apresentaram dados extraídos por simulação utilizando o *software Optisystem*, que é o mesmo simulador óptico utilizado neste trabalho. No estudo, foi analisado o desempenho do sistema de multiplexação por divisão de comprimento de onda (WDM) usando fibra compensadora de dispersão (DCF) para compensar a dispersão no *link* WDM, reduzindo desta forma a dispersão e aumentando a distância de transmissão, comparando o desempenho do *link* com diferentes comprimentos de onda, 980 nm, 1.300 nm e 1.550 nm.

R. Rudra et al. (2015) desenvolveu um trabalho com dados coletados por simulação utilizando o *software Optisystem* em que foram analisados alguns parâmetros de entrada, tais como, frequência, espaçamento de frequências, taxa de bits e comprimento da fibra do sistema de multiplexação de comprimento de onda denso (DWDM – *Dense Wavelength Division Multiplexing*), para prever os parâmetros de saída, como fator de qualidade (Fator Q), taxa de erro de bit (BER – *bit error rate*), altura e valor limite, utilizando algoritmos como modelo de regressão multivariável e redes neurais de aprendizado de máquina que foram implementados usando Linguagem R e *Matlab*, com o objetivo de calcular a qualidade do sinal transmitido pela fibra óptica através do canal analisado.

Sharifani e Amini (2023) trazem em seu trabalho uma visão atual e abrangente dos fundamentos do aprendizado de máquina e do *deep learning*, o impacto que os estudos tiveram na sociedade, além do potencial implicações para o futuro. Destaque de implicações positivas na área médica é feito por Haug e Drazen (2023), que destacam a melhora da qualidade dos cuidados oferecidos pelos profissionais de saúde. Bharadiya (2023) também evidencia a importância do aprendizado de máquina na área de *Business Intelligence*, ou Inteligência de Negócios, para fornecer insights significativos e informações acionáveis que podem impulsionar a tomada de decisões estratégicas dentro de uma organização. L. Zhang et al. (2022) ressalta a importância para utilização em redes ópticas na previsão de qualidade de transmissão (QoT).

Assim, explorar o aprimoramento das redes de comunicações ópticas e as aplicações do aprendizado de máquina para solução de problemas detém um grande potencial e estimulará a ampliação do conhecimento na área. Portanto, este trabalho irá analisar o uso de aprendizado de máquina para treinar bases de dados usando os algoritmos de regressão com eficiência comprovada.

1.1 OBJETIVOS

1.1.1 Objetivo Geral

O objetivo desta dissertação de mestrado é analisar o uso de técnicas de inteligência artificial para modelagem de redes de comunicações ópticas considerando perdas e dispersão.

1.1.2 Objetivos Específicos

- Simular uma rede óptica utilizando o *software OptiSystem* e avaliar os parâmetros de entrada, potência do WDM, potência do bombeamento do amplificador de fibra dopada por érbio (EDFA) e comprimento da fibra compensadora de dispersão, correlacionando estes, com os parâmetros de QoT;
- Avaliar modelos de aprendizagem de máquina para correlacionar os parâmetros de entrada, potência do WDM, potência do bombeamento do amplificador de fibra dopada por érbio (EDFA) e comprimento da fibra compensadora de dispersão, aos parâmetros de saída, potência total, ganho total, máximo Fator Q e mínimo BER;
- Analisar o modelo de regressão que obteve melhor desempenho para cada alvo de QoT: potência total, ganho total, máximo Fator Q e mínimo BER;
- Avaliar se com o acréscimo de parâmetros de dispersão, os modelos de aprendizagem de máquina terão eficiência para todos os parâmetros de saída.

1.2 ORGANIZAÇÃO DA DISSERTAÇÃO

Esta dissertação será estruturada em 5 capítulos na seguinte sequência: Introdução, Fundamentação Teórica, Metodologia, Resultados e Conclusões. O Capítulo 2 trata do embasamento teórico acerca das fibras ópticas, descrevendo a dispersão em fibras monomodo, atenuação e técnicas de compensação. Também será apresentada a base conceitual da técnica WDM e o detalhamento de seus principais componentes que foram desenvolvidos para implementar essa nova tecnologia, os principais parâmetros utilizados para a análise de QoT em redes ópticas, além de conceitos referente à inteligência artificial.

Em seguida, no Capítulo 3, é apresentada a metodologia. Será realizada uma descrição detalhada sobre a metodologia utilizada durante a obtenção dos dados

simulados no *software OptiSystem* e algumas explicações sobre os diferentes algoritmos que foram usados para o aprendizado de máquina.

No Capítulo 4, serão exibidos os resultados obtidos por meio de gráficos e tabelas, que representam as coletas de dados simulados no *OptiSystem*. Esses dados serão utilizados posteriormente no treinamento de modelos de aprendizado de máquina e sua avaliação.

No Capítulo 5, serão apresentadas as considerações finais e uma conclusão abrangente, destacando as principais contribuições resultantes deste estudo de mestrado. Além disso, serão oferecidas sugestões para pesquisas futuras.

2. FUNDAMENTAÇÃO TEÓRICA


Neste capítulo será abordado o embasamento teórico acerca das fibras ópticas, descrevendo a dispersão em fibras monomodo, atenuação e técnicas de compensação. Também será apresentada a base conceitual de uma rede WDM e o detalhamento dos principais componentes que compõem o sistema. Conceitos importantes para a análise de desempenho em redes ópticas também foram apresentados, além dos conceitos referentes ao *Machine Learning*.

2.1. FIBRA ÓPTICA

De modo geral, as fibras ópticas são condutores de luz dielétricos confeccionados a partir de materiais especiais como vidro ou plástico, que realizam o guiamento da luz utilizando o princípio da reflexão interna total, no qual a luz é refletida de maneira contínua ao longo da extensão da fibra.

Elas são comumente fabricadas a partir de sílica altamente pura (SiO_2) e são caracterizadas por possuírem um revestimento externo (ou casca) que envolve o núcleo e que possui um índice de refração menor que o do núcleo, permitindo, assim, o confinamento da luz no guia de onda por meio de um fenômeno da reflexão interna total (KAISER, 2014), como pode ser observado na Figura 1.

Figura 1 - Estrutura de uma fibra óptica.



Fonte: Autora


Para se estudar a reflexão interna total, considera-se inicialmente a lei de Snell que caracteriza o comportamento dos raios luminosos quando eles atravessam a superfície que separa dois meios (HALLIDAY, 2009). Desta forma, como há uma

diferença entre os índices de refração do núcleo da fibra e da casca, a reflexão do raio se dará de forma com que fique confinado no interior do núcleo da fibra ao longo de todo o comprimento desta.

As fibras ópticas podem ser classificadas com base na quantidade de modos de propagação que elas suportam. A relação entre o número de modos da fibra está intimamente relacionada ao tamanho do núcleo e varia inversamente com o comprimento de onda empregado. Quando uma fibra suporta diversos modos é chamada de multimodo. caracterizada por um núcleo de maior diâmetro, geralmente em torno de 50 ou 62,5 μm . Isso viabiliza a transmissão de luz em comprimentos de onda de 850 nm ou 1300 nm, com a luz percorrendo o núcleo em trajetórias em zigue-zague. Redes de área local de curto alcance utilizam este tipo de fibra.

Quando a fibra suporta apenas o modo fundamental é chamada de monomodo. O diâmetro do núcleo das fibras monomodo é pequeno, em torno de 9 μm , e com estreita diferença do índice entre o núcleo e a casca e suportam apenas um modo de propagação, também conhecido como modo fundamental da fibra, com a transmissão dos comprimentos de onda entre 1310 nm a 1650 nm (AGRAWAL, 2010). Neste tipo de fibra, a luz percorre o núcleo em uma trajetória linear, resultando em menor atenuação e, por conseguinte, menor perda de sinal (Figura 2). Atualmente, essas são as fibras mais prevalentes em redes externas de longo alcance, sendo estas tomadas como cerne deste trabalho.

Figura 2 - Tipos de fibras.



Fonte: Autora

Durante a transmissão de dados por meio de fibras ópticas, ocorrem fenômenos intrínsecos à propagação que limitam a taxa de transmissão, estes fenômenos podem ser lineares e não lineares.

2.1.1. Efeitos lineares

Efeitos comumente conhecidos em projetos de redes ópticas são dispersões e atenuações. Os efeitos da dispersão do sinal também são extremamente relevantes, pois podem causar o alargamento dos pulsos ópticos, resultando na sobreposição entre eles e levando a erros na saída do receptor (KAISER, 2014).

Já a atenuação é uma propriedade fundamental das fibras ópticas, uma vez que influencia no projeto da rede, determinando a distância máxima entre transmissores e receptores sem a necessidade de amplificação ou repetição do sinal. Neste trabalho, a rede simulada utiliza fibra monomodo, em virtude das características da rede proposta. Desta forma, serão detalhados com mais riqueza de detalhes os efeitos lineares inerentes a mesma.

2.1.1.1. Dispersão em Fibras Monomodo

A dispersão cromática ou, como também é conhecida, dispersão de velocidade de grupo (GVD – *Group Velocity Dispersion*), manifesta-se em decorrência dos diferentes componentes espectrais do pulso viajarem com velocidades de grupo ligeiramente diferentes. Ela possui duas contribuições: a dispersão material e a dispersão de guia da onda.

Sendo considerada uma fibra monomodo de comprimento L , o tempo T de propagação de um pulso pode ser obtido através de

$$T = \frac{L}{v_g} \quad (2.1)$$

em que v_g é a *velocidade de grupo* dada por

$$v_g = \left(\frac{d\beta}{d\omega} \right)^{-1} \quad (2.2)$$

Percebe-se assim que o tempo varia de acordo com a frequência angular, ou seja, cada modo particular da fibra leva um tempo diferente para percorrê-la. Em certos sistemas de comunicação óptica, o espalhamento de frequência $\Delta\omega$ é determinado pela faixa de comprimentos de onda $\Delta\lambda$ emitidos pela fonte de luz. É comum substituir $\Delta\omega$ por $\Delta\lambda$. Usando $\omega = \frac{2\pi c}{\lambda}$, $\Delta\omega = \left(-\frac{2\pi c}{\lambda^2}\right)\Delta\lambda$ e sabendo que c é a velocidade da luz no vácuo, tem-se

$$\Delta T = \frac{dT}{d\omega} \Delta\omega = \left[\frac{d}{d\omega} \left(\frac{L}{v_g} \right) \right] \left[\left(-\frac{2\pi c}{\lambda^2} \right) \Delta\lambda \right] = L \left(\frac{d^2\beta}{d\omega^2} \right) \left(-\frac{2\pi c}{\lambda^2} \right) \Delta\lambda \quad (2.3)$$

Conhecido como parâmetro GVD, o fator $\beta_2 = \frac{d^2\beta}{d\omega^2}$ determina o quanto um pulso óptico será alargado temporalmente após a propagação pela fibra óptica (AGRAWAL, 2010). Procedendo com as relações, pode-se alcançar a seguinte expressão do atraso de grupo:

$$\Delta T = L\beta_2 \left(\frac{-2\pi c}{\lambda^2} \right) \Delta\lambda \quad (2.4)$$

Onde é então determinado que o parâmetro de dispersão, D , é (AGRAWAL, 2010):

$$D = \beta_2 \left(\frac{-2\pi c}{\lambda^2} \right) \quad (2.5)$$

Também conhecido como dispersão cromática, este coeficiente elucida como o pulso se espalha em função do comprimento de onda e é medido em picossegundos por nanômetro por quilômetro [ps/(nm · km)]. Esse valor pode ser escrito como a soma das duas contribuições mencionadas

$$D = D_M + D_W \quad (2.6)$$

sendo a dispersão de material (D_M) e a dispersão de guia da onda (D_W) dadas por (AGRAWAL, 2010).


$$D_M = -\frac{2\pi}{\lambda^2} \frac{dn_{2g}}{d\omega} = \frac{1}{c} \frac{dn_{2g}}{d\lambda}, \quad (2.7)$$

$$D_W = -\frac{2\pi\Delta}{\lambda^2} \left[\frac{n_{2g}^2}{n_2\omega} \frac{Vd^2(V_b)}{dV^2} + \frac{dn_{2g}}{d\omega} \frac{[d(V)]_b}{dV} \right] \quad (2.8)$$

Aqui, n_{2g} é o índice de grupo do material da casca, e os parâmetros V e b descritos pelas Equações 2.10 e 2.11, respectivamente. Assim, a dispersão de material se dá em virtude de o índice de refração alterar com o comprimento da onda óptica, e a dispersão ao passo que a dispersão de guia de onda é determinada por características como o raio do núcleo e da diferença de índices.

A Figura 3 apresenta a dispersão do material, a dispersão de guia de onda e a combinação dessas duas para uma fibra monomodo comum. O comprimento de onda em que ocorre $\frac{dn_{2g}}{d\omega} = 0$ e, portanto, $D_M = 0$, é conhecido como comprimento de dispersão zero (λ_{ZD}). Esse valor é um ponto de referência para os valores de D_M , que serão positivos para comprimentos de onda maiores e negativos para comprimentos de onda menores que λ_{ZD} .

Figura 3 - Dispersão total D e as contribuições relativas da dispersão de material D_M e da dispersão de guia de onda D_W para uma fibra monomodo convencional.



Fonte: AGRAWAL (2010)

O efeito da dispersão de guia de onda desempenha um papel crucial na criação de duas importantes categorias de fibras ópticas: as fibras de dispersão

decrecente e as fibras compensadoras de dispersão (AGRAWAL, 2010). Nas fibras de dispersão decrecente, a dispersão de grupo variável diminui ao longo do comprimento da fibra devido a variações no raio do núcleo ao longo do eixo da fibra. Por outro lado, nas fibras compensadoras de dispersão, a GVD é normal e possui um valor relativamente alto.

Outra fonte de alargamento dos pulsos são os efeitos da birrefringência da fibra nos estados de polarização de um sinal óptico. Esse efeito é crucial para sistemas de longa distância com altas taxas de transmissão. Esse fenômeno é conhecido como dispersão do modo de polarização, ou PMD - *Polarization Mode Dispersion*.

A birrefringência pode ser resultado de fatores intrínsecos, como pequenos desvios geométricos do núcleo da fibra, além de externos, tais como flexão, torção e compressão da fibra. Estes fatores são variáveis ao longo da fibra, fazendo com que cada modo de polarização viaje a uma velocidade ligeiramente diferente, resultando em um alargamento do pulso. Considerando que as velocidades de grupo de dois modos de polarização ortogonais são v_{gx} e v_{gy} , logo o atraso de tempo diferencial, ΔT , entre dois componentes de polarização durante a propagação do pulso através de uma distância L é descrito pela Equação 2.9

$$\Delta T = \left| \frac{L}{v_{gx}} - \frac{L}{v_{gy}} \right| \quad (2.9)$$

Na realidade, a influência da PMD é estocástica ao longo da trajetória, e, por isso, é necessário recorrer a estimativas estatísticas para compreender seus efeitos. Portanto, uma maneira proveitosa de descrever a PMD é em termos do atraso de grupo diferencial médio, conforme expresso na seguinte relação:

$$\Delta T = D_p \sqrt{L} \quad (2.10)$$

em que D_p é o parâmetro de PMD, medido em ps/km^{1/2}. Os valores típicos de D_p variam de fibra para fibra, no intervalo de 0,010 a 10 ps/km^{1/2}. Por causa da sua dependência em relação a $\sqrt{L}$, o alargamento provocado pela PMD é comparativamente menor em relação ao causado por GVD. No entanto, a PMD se torna um fator restritivo em projetos de sistemas ópticos que operam em longas

distâncias e com taxas de bits elevadas, excedendo os 10 Gbps (KAISER, 2014) (AGRAWAL, 2010).

2.1.1.2. Técnicas de Compensação de Dispersão

Na prática, existem várias técnicas disponíveis para gerenciar a dispersão em sistemas de transmissão de ondas luminosas. Uma solução comumente utilizada no domínio óptico, quando os efeitos não lineares são insignificantes, é o uso de uma fibra especial chamada de fibra compensadora de dispersão (DCF - *Dispersion-Compensating Fiber*).

Esse tipo de fibra possui uma característica de dispersão oposta à da fibra de transmissão. Um trecho de comprimento de DCF é inserido no link e, após uma determinada distância, compensa totalmente a dispersão acumulada, resultando em uma dispersão total zero (KAISER, 2014).

A DCF é projetada de modo a apresentar dispersão negativa em 1550 nm, com um diâmetro de núcleo menor que uma fibra monomodo convencional, de tal sorte que suporta um único modo fracamente confinado. O conhecimento do total necessário da DCF, L_{DCF} , pode ser obtido pela relação

$$L_{DCF} = \left| \frac{D_{TX}}{D_{DCF}} \right| * L_{TX} \quad (2.11)$$

onde o comprimento total do enlace é L_{TX} , e as dispersões da fibra convencional e a de dispersão são, respectivamente, D_{TX} e D_{DCF} .

Fatores limitantes como a perda por inserção e o aumento dos efeitos não lineares são apresentados pelas DCFs. Assim, um outro modo utilizado baseia-se no emprego de grades de dispersão de Bragg baseadas em fibra para a compensação da dispersão.

A grade de dispersão de Bragg atua como um filtro óptico devido ao índice de refração do núcleo sofrer uma variação periódica ao longo do comprimento. Essas grades possuem a capacidade de difratar diferentes comprimentos de onda de luz em diferentes ângulos, o que pode ser usado para compensar os efeitos da dispersão cromática em sistemas de comunicação óptica de alta velocidade.

Na configuração, ao longo do comprimento da grade, o comprimento de onda de Bragg se reduz. Isso significa que os componentes de comprimentos de onda mais curtos de um pulso viajam mais para dentro na fibra antes de serem refletidos. Consequentemente, eles experimentam um maior retardo ao passar pela grade do que os componentes de comprimentos de onda mais longos. Os atrasos proporcionados pela grade em diferentes componentes de frequência do pulso são opostos aos atrasos causados pela própria fibra, ou seja, os comprimentos de onda que chegam primeiro na rede de Bragg serão os últimos a serem refletidos, dessa forma compensando a dispersão (KAISER, 2014).

2.1.1.3. Atenuação

Em projetos de um sistema de comunicações ópticas, a atenuação é um importante parâmetro a ser considerado na análise de QoT da rede.

Utilizando a potência óptica média P , o coeficiente de atenuação pode ser obtido pela lei de Beer

$$\frac{dP}{dz} = -\alpha P \quad (2.12)$$

Se P_{in} for a potência lançada na entrada de uma fibra de comprimento L , a potência de saída P_{out} é obtida como

$$P_{out} = P_{in} \exp(-\alpha L) \quad (2.13)$$

Para a análise em grandes redes de comunicações ópticas, comumente o coeficiente de atenuação é expresso em unidades de decibéis por quilômetro, denotada por dB/Km, onde tem-se

$$\alpha \left(\frac{\text{dB}}{\text{km}} \right) = -\frac{10}{L} \log_{10} \left(\frac{P_{out}}{P_{in}} \right) \cong 4.343 \alpha \text{ (km}^{-1}\text{)} \quad (2.14)$$

Diversos fatores contribuem para atenuação da fibra óptica, sendo as duas principais delas a absorção material e o espalhamento Rayleigh. A absorção material pode ser dividida em duas categorias: Intrínseca e extrínseca. Perdas por absorção

intrínseca correspondem à absorção pela sílica fundida, enquanto a absorção extrínseca está relacionada às perdas causadas por impurezas na sílica

A absorção de material ocorre devido à capacidade da sílica (SiO_2) de absorver moléculas, principalmente nas regiões ultravioleta ($\lambda < 0,4 \mu\text{m}$) e infravermelha ($\lambda < 0,7 \mu\text{m}$). Além disso, a presença de impurezas provenientes do processo de fabricação da fibra óptica também pode ser uma fonte de absorção. Portanto, a quantidade de impurezas, como os metais de transição (Fe, Co, Cr e Cu), precisa ser reduzida a níveis inferiores a uma parte por bilhão para garantir uma perda de sinal abaixo de 1 dB/km, o que resulta em sílica de alta pureza.

A maior causa da atenuação é o espalhamento. Flutuações de densidade levam a flutuações aleatórias no índice de refração, em uma escala menor do que o comprimento de onda λ , a seção reta de espalhamento varia com λ^{-4} . Ou seja, O espalhamento Rayleigh também é uma função do comprimento de onda, inversamente proporcional ao comprimento de onda da luz elevada à quarta potência.

O nível de atenuação é crucial para o projeto do sistema de comunicações ópticas. É necessária a determinação de características como a distância de transmissão máxima e a quantidade de amplificadores ópticos, visto que os receptores requerem certa quantidade mínima de potência para a recuperação do sinal ao final do caminho percorrido (AGRAWAL, 2010).

Assim, para realizar a compensação da atenuação em fibras ópticas são utilizadas técnicas e dispositivos para mitigar a perda de sinal que ocorre ao longo do percurso da transmissão óptica. Existem várias maneiras de compensar a atenuação em sistemas de comunicação óptica. Na prática, comumente são utilizados dispositivos de amplificação óptica para compensar as limitações impostas pelas atenuações. Amplificadores de fibra dopada com érbio (EDFA) e os amplificadores Raman são tipo de dispositivos utilizados para aumentar a intensidade do sinal óptico ao longo da transmissão, compensando a atenuação. Serão explanados em um tópico específico adiante o funcionamento destes dispositivos.

2.1.2. Efeitos não lineares

Ao conceber um projeto para sistemas de comunicações ópticas, pode parecer inicialmente razoável supor que simplesmente aumentar a potência resolverá as limitações causadas pela degradação dos sinais ópticos, levando ao alcance do objetivo do projeto do link. Entretanto, à medida que o nível de potência do sinal é elevado, uma série de efeitos não lineares passam a se manifestar.

Essas não linearidades ocorrem quando múltiplos campos ópticos de alta intensidade, com diferentes comprimentos de onda, coexistem em uma fibra simultaneamente e quando esses campos interagem com as ondas sonoras e vibrações moleculares (KAISER, 2014). Entre importantes processos não lineares que afetam fisicamente o desempenho de um sistema, têm-se os gerados pelo espalhamento inelástico linear, o espalhamento Raman estimulado e o espalhamento Brillouin estimulado, além dos efeitos decorrentes das variações que dependem da intensidade do índice de refração, que incluem a Automodulação de Fase, a modulação de Fase Cruzada e o efeito da Mistura de Quatro Ondas.

2.2. REDE WDM

Foi possível obter um progresso significativo na transmissão por fibras ópticas ao utilizar uma técnica chamada multiplexação por divisão de comprimento de onda (WDM). Com essa técnica, diversas fontes de luz operam em comprimentos de onda ligeiramente diferentes, permitindo a transmissão simultânea de vários fluxos de informação independentes pela mesma fibra.


A utilização das técnicas WDM teve um crescimento significativo nos primeiros anos da década de 1990, embora os estudos sobre essas técnicas remontem ao meio da década de 1970. Somente com o surgimento de novos tipos de fibras e dispositivos WDM, foi possível obter um desempenho aprimorado nas operações com múltiplos comprimentos de onda, especialmente na faixa de 1.500 nm, devido à capacidade de separar comprimentos de onda muito próximos (KAISER, 2014).

A diretriz ITU-T G.692 define os intervalos de frequência para os canais de Multiplexação por Divisão de Comprimento de Onda (WDM). A seleção da

frequência como um parâmetro para WDM é fundamentada no funcionamento dos lasers, nos quais a frequência de emissão desempenha um papel crucial. Inicialmente, a separação entre as frequências dos canais WDM era de 100 GHz, começando a partir de 193,100 THz. Isso resultou em uma largura de aproximadamente 0,8 nm para cada sinal independente. Essa convenção foi adotada para configurar os equipamentos de Multiplexação (MUX) e Demultiplexação (DEMUX).

No entanto, a mesma norma também especifica espaçamentos de 50 GHz e 200 GHz. Na Figura 4 é ilustrada a aplicação dessa técnica no espectro de comprimento de onda. Atualmente, a recomendação G.694.1 define a multiplexação por divisão densa de comprimento de onda (DWDM - *Dense Wavelength Division Multiplexing*) com espaçamentos que variam de 12,5 GHz a 100 GHz.

Figura 4 - Janelas de transmissão de baixa perda em fibras de sílica com detalhe de aplicação da técnica WDM nas regiões de comprimentos de onda próximas de 1,3 e 1,55 μm .



Fonte: AGRAWAL (2010)

Para a compreensão da rede, é possível examinar os componentes que constituem um sistema WDM. O primeiro componente é o transmissor óptico, responsável por converter os sinais binários emitidos pela fonte em sinais luminosos. Todos os sinais gerados em diferentes comprimentos de onda são combinados no multiplexador para formar um único sinal que é finalmente emitido.

Os amplificadores são elementos que aumentam a potência do sinal em várias etapas do percurso, a fim de compensar a atenuação causada pelo meio. O demultiplexador opera de maneira oposta ao multiplexador, separando cada sinal em diferentes portas de acordo com o seu comprimento de onda. Por fim, o receptor óptico realiza a detecção do sinal e gera uma saída elétrica. Conforme sua aplicação no trabalho, a seguir serão detalhados os componentes de uma rede WDM.

2.2.1. Transmissor Óptico

As fontes de luz que são amplamente utilizadas na comunicação por fibras ópticas são os diodos emissores de luz (LED – *Light-Emitting Diode*) e lasers de semicondutores de injeção ou DL.

A emissão da luz pode ocorrer por dois processos chamados de emissão espontânea e estimulada, onde um átomo em um estado excitado retorna ao estado natural. No caso de emissão espontânea, esse terá mesmo comprimento de onda, entretanto não terá a mesma frequência, fase, polarização e irá gerar ruído no sinal de saída. Em contraponto, emissão estimulada é iniciada por um fóton existente chamado de fóton estimulante que ocasionará um fóton gêmeo, não apenas com as mesmas características, mas também como a mesma direção de propagação (AGRAWAL, 2010).

A principal diferença entre as fontes de luz reside no fato de que a saída de um LED é incoerente, enquanto a do laser é coerente. Isso significa que para os lasers a energia óptica é altamente monocromática e o seu feixe é muito direcional. Em geral, ele pode ser utilizado tanto em fibras monomodo como multimodo, enquanto os LEDs são comumente utilizados em fibras multimodo, pois somente nessas fibras a potência pode ser acoplada de forma funcional.


1.1.1.1 Bandas de Energia

Em um laser de semicondutor, ocorre a formação de bandas de energia resultantes da combinação dos níveis de energia individuais dos átomos. Essas bandas são conhecidas como banda de valência e banda de condução, representando a banda mais alta preenchida por elétrons e a primeira banda com poucos elétrons, respectivamente (Figura 5). Essas bandas estão separadas por

um intervalo de energia, ou *bandgap*, em que não existem níveis de energia permitidos.

Quando alguns elétrons são excitados para a banda de condução através de bombeamento elétrico, os espaços vazios deixados na banda de valência são chamados de lacunas ou buracos. A condutividade elétrica é formada quando um elétron na banda de valência move-se para dentro de uma vaga do buraco, fazendo com que o movimento destes ocorra no sentido oposto ao fluxo dos elétrons (KAISER, 2014).

Figura 5 - Excitação de um elétron da banda de valência para a banda de condução.



Fonte: Modificada de KAISER (2014)


1.1.1.2 Multiplexador e Demultiplexador

Multiplexadores e demultiplexadores são elementos essenciais em sistemas de comunicação óptica DWDM uma vez que permitem o transporte de várias portadoras (canais) em uma única fibra óptica (Figura 6). O multiplexador tem a função de combinar todos os sinais de diferentes comprimentos de onda, que serão transmitidos pela mesma fibra óptica, em um único feixe. Já o demultiplexador realiza o processo inverso, ou seja, separa o feixe recebido em suas diversas componentes de comprimento de onda.

Um mesmo dispositivo pode ser utilizado como multiplexador e demultiplexador, já que a estrutura é basicamente a mesma, dependendo apenas do sentido de propagação em que é empregado. A seleção ou combinação dos canais é principalmente realizada por meio de filtros ópticos (AGRAWAL, 2010).


Multiplexadores e demultiplexadores baseados em grades de difração utilizam o fenômeno de difração de Bragg em uma grade de difração. Nesse processo, o sinal de entrada é direcionado para a grade de difração por reflexão, que separa os comprimentos de onda do sinal em diferentes ângulos (Figura 7). Em seguida, uma lente é usada para focalizar cada feixe de maneira adequada, permitindo que eles sejam acoplados corretamente à fibra óptica (AGRAWAL, 2010).

Figura 6 - Esquema de um multiplexador/demultiplexador.



Fonte: Modificada de AGRAWAL (2010)

Figura 7 - Grades de difração para (a) multiplexação e (b) demultiplexação.



Fonte: Autora

2.2.2. Amplificadores Ópticos

Em sistemas de transmissão óptica de longas distâncias, é essencial que o sinal chegue ao receptor com potência suficiente para ser detectado e interpretado corretamente. Em sistemas WDM, a utilização de repetidores optoeletrônicos para a regeneração do sinal era uma opção que demandava tempo de processamento e o custo operacional, pois era necessário que o sinal fosse convertido primeiramente para a forma elétrica, amplificado e assim ser transmitido novamente. O uso de amplificadores ópticos tornou-se comum durante a década de 1990. Com esse equipamento foi possível realizar a amplificação sem a necessidade de conversão do sinal óptico em pulsos elétricos. (AGRAWAL,2010)


Quanto às possíveis formas com que são aplicados em um link de transmissão, os amplificadores podem ser de:

- a) amplificação de linha ou *in-line* onde uma simples amplificação do sinal óptico é suficiente para aumentar a distância de transmissão compensando as perdas;
- b) pré-amplificador onde o equipamento é inserido imediatamente antes do receptor óptico, de tal modo que a degradação da relação sinal-ruído inerente seja eliminada, proporcionando maior fator de ganho e largura de banda;
- c) amplificador de potência ou *booster*, quando a inserção do dispositivo é feita após o transmissor óptico para aumentar a potência transmitida, propiciando um aumento na distância de transmissão de 10-100 km.

Segundo Kaiser (2014), os amplificadores ópticos podem ser classificados em três tipos: os amplificadores ópticos semicondutores (SOAs), os amplificadores *Raman* e os amplificadores de fibra dopada (DFAs). No âmbito deste trabalho, será enfatizado o amplificador EDFA (*Erbium-Doped Fiber Amplifier*), um tipo de amplificador DFA que incorpora érbio como elemento dopante. Esse amplificador estará presente nas simulações realizadas, recebendo especial atenção.

A condição do ganho óptico está associada ao bombeamento dos íons de érbio ((Er^{3+})) presentes no núcleo da fibra em um apropriado comprimento de onda. O bombeamento eficiente é alcançado com o emprego de lasers de semicondutores que, cabe ressaltar, teve sua evolução estimulada pelos amplificadores EDFAs. O espectro de ganho depende do esquema de bombeamento, assim como da presença de outros dopantes, como germânia (Ge) e alumina (Al), no núcleo da fibra. Pode-se observar na Figura 8 as respostas de absorção e de ganho de um EDFA em uma fibra de sílica dopada com Ge. É observada boa atuação do EDFA em 1.532nm e uma diminuição acentuada após 1.560nm.

Figura 8 - Espectro de absorção e ganho de um EDFA com núcleo dopado com germânia.



Fonte: Modificada de AGRAWAL (2010)

Ao mesmo tempo em que amplificam o sinal, os amplificadores ópticos também amplificam fótons indesejados que se propagam ao longo da fibra. Esse fenômeno é conhecido como emissão espontânea amplificada (ASE - *Amplified Spontaneous Emission*). Desta forma, o ganho fornecido pelo amplificador EDFA depende de vários fatores, incluindo o nível de dopagem e o comprimento da fibra utilizada como elemento ativo, a potência do laser de bombeamento e a potência do sinal. Restrições à amplificação são impostas em função do ASE, pois eles degradam a relação sinal-ruído (SNR).

2.2.3. Receptor Óptico

Os receptores ópticos realizam o processo inverso dos transmissores, ou seja, convertem o sinal óptico novamente à forma elétrica para a recuperação dos dados enviados através do sistema. O principal componente deste equipamento é um fotodetector que tem como incumbência a conversão da luz em eletricidade por meio do efeito fotoelétrico.

O mecanismo fundamental responsável pelo processo de fotodetecção é a absorção óptica. Os fotodetectores comumente utilizados são baseados em blocos de semicondutores, o mais comum são os fotodiodos. Os dois tipos de fotodiodos utilizados são o fotodetector *pin*, que consiste em inserir entre as regiões *p* e *n* um material semicondutor não dopado, ou levemente dopado, e o

fotodiodo de avalanche (APD - *Avalanche Photo Diode*), que combina a detecção de sinais ópticos com amplificação interna da fotocorrente obtida por meio do processo de multiplicação avalanche de portadores na região da junção.

Além do fotodetector, na estrutura do receptor têm-se um pré-amplificador eletrônico, que aumenta a corrente elétrica a ser processada pela eletrônica que se segue, e outros elementos essenciais para o processamento do sinal. Para obter um bom desempenho em sistemas de transmissão óptica, é essencial que um receptor apresente características como alta sensibilidade, resposta rápida, alta confiabilidade, baixo nível de ruído e custo acessível.

Os receptores ópticos devem possuir ainda certa sensibilidade para alcançar a conversão do sinal. O desempenho é definido pela probabilidade de identificação incorreta de um bit pelo circuito de decisão, também conhecido como taxa de erro por bit (BER - *Bit Error Rate*).

Assim, para alcançar uma BER específica com determinada taxa de dados, é necessário que uma potência óptica mínima atinja o fotodetector. Uma BER de 2×10^{-6} corresponde, em média, a 2 erros por milhão de bits. Um critério aceito para a sensibilidade em receptores ópticos digitais requer que a BER opere a taxas abaixo de 1 erro por bilhão de bits, 10^{-9} . Sabendo que N_e representa o número de erros que ocorrem durante um dado intervalo de tempo t e N_t o número de pulsos transmitido durante esse intervalo, então temos

$$BER = \frac{N_e}{N_t} = \frac{N_e}{Bt} \quad (2.15)$$

onde a taxa de bits é dada por $B = \frac{1}{T_b}$.


Outro parâmetro amplamente utilizado para especificar o desempenho do receptor é o Fator Q. Uma vez que ele está relacionado com a relação sinal-ruído requerida para alcançar uma taxa de erro bit específica. Ele leva em consideração que em sistemas de fibras ópticas, as variâncias de energia para pulsos lógicos 0 e 1 recebidos geralmente são diferentes.

A Equação 2.16 exprime a relação entre BER e Fator Q

$$BER = \frac{1}{2} \operatorname{erfc}\left(\frac{Q}{\sqrt{2}}\right) = \frac{1}{\sqrt{2\pi}} \frac{1}{Q} \exp\left(-\frac{Q^2}{2}\right) \quad (2.16)$$

Assim, uma forma simples de examinar a probabilidade de erro versus o fator Q é variar o Q alterando o nível de potência óptica para o receptor. Pode ser observado na Figura 9 que, conforme aumenta-se o valor de Q, a BER diminui, e a sensibilidade do receptor ($BER = 10^{-9}$) corresponde à potência óptica média para a qual fator Q tem valor 6 (KAISER, 2014).

Figura 9 - Taxa de erro de bit (BER) em função do Fator Q.




Fonte: AGRAWAL (2010)

Para a avaliação da capacidade de manipulação de dados de um sistema de transmissão digital pelo Fator Q, o diagrama de olho é uma ferramenta adequada. Ele fornece uma forma visual de monitorar o desempenho do receptor.

Em sistemas digitais de fibras ópticas, onde os níveis lógicos 0 e 1 são caracterizados pelas tensões médias dos sinais recebidos, quanto maior o valor do Fator Q, menor é a possibilidade de ocorrência de erros. As principais características a serem examinadas em um diagrama de olho são a largura da abertura do olho, que determina o intervalo de tempo no qual o sinal recebido pode ser corretamente amostrado, minimizando a interferência intersimbólica; e a altura da abertura do olho, que indica o grau de distorção e, portanto, a tolerância ao ruído (Figura 10).

Figura 10 - Padrão de olho (a) ideal e (b) degradado para pulsos no formato NRZ.



Fonte: AGRAWAL (2010)

2.3. MACHINE LEARNING

Como já apresentado, a previsão de QoT, antes do estabelecimento de conexões, pode ajudar a melhorar a taxa de sucesso do estabelecimento de conexões e reduzir as grandes margens inseridas nos sistemas ópticos. Neste cenário, a utilização de *machine learning* para melhorar a precisão dos modelos de previsão dos níveis de qualidade revela-se como grande aliado.

O aprendizado de máquina (ML - *Machine Learning*) é um tipo de inteligência artificial (IA) que dá aos computadores a capacidade de aprender, sem que sejam explicitamente programados; o conhecimento é adquirido sem que seja necessário informar ao computador detalhadamente os movimentos sequenciados para que ele aprenda o que precisa, pois o conhecimento é obtido, detectando padrões e ajustando as ações do programa. Há dois tipos de aprendizado que serão detalhados na sequência (BISHOP, 2006).

2.3.1. Aprendizado não supervisionado e supervisionado

O aprendizado não supervisionado identifica semelhanças nos dados e reage conforme a presença ou ausência de tais semelhanças em cada novo dado, irá treinar uma máquina a partir de dados que não estão rotulados e/ou classificados. Os algoritmos irão encontrar padrões para agrupar, mas não irá limitar a busca de padrões no conjunto de dados já que eles não foram rotulados. Como não há uma variável específica a ser explicada (ou seja, não há um alvo), se torna com isso, mais

difícil de serem avaliados, pois não haverá uma resposta correta. Como não há impedimentos para utilização de aprendizado não supervisionado mesmo quando já temos conhecimento de padrões do problema, poderemos utilizar como uma etapa de pré-processamento que irá auxiliar na descoberta dos dados (BISHOP, 2006).


O principal método de aprendizado não supervisionado é o de agrupamento (*Clustering*), onde podemos destacar os algoritmos K-means e o DBSCAN, entretanto há outras técnicas como redução de dimensionalidade (*Dimensionality Reduction*) como a análise de componentes principais (PCA), método matemático que irá converter um conjunto de dados que descrevem um elemento em um novo conjunto, menor; há ainda outro método chamado de regras de associação (*Association Rules*), que podemos citar os algoritmos AIS, SETM e o Apriori (BISHOP, 2006).

Nos modelos de aprendizagem de máquina supervisionado poderemos encontrar padrões em dados, bem como gerar previsões que poderão ser aplicadas a diversas soluções. Há a intervenção humana nos dados de treinamento e irá adquirir informações de relacionamento ou correlação entre entrada e saída de um sistema, onde o rótulo pode ser definido como o conhecimento da resposta de alguns casos solucionados. Modelos de aprendizado de máquina supervisionados são em geral os mais utilizados. Poderão solucionar problemas de classificação ou regressão.

A classificação utiliza métodos que procuram explicar uma variável categórica, com duas categorias (binária) ou mais, já a regressão busca encontrar como uma variável evolui em relação as outras (BISHOP, 2006). Tendo o enfoque deste trabalho de dissertação a previsão de parâmetros de qualidade dos valores alvo de acordo com determinadas características do sistema óptico proposto, os algoritmos de regressão utilizados serão discutidos com mais detalhes a seguir.

Os modelos de regressão são utilizados onde o resultado esperado é a estimativa de um valor, por exemplo, prever o preço de uma casa ou a demanda de produtos em um *e-commerce* que serão comprados em determinado mês, e assim por diante. Os modelos de regressão podem ser simples ou múltiplos, lineares ou não lineares, conforme Figura 11 (BISHOP, 2006).

Figura 11 - Modelos de regressão utilizados no aprendizado de máquina.




Fonte: Autora

Nos modelos supervisionados o conjunto de dados é dividido em duas partes: treino e teste, onde o modelo de aprendizado de máquina será treinado no conjunto de dados (*dataset*) de treino. O modelo irá realizar previsões no conjunto de dados de teste e será feita uma avaliação de qualidade das previsões, utilizando métricas de validação de medição estatística (BISHOP, 2006).

De maneira geral, o algoritmo de *machine learning*, de posse de uma base de dados já classificada, é capaz de realizar a previsão sobre novos dados. Para isto, uma parte dos dados é utilizada para treino e a outra parte para teste. Frequentemente são utilizadas as proporções de 80/20 ou 90/10 para treino e teste, respectivamente, porém outras proporções podem ser utilizadas de acordo com o problema apresentado. Assim, pode ser observado na Figura 12 que em uma primeira etapa, o modelo é treinado com uma porcentagem da base de dados. Após esta fase, a confiabilidade dos dados previstos pelo modelo é testada com o restante da base não utilizada no teste para a avaliação do modelo.

Figura 12 – Esquemático funcionamento do aprendizado de máquina.



Fonte: Autora

Com isso, na Figura 13 é possível observar que o modelo treinado é capaz, com a adição de novos dados, de realizar a predição dos valores.

Figura 13 - Esquemático de predição de valores com novos dados.



Fonte: Autora

O trabalho com *machine learning* pode ser feito com linguagens de programação. As duas principais linguagens utilizadas são a *Python* e a Linguagem R, que possuem bibliotecas e *frameworks* prontos para utilização que tornam facilitava a construção do algoritmo. A seguir, serão descritos os algoritmos que apresentaram melhores desempenho e, portanto, foram utilizados no treinamento da base de dados do estudo.

2.3.2. Algoritmos de Machine Learning

2.3.2.1. Decision Tree Regression


O algoritmo *Decision Tree Regression* (DTR) é constituído a partir do conceito da árvore de decisão. Com estrutura similar ao de um fluxograma, a árvore de decisão

é um algoritmo de aprendizado de máquina supervisionado, quando o modelo aprende a partir de resultados pré-definidos.

A árvore de decisão utiliza o conceito de nós para cada ponto de decisão. O nó raiz é o mais alto em uma árvore, enquanto cada nó interno simboliza um teste em um atributo, em que cada ramificação representa o resultado de um teste e, por fim, onde o nó folha contém um rótulo de classe, pode ser visualizado na Figura 14.

As árvores de decisão utilizadas para regressão utilizam-se dos conceitos de média e desvio padrão. Na análise do problema, nas variáveis preditoras dos nós principais será calculado o desvio padrão dos valores da variável alvo para cada variável preditora, de acordo com suas variações.

Figura 14 – Estrutura da árvore de decisão.



Fonte: Autora

2.3.2.2. *Random Forest Regression*

Este outro modelo de regressão também utiliza um conjunto de árvores de decisão, que executam uma sequência de testes simples para cada instância, percorrendo uma estrutura de dados de árvore binária até que uma decisão (nó folha) seja obtida. Para começar é preciso definir o primeiro nó da árvore (nó raiz), que será a primeira condição verificada, dando origem aos dois primeiros ramos. No *Random Forest Regression* (RFR) essa escolha da variável não acontece com base em todas as variáveis disponíveis. O algoritmo irá escolher de maneira aleatória (*random*) duas

ou mais variáveis, e então realizar os cálculos com base nas amostras selecionadas, para definir qual dessas variáveis será utilizada no primeiro nó. Para escolha da variável do próximo nó, novamente serão escolhidas duas (ou mais) variáveis, excluindo as já selecionadas anteriormente, e o processo de escolha se repetirá. Desta forma a árvore será construída até o último nó. A quantidade de variáveis a serem escolhidas pode ser definida na criação do modelo.

É evidente que este não é o método mais adequado para construção de uma árvore de decisão. O algoritmo pode, sem querer, selecionar as duas variáveis menos favoráveis na primeira seleção, escolhendo uma variável inadequada para o primeiro nó. Mas como serão construídas muitas árvores, essa estratégia se torna eficaz, e costuma prevenir o *overfitting*. (CRIMINISI, A.; SHOTTON, J.; KONUKOGLU, E, 2012).

2.3.2.3. *Gradient Boosting Regression*

O algoritmo *Gradient Boosting Regression* (GBR) é uma técnica de aprendizado de máquina utilizada para abordar problemas de classificação e regressão. Ele cria um modelo de previsão robusto combinando vários modelos de previsão mais simples, como árvores de decisão. Sua característica principal é que cada cálculo é realizado por um modelo básico, e o próximo cálculo visa reduzir os resíduos desses modelos, criando assim um modelo básico na direção do gradiente com resíduos minimizados. Em resumo, o GBR é uma técnica eficaz que gradualmente melhora o desempenho do modelo, refinando-o através da redução sistemática dos erros residuais.

O objetivo do algoritmo é criar uma corrente de modelos fracos, onde cada um tem como objetivo minimizar o erro do modelo anterior, por meio de uma função de perda. Aos ajustes de cada modelo fraco é multiplicado um valor chamado de taxa de aprendizagem. Esse valor, tem como objetivo determinar o impacto de cada árvore no modelo final. Quanto menor o valor, menor a contribuição de cada árvore (WEI, 2019).

2.3.2.4. *Histogram Gradient Boosting Regression*

Histogram Gradient Boosting Regression (HGBR) é um algoritmo com estrutura de árvore baseado em histograma que são utilizados para transmitir graficamente conhecimento acerca de uma distribuição de dados. Eles são utilizados

para retratar um determinado conjunto de informações em relação a uma variável específica, as vezes estando associados ao plano cartesiano de coordenadas. Sua estrutura consiste em um gráfico com número pré-determinado de colunas de largura igual que variam de altura no eixo y representando a quantidade de informação agrupada naquela determinada coluna em relação a uma única variável do eixo x.

O algoritmo baseado em histograma pode reduzir significativamente o custo computacional porque a fase de treinamento de uma árvore de decisão não exige a varredura de todas as faixas de entradas para ponto de divisão avaliado que resultaria na lentidão no treinamento dos dados e pode ajudar a conseguir um melhor desempenho porque a fase de aprendizagem é menos suscetível ao ruído (BISHOP, 2006).

3. METODOLOGIA

Ao longo desse capítulo, será apresentada a metodologia utilizada para a realização das simulações e análise dos dados. Com o intuito de prover um cenário com as configurações análogas às reais, foi realizada a simulação através de software referência em redes ópticas. De posse dos dados, técnicas de *machine learning* apresentam-se como grandes aliadas para a observação e análise dos parâmetros de qualidade alvo do estudo.

3.1. SIMULAÇÃO E TOPOLOGIA DA REDE ÓPTICA


O primeiro passo para a utilização dos algoritmos de aprendizado de máquina é a coleta dos dados e adequação dos mesmos. Para este propósito, foi utilizado o *software* de simulação *Optisystem* em sua versão 7.0 fornecido pela instituição e rodando no sistema operacional Windows.

O *software* é fornecido pela empresa *Optiwave*, amplamente empregado no mundo acadêmico e no mercado fotônico por ser capaz de proporcionar o planejamento, teste e simulação de redes ópticas eficientes e eficazes. Entre suas principais características, incluem-se o fornecimento de uma biblioteca de componentes para a caracterização do sistema e varredura automática dos parâmetros considerados (OPTIWAVE, 2023).

Assim, o sistema WDM, fundamentado em uma rede real delineada, foi simulado repetidamente em diferentes configurações para os parâmetros de entrada. Os dados de saída executados e fornecidos pelo *software* foram tratados e salvos como arquivos de texto CSV para posterior identificação e análise.

Os parâmetros de entrada examinados na simulação diretamente relacionados ao gerenciamento de perdas e dispersão são a potência do transmissor WDM, a potência de bombeamento do amplificador e o comprimento da fibra compensadora de dispersão. Para a avaliação do desempenho e qualidade do sistema, os parâmetros de saída alvo simulados foram o ganho total, a potência total, o mínimo BER e o máximo fator Q (Figura 15).


Figura 15 - Esquemático da simulação da rede.



Fonte: Autora

Na simulação base do estudo, é feita a análise tomando como base uma rede WDM ponto a ponto existente projetada por um ISP (*Internet Service Provider*) do estado do Ceará que interliga as cidades de Itapajé e Itapipoca. A distância total da rede é de 70 quilômetros e, em virtude deste distanciamento, a interligação do enlace é concebida por uma fibra monomodo (SMF - *Single Mode Fiber*), conforme recomendação ITU-T G.652 (ITU-T, 2016), utilizada na região de 1550 nm. A capacidade total do sistema é de 10 Gb/s. Na Figura 16 é ilustrada de maneira geral o *design* da rede óptica ponto a ponto.

Figura 16 - Rede óptica real simulada no Optisystem.



Fonte: Autora

3.2. CONFIGURAÇÃO DOS PARÂMETROS

Ao todo, o *software* realizou a varredura dos parâmetros de entrada em um total de 1.000 interações. Tendo em consideração a potência de transmissão do sistema WDM, esta foi variada em 10 incrementos de 1 dBm, variando de 3 a 12 dBm.

Para a potência de bombeamento dos amplificadores da rede óptica, a mesma foi ajustada em 10 níveis diferentes, variando de 21 a 30 dBm com passo de 1 dBm. O comprimento da fibra compensadora de dispersão foi variado em incrementos de 1 Km, abrangendo o intervalo de 1 a 10 Km.

Em Itapajé, o transmissor WDM utilizado possui 40 canais de comprimento de onda, de 193,1 a 197 THz, com frequência de espaçamento entre eles de 100GHz, seguindo a modulação NRZ, conforme a recomendação ITU-T G.694.1 (ITU-T, 2020). O canal de 10 GHz foi ajustado para a frequência de 193,1 THz, que corresponde ao canal 31 na banda C de transmissão óptica. Um amplificador EDFA atuando como *booster* foi inserido logo após ao transmissor óptico ainda na cidade de Itapajé com a finalidade de aumentar a potência transmitida. A Tabela 1 apresenta os parâmetros configurados para o transmissor WDM.

Tabela 1 - Parâmetros do transmissor WDM.

Parâmetro	Valor
Quantidade canais	40
Taxa Canal	10 Ghz
Frequência utilizada	193,1 THz
Banda Transmissão	C - Canal 31
Espaçamento entre canais	100 Ghz
Modulação	NRZ

Fonte: Autora

Levando em consideração ainda a grande influência da dispersão cromática em projetos de redes ópticas de longas distâncias, uma fibra DCF foi adicionada logo após a fibra SMF para minimizar os efeitos desse fenômeno. Os parâmetros integrantes das fibras SMF e DCF são exibidos na Tabela 2.

Tabela 2 - Parâmetros da fibra SMF e DCF.

Parâmetro	SMF	DCF
Dispersão (ps/nm·km)	16,75	-85,00
Atenuação (dB/km)	0,2	-0,3
Área efetiva (μm^2)	80	22

Fonte: Autora

O multiplexador e o demultiplexador inseridos nas extremidades do enlace possuem as mesmas configurações de quantidade de canais e definições das frequências de cada canal correspondente aos transmissores ópticos. Na estação fim de Itapipoca, será extraído pelo demultiplexador o Canal 31 a fim de ser ter sua informação detectada e regenerada pelo receptor óptico. A verificação dos pulsos é realizada pelo componente fornecido pela biblioteca do *software*, chamado de *BER Analyzer*, que fornece, além dos resultados da BER, as respostas para o ganho total, potência total e máximo fator Q.

3.3. TREINAMENTO DOS DADOS

A partir dos dados adquiridos após a simulação no software *OptiSystem*, e antes mesmo da aplicação dos algoritmos para treinamento do modelo que realizará a predição, é necessário realizar a conversão dos dados no formato para armazenamento de dados (.csv) para o emprego nas plataformas Azure ML (*classic*), Anaconda Navigator e Google Colab que executam o regressor.

3.3.1. Coeficientes de correlação

A análise de correlação, conforme Moore (2007), é uma medida numérica complementar ao gráfico que é capaz de medir a direção e a força da relação linear entre duas variáveis quantitativas, ou seja, o quanto duas variáveis guardam semelhanças. Elas podem se associar a partir da distribuição das frequências ou pelo compartilhamento de variância.

Neste ponto do trabalho serão demonstrados, através de dois coeficientes, como será analisado o grau de relacionamento (ou correlação) entre as variáveis. Para este fim, foram eleitos os coeficientes de correlação de *Pearson* e de *Spearman*.

3.3.1.1. Pearson

O coeficiente linear de Pearson, em nome de Karl Pearson que criou o teste, é uma medida estatística que avalia a relação linear entre duas variáveis quantitativas. Supondo que temos dados sobre as variáveis x e y para n indivíduos. Os valores para o primeiro indivíduo são x_1 e y_1 , os valores para o segundo indivíduo são x_2 e y_2 , e assim por diante. A correlação de Pearson (r) entre as variáveis x e y pode ser então definida como (Moore, 2007):

$$r = \frac{1}{n-1} \sum \left(\frac{x_i - \bar{x}}{s_x} \right) \left(\frac{y_i - \bar{y}}{s_y} \right) \quad (3.1)$$

onde $\bar{x}$ e $\bar{y}$ são as médias das duas variáveis, e os desvios padrão são s_x e s_y .

Os valores de r mais próximos de 1 ou -1 representam as relações lineares mais fortes, já para valores com correlação igual a zero revela a inexistência de uma relação linear entre as variáveis. Dancey e Reidy (2006) propõem uma classificação mais detalhada onde, além dos valores em 1 (+ ou -), em que se têm uma perfeita correlação, os valores r entre 0,10 até 0,30 a correlação é classificada como fraca; para r de 0,40 até 0,6 têm-se a classificação moderada e r igual 0,70 até 1 é considerada uma forte correlação.

3.3.1.2. Spearman

Os coeficientes de correlação de *Pearson* e *Spearman* são interpretados da mesma maneira. O coeficiente é usado quando os dados não satisfazem as condições de testes paramétricos, ou seja, não possuem uma distribuição normal (Dancey e Reidy, 2006). Quando há incerteza sobre a manutenção das condições para aplicar o coeficiente de Pearson e existem alguns pontos que se encontram muito distantes dos demais, é mais apropriado utilizar o coeficiente de *Spearman*. Isso porque o coeficiente converte os valores originais em classificações antes de realizar outros cálculos. Dessa forma, uma fórmula para calcular o coeficiente ρ de *Spearman* é dada pela Equação 3.2 seguinte:

$$\rho = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n^3 - 1} \quad (3.2)$$

onde é n o número de pares (x_i, y_i) e $d_i =$ (postos de x_i dentre os valores de x) - (postos de y_i dentre os valores de y). Assim como temos para o coeficiente de Pearson, se o valor de ρ se aproxima dos extremos +1 e -1, então eles têm uma associação de classificação perfeita. Para as interpretações dos níveis de correlação entre as variáveis em estudo, são consideradas as seguintes classificações demonstradas na Tabela 3:

Tabela 3 - Interpretação dos coeficientes de correlação Pearson e Spearman.

Correlação (+ ou -)	Interpretação
0,00 a 0,39	Correlação fraca
0,40 a 0,69	Correlação moderada
0,70 a 1,00	Correlação forte

Fonte: Autora

3.3.2. Métricas de avaliação dos modelos

Uma porção do conjunto de dados foi segregada para treinar o modelo, enquanto o restante foi reservado para fins de teste. Essa parcela separada, destinada à avaliação, será utilizada para verificar, através das métricas, o quanto o modelo proposto se ajusta ao problema apresentado.

Foram realizadas predições sobre todo o conjunto de dados com 80% do *dataset* para treinamento e os 20% restantes para avaliação do mesmo. Em geral, obter 90% dos dados para treinamento tende a produzir resultados mais eficazes, mas é incomum trabalhar com essa quantidade devido ao risco de indução a erro.

3.3.2.1. Coeficiente de determinação (R^2)

Esse coeficiente, chamado de R^2 ou “R-dois”, mede a porcentagem da variação total dos dados em relação a sua média que é explicado pelo modelo de regressão. Ele varia de 0 a 1, e tem-se que quando o valor de R^2 se aproxima de 1, isso indica que o modelo se ajusta muito bem aos dados, e a altura explica uma grande porcentagem das variações no peso. Por outro lado, quando R^2 se aproxima de 0,

significa que o modelo não se ajusta bem aos dados, e a altura não explica muitas das variações observadas no peso.

O coeficiente de determinação R^2 é definido conforme a Equação 3.3 abaixo:

$$R^2 = \frac{SQ_{TOT} - SQ_{REST}}{SQ_{TOT}} = \frac{SQ_{REG}}{SQ_{TOT}} = 1 - \frac{SQ_{REST}}{SQ_{TOT}} \quad (3.3)$$

onde SQ_{TOT} é a soma dos quadrados total, $SQ_{TOT} = \sum_{i=1}^n (y_i - \bar{y})^2$, SQ_{REST} representa a soma dos quadrados dos erro, $SQ_{REST} = \sum_{i=1}^n (y_i - \hat{y}_i)^2$, e SQ_{REG} é a soma dos quadrados de regressão, $SQ_{REG} = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$.

3.3.2.2. Erro Médio Absoluto (MAE)

Para se ter uma visão global sobre a performance do modelo, o erro médio absoluto (MAE - *Mean Absolute Error*) é a métrica de erro de regressão mais simples. Para cada ponto de dados, é obtido o valor do resíduo, ou seja, a diferença entre o valor real e o valor predito, e, em seguida, é calculada a média de todos esses resíduos. A aplicação do valor absoluto entre as diferenças dos valores (conforme a Equação 3.4) permite tratar tanto valores positivos quanto negativos, evitando que as diferenças com sinais contrários se anulem.

Uma das vantagens do MAE é que ele não é afetado por valores discrepantes (*outliers*), uma vez que a métrica leva em consideração apenas a magnitude das diferenças, não atribuindo pesos diferentes para resíduos maiores ou menores. Isso o torna uma medida robusta para avaliar o desempenho do modelo em relação às previsões.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3.4)$$

O valor de saída da equação tem a mesma escala dos dados utilizados para previsão, logo fica mais fácil a sua interpretação.

3.3.2.3. Erro Quadrático Médio (MSE)

O *Mean Squared Error* (Erro Quadrático Médio) é uma métrica que calcula a média das diferenças entre os valores preditos e os valores reais, assim como a métrica MAE (Erro Absoluto Médio). No entanto, ao invés de utilizar o valor absoluto da diferença entre y (valor real) e $\hat{y}$ (valor predito), nesta métrica a diferença é elevada ao quadrado, conforme a Equação 3.5. Isso resulta em uma penalização mais acentuada para valores que se distanciam muito entre as previsões e os valores reais.

Assim, quanto maior for o valor do MSE, indica que o modelo apresentou um desempenho menos satisfatório em suas previsões. Em contrapartida, quanto menor for o valor do MSE, melhor será o desempenho do modelo em suas previsões, demonstrando uma maior precisão.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3.5)$$

4. RESULTADOS E DISCURSÕES

Neste capítulo, de acordo com sequência dos estudos, serão apresentados os resultados obtidos na simulação e pelo emprego das técnicas de *machine learning*. Inicialmente respostas proporcionadas pelo *software* simulador na Seção 4.1 são divulgadas. Na Seção 4.2, é feita a análise de correlação entre os parâmetros de entrada fornecidos. Na sequência, Seção 4.3, foram abordados os resultados atingidos no treinamento dos modelos por meio dos algoritmos de regressão considerados. Por fim, na Seção 4.4, foi realizada a comparação dos valores simulados e dos treinados.

4.1. RESULTADOS OPTISYSTEM

Como já dito anteriormente, os parâmetros de entrada foram testados com as mais diversas configurações, atingindo um total de mil interações. O *software* foi capaz de proporcionar uma rica base de dados, porém sem, até este momento, ser qualificado para fornecer uma informação inteligível o suficiente que propicie um modelo e/ou resultado esperado para futuras predições.

Exemplo disso pode ser observado nas quatro configurações que obtiveram os melhores resultados da simulação para cada parâmetro de saída alvo. A Tabela 4 apresenta os valores atingidos na simulação e a configuração que culminou no respectivo resultado.

Tabela 4 - Melhores parâmetros de saída simulados e a sua configuração.

Parâmetros de saída	Resultado OptiSystem	WDM	EDFA	DCF
		Potência de Transmissão	Potência do Amplificador	Comprimento da Fibra
Ganho Total	-15,9740	3 dBm	30 dBm	1 km
Potência Total	-23,9852	12 dBm	30 dBm	1 km
Mínimo BER	$1,3320 \times 10^{-9}$	06 dBm	26 dBm	2 km
Máximo Fator Q	5,7142	10 dBm	21 dBm	1 km

Fonte: Autora

Pode-se observar que, para os alvos com os melhores valores alcançados, não há uma configuração padrão que atinja um nível de aptidão que sirva para a análise dos parâmetros de qualidade da rede. Desta forma, a seguir serão

apresentados graficamente os dados para cada parâmetro de saída simulado no *software OptiSystem* considerando as configurações selecionadas declaradas na Tabela 5.

Tabela 5 - Configurações dos parâmetros de saída selecionados.

Parâmetros de Entrada		Variações
WDM	Potência de Transmissão	3 a 12 dBm
EDFA	Potência do Amplificador	23, 25 ,27 e 29 dBm
DCF	Comprimento da Fibra	3, 5, 7 e 9 km


Fonte: Autora

4.1.1. Ganho Total

Os gráficos das curvas para o alvo ganho total, correlacionando as potências de amplificação (23, 25, 27 e 29) dBm aos valores de comprimento da fibra compensadora de dispersão, (3, 5, 7 e 9) km, demonstraram que, de forma geral, segue-se uma tendência de redução dos valores de ganho total, à medida que a potência de transmissão aumenta, porém, há um limiar que converge os valores a um denominador comum, onde fica desnecessário o acréscimo de potência de transmissão além da medida (Figura 17).

Maiores valores da potência de bombeamento do amplificador dopado com érbio alcançam maiores valores de ganho total, contudo, de forma semelhante ao que ocorre para a potência de transmissão, existe um instante em que mais amplificação não conduz a mais ganho. Pode-se perceber também que, em um contexto geral, os a inserção da DFC reduziu progressivamente valores de ganho total.

Figura 17 - Gráfico das curvas para a saída ganho total correlacionando as entradas potência WDM e bombeamento dos amplificadores para o comprimento da DCF em 3, 5, 7 e 9 km.




Fonte: Autora

4.1.2. Potência Total

Conforme pode ser visualizado na Figura 18, os gráficos das curvas para a saída potência total, correlacionando as potências de amplificação (23, 25, 27 e 29) dBm aos valores de comprimento da fibra compensadora de dispersão, (3, 5, 7 e 9) km, demonstraram que houve uma tendência de alta ao passo que a potência de transmissão aumentava.

Também foi observado que maiores valores da potência de bombeamento do amplificador alcançam maiores valores de potência total. Porém, de forma geral, houve uma condução a piores valores de potência total à medida que se aumentava o tamanho da fibra compensadora de dispersão.

Figura 18 - Gráfico das curvas para a saída potência total correlacionando as entradas potência WDM e bombeamento dos amplificadores para o comprimento da DCF em 3, 5, 7 e 9 km.



Fonte: Autora


4.1.3. Mínimo BER

Correlacionando-se as potências de amplificação (23, 25, 27 e 29) dBm aos valores de comprimento da fibra compensadora de dispersão, (3, 5, 7 e 9) km, pode-se observar na Figura 19 que não houve ausência de sinal, BER igual a 1, para nenhuma das configurações expressas.

Uma unanimidade não foi observada nas potências de amplificação que representasse uma escolha mais adequada para nenhuma das configurações da DCF. Para a fibra compensadora de dispersão a 3 km, o EDFA de 25 dBm apresentou melhor desempenho. Com as fibras a 5 km e 7 km, o EDFA de 23 dBm demonstrou

resultado mais satisfatório. Já o EDFA de 29 dBm teve melhor resultado no arranjo com a fibra compensadora de dispersão de 9 km.

Figura 19 - Gráfico das curvas para a saída mínimo BER correlacionando as entradas potência WDM e bombeamento dos amplificadores para o comprimento da DCF em 3, 5, 7 e 9 km.




Fonte: Autora

4.1.4. Máximo Fator Q

Na correlação entre as potências de amplificação (23, 25, 27 e 29) dBm aos valores de comprimento da fibra compensadora de dispersão, (3, 5, 7 e 9) km, o cenário em que o fator Q é zero e apresenta ausência de sinal não é apresentada. Em um contexto geral, é possível observar na Figura 20 que há uma tendência de queda dos valores de fator Q conforme aumenta-se a potência de transmissão. Porém percebe-se que há uma propensão à recuperação dos resultados a partir da potência de transmissão em 8 dBm, para a DCF de 5 e 7 km. É também observada que os

resultados de fator Q sofrem ligeira degradação à medida que se aumenta o tamanho da fibra compensadora de dispersão.

Figura 20 - Gráfico das curvas para a saída máximo Fator Q correlacionando as entradas potência WDM e bombeamento dos amplificadores para o comprimento da DCF em 3, 5, 7 e 9 km.



Fonte: Autora

4.2. ANÁLISE DE CORRELAÇÃO


Nesta fase, foram criados mapas de calor para avaliar os níveis de correlação e entender a relação matemática entre as variáveis alvo. Serão apresentadas em formato de subseções com o intuito de pontuar uma saída alvo por vez.

4.2.1. Ganho Total

Com enfoque na variável ganho total, conforme pode ser visualizado no mapa de calor (Figura 21), tanto para a correlação de *Pearson* quanto a de *Spearman*, a variável potência do EDFA possui uma fraca correlação e a fibra de dispersão

cromática possui uma correlação moderada. Enquanto a potência de transmissão possui uma ligeira variação que lhe coloca com a possibilidade de duas interpretações, moderada e forte, de acordo com *Pearson* e *Spearman*, respectivamente.

Figura 21 - Mapa de calor da correlação entre o ganho total e os dados de entrada para os coeficientes a) *Pearson* e b) *Spearman*.




Fonte: Autora

4.2.2. Potência Total

Buscando a análise da potência total, o mapa de calor gerado (Figura 22) apresenta pouca variação entre as correlações de *Pearson* e *Spearman*. As variáveis potência de transmissão WDM e potência do amplificador EDFA possuem uma correlação moderada. Para a distância da fibra compensadora de dispersão DCF, obteve-se valores de correlação um pouco melhores em comparação com as demais, porém que ainda a coloca, de acordo com a interpretação, em um nível moderado de correlação.

Figura 22 - Mapa de calor da correlação entre a potência total e os dados de entrada para os coeficientes a) Pearson e b) Spearman.



Fonte: Autora

4.2.3. Mínimo BER

O mapa de calor mostrado a seguir (Figura 23) apresenta os níveis de correlação para o mínimo BER considerando os coeficientes de correlação *Pearson* e *Spearman*. Nesta análise, percebe-se foram obtidos níveis de correlação muito fracos para todas as variáveis alvo estudadas nos dois coeficientes de correlação propostos.

Figura 23 - Mapa de calor da correlação entre o mínimo BER e os dados de entrada para os coeficientes a) Pearson e b) Spearman.




Fonte: Autora

4.2.4. Máximo Fator Q

Por fim, a Figura 24 gerada para os coeficientes de correlação de *Pearson* e *Spearman* busca examinar a correlação da variável máximo fator Q. A correlação da potência do WDM é considerada fraca, ao passo que o comprimento da fibra DCF pode ser interpretado como tendo uma correlação fraca ou moderada, de acordo com os critérios de Pearson e Spearman, respectivamente. Por outro lado, foi notado que a potência de bombeamento do amplificador EDFA apresenta uma correlação de nível moderado.


Figura 24 - Mapa de calor da correlação entre o máximo fator Q e os dados de entrada para os coeficientes a) Pearson e b) Spearman.



Fonte: Autora

A Figura 25 apresenta de forma consolidada para cada coeficiente, *Pearson* e *Spearman*, os valores de correlação das variáveis estudadas. Observa-se que os resultados encontrados não apresentam grandes variações de um coeficiente de correlação para o outro para as variáveis de saída consideradas.

Figura 25 - Mapa de calor da correlação consolidada dos dados de entrada e saída para os coeficientes a) Pearson e b) Spearman.




Fonte: Autora

4.3. AVALIAÇÃO DO TREINAMENTO DOS MODELOS

Nesta etapa serão apresentados gráficos para cada algoritmo de regressão, considerado as métricas de avaliação do treinamento dos modelos em função da porcentagem do banco de dados utilizada para treinamento os resultados alcançados. Foi focalizada uma saída alvo por vez para analisar de forma independente cada uma. O objetivo é exibir qual método possui o melhor desempenho, sendo identificado a partir das porcentagens e sua influência no treinamento dos modelos.


4.3.1. Ganho Total

Na análise do alvo ganho total, percebe-se (Figura 26) que o algoritmo *Histogram Gradient Boosting Regressor* (HGBR) alcançou as melhores pontuações. Para o coeficiente de determinação (R^2), ele permaneceu constante para quase toda a porcentagem da base de dados selecionada. Os demais algoritmos também alcançaram níveis relevantes, com R^2 acima de 95%, quando se utilizou a base de treinamento a partir dos 80%.

Figura 26 - Coeficiente de determinação R^2 para a saída ganho total.


Na Figura 27 e na Figura 28 são apresentados gráficos que corroboram com o resultado apontado pelo R^2 . Os erros de regressão MAE e MSE atingidos pelo HGBR foram os que apresentaram menores valores. Para o MAE, o modelo atingiu 0,046 de erro, enquanto para o MSE, o erro incidido foi de apenas 0,004.

Figura 27 - Erro Médio Absoluto (MAE) para a saída ganho total.



Fonte: Autora

Figura 28 - Erro Quadrático Médio (MSE) para a saída ganho total.




Fonte: Autora

4.3.2. Potência Total

Percebe-se que existe para o coeficiente de determinação R^2 , na exploração do alvo potência total, um gradativo crescimento, conforme se aumenta a base de treinamento utilizada. Novamente o destaque dos modelos propostos volta-se para o HGBR, que atinge na utilização da base em 80% um R^2 de 0,9997, representando o quanto o modelo consegue captar da variabilidade dos dados.

Os modelos *Random Forest Regression* (RFR) e *Gradient Boosting Regression* (GBR) também se apresentaram como aliados adequados no exame da saída potência total, principalmente para utilização da base a partir dos 50% quanto tiveram R^2 superior a 0,9837 (Figura 29). Nesta verificação é possível observar ainda que o algoritmo *Decision Tree Regression* apresentou rendimento menor em comparação com os demais, porém ainda favorável, alcançando 96,70% de adequação aos dados apresentados.

Figura 29 - Coeficiente de determinação R^2 para a saída potência total.




Fonte: Autora

Na avaliação da eficácia dos modelos de regressão considerando o MAE e MSE, novamente o algoritmo HGBR tem destaque com níveis de erro praticamente zerados (Figura 30 e 31). Os demais algoritmos apresentam uma tendência de redução de erro conforme aumenta-se a base de treinamento, sendo, por ordem de


desempenho, o GBR, o RFR e o DTR, porém que não lograram a performance notória do HGBR.

Figura 30 - Erro Médio Absoluto (MAE) para a saída potência total.



Fonte: Autora

Figura 31 - Erro Quadrático Médio (MSE) para a saída potência total.



Fonte: Autora

4.3.3. Mínimo BER

A saída de mínimo BER apresentou condições muito diferente das demais. Nenhum dos modelos propostos na averiguação se adequou de forma apropriada e o resultado foi insatisfatório como pode ser observado na Figura 32.

Ao contrário do previsto, obteve-se níveis negativos para coeficiente de determinação R^2 para praticamente todos os cenários explorados. Apenas o modelo GBR atingiu, utilizando 90% da base para treinamento, 6,40% de adequação aos dados. Porcentagem essa que não representa minimamente o esperado em termos qualitativos e o modelo escolhido se ajusta muito mal aos dados, ou seja, além do modelo não ter compreendido o padrão, ainda o detectou de maneira inversa.

Para justificar tal adversidade, algumas explanações podem ser consideradas. Primeiramente, destaca-se a análise previamente mencionada da correlação, na qual foram identificados níveis fracos de correlação para o BER mínimo, indicando que essa variável está consideravelmente descorrelacionada das entradas propostas.


Outro item relevante a ser ponderado é o tamanho da base utilizada no estudo. Observa-se uma tendência de crescimento dos valores de R^2 para o modelo GBR a partir da utilização de quase toda a base para treinamento, o que sugere melhores resultados com o reforço da base de dados de forma que o algoritmo se adeque de maneira mais certa ao modelo. Infelizmente, mensurar a proporção deste crescimento é possível apenas com incremento e testes.

Nesse contexto, uma opção de teste viável poderia ser a aplicação do *deep learning* (DL), uma subárea do *machine learning* que tem a capacidade de aprender com maior refinamento e é especialmente adequado para lidar com tarefas complexas. Outra abordagem praticável seria considerar a utilização de um algoritmo diferente, permitindo que os parâmetros se ajustem de forma mais adequada aos dados.

Nas métricas de erro, MAE e MSE, onde o objetivo é minimização destas, para encontrar o modelo que melhor se ajuste aos dados de treinamento e faça boas

previsões em dados não vistos, a saída mínimo BER não obteve êxito. Consequência de o modelo não ter se adequadado de maneira alguma ao propósito exposto.

Figura 32 - Coeficiente de determinação R^2 para a saída mínimo BER.




Fonte: Autora

4.3.4. Máximo Fator Q

Observa-se na Figura 33, que, para esse, alvo bons valores do coeficiente de determinação foram alcançados, com um crescimento gradual na medida em que se aumentava a base de treinamento para todos os modelos propostos no estudo.


O modelo HGBR obteve os melhores resultados durante a utilização de todas as bases de treinamento utilizadas, atingindo 0,9656 valor de R^2 com 80% da base utilizada para treinamento e 0,9804 com 90% de utilização da base.

Figura 33 - Coeficiente de determinação R^2 para a saída máximo fator Q.

Fonte: Autora


A avaliação do desempenho de modelos de regressão, medindo a qualidade das previsões em relação aos valores reais, proporcionada pelas métricas de erro MAE (Figura 34) e MSE (Figura 35), retornou como rendimento eminente o modelo HGBR, demonstrando uma maior precisão pelos menores valores de erro, a saber: MAE 0,071 e MSE igual a 0,020, quando da taxa de treinamento em 80%.

Figura 34 - Erro Médio Absoluto (MAE) para a saída máximo fator Q.



Fonte: Autora

Figura 35 - Erro Quadrático Médio (MSE) para a saída máximo fator Q.



Fonte: Autora

4.4. CONFRONTAÇÃO: SIMULADO x PREDITO

De posse dos modelos que obtiveram, na etapa de avaliação do treinamento dos modelos, as melhores respostas, serão comparadas as previsões do modelo com as respectivas simulações para averiguar o nível de assertividade ou erro nas previsões.


A seleção do algoritmo que forneceu melhores respostas foi feita com base nas previsões do conjunto de dados com 80% para treinamento e restante dos 20% para avaliação do modelo. Assim, busca-se a verificação dos resultados obtidos por meio das previsões, com o propósito de apresentar as comparações necessárias.


4.4.1. Ganho Total

O algoritmo *Histogram Gradient Boosting Regressor* (HGBR) foi o método que alcançou o melhor desempenho com o maior coeficiente de determinação para a saída ganho total. É possível visualizar graficamente, conforme Figura 36, o ganho total em função do parâmetro de entrada potência do WDM, correlacionando as potências de amplificação ao comprimento da fibra compensadora de dispersão.

Percebe-se que não há variações significativas entre os valores reais (simulados) e preditos (treinados) pelo algoritmo para as 4 configurações de DCF (3, 5, 7 e 9) km apresentadas, confirmando, dessa forma, que há correlação direta entre as entradas estudadas e a referida saída.

Figura 36 - Gráfico das curvas para a saída ganho total correlacionando as entradas potência WDM e bombeamento dos amplificadores para o comprimento da DCF em 3, 5, 7 e 9 km para os valores simulados e preditos.







4.4.2. Potência Total

Para realizar a comparação com os valores simulados, o algoritmo *Histogram Gradient Boosting Regressor* também foi utilizado por apresentar, diante das métricas de avaliação dos modelos, o melhor desempenho.

Na análise das curvas dos dados simulados e treinados, onde são correlacionadas as potências de amplificação (23, 25, 27 e 29) dBm com os comprimentos da fibra compensadora de dispersão (3, 5, 7 e 9) km, foi constatado que não há erros significativos (Figura 37). Esse resultado reforça a existência de uma correlação direta entre as entradas, comprimento da DCF e potências de transmissão e amplificação, e a saída (potência total) do sistema.

Figura 37 - Gráfico das curvas para a saída potência total correlacionando as entradas potência WDM e bombeamento dos amplificadores para o comprimento da DCF em 3, 5, 7 e 9 km para os valores simulados e preditos.





Fonte: Autora

4.4.3. Mínimo BER


O algoritmo *Gradient Boosting Regressor* foi utilizado por apresentar, dentre os demais, um desempenho mínimo pelas métricas de avaliação dos modelos. Na confrontação entre valores treinados e simulados, pode ser observado na Figura 38


que houve variação para certas configurações propostas pelo estudo. No geral, para os valores preditos, observa-se uma convergência próxima a zero, ou seja, a se ter um bom resultado pela baixa taxa de erro.

Porém, como já apresentado nas seções de análise de correlação e de avaliação do treinamento, para a saída mínimo BER, o modelo não conseguiu ter uma resposta satisfatória, o que macula o resultado predito e, consequentemente, toda a comparação.

Nesse cenário, podemos identificar uma ocorrência de *underfitting*, que é um fenômeno presente em modelos de aprendizado de máquina e que resulta em baixo desempenho tanto nos dados de treinamento quanto nos dados de teste. Em outras palavras, o modelo não consegue aprender de forma eficiente a relação entre as variáveis de entrada e de saída durante o processo de treinamento. Isso acaba levando a uma representação inadequada dos padrões nos dados e, consequentemente, a uma performance insatisfatória.

Figura 38 - Gráfico das curvas para a saída mínimo BER correlacionando as entradas potência WDM e bombeamento dos amplificadores para o comprimento da DCF em 3, 5, 7 e 9 km para os valores simulados e preditos.






Fonte: Autora


4.4.4. Máximo Fator Q

Os gráficos das análises para a saída máximo fator Q foram gerados também para o método HGBR, que obteve melhores respostas na etapa de avaliação.

A partir da Figura 39, pode-se perceber que foram observadas ligeiras variações entre os valores reais (simulados) e os valores previstos (treinados). Isso se deve ao fato de que as métricas de avaliação dos modelos para esse alvo apresentaram menor desempenho. Essa análise reitera a importância da correlação direta das variáveis de entrada com a saída, a qual se mostra como um fator determinante na predição realizada pelos métodos de aprendizado de máquina.

Figura 39 - Gráfico das curvas para a saída máximo fator Q correlacionando as entradas potência WDM e bombeamento dos amplificadores para o comprimento da DCF em 3, 5, 7 e 9 km para os valores simulados e preditos.





Fonte: Autora

5. CONCLUSÕES

No decorrer deste trabalho, foi evidenciado, com base em uma rede existente, como a aplicação da inteligência artificial no gerenciamento dos parâmetros de qualidade otimiza o desempenho das redes ópticas. A incorporação de algoritmos de aprendizado de máquina nas operações das redes ópticas possibilita atingir um nível de eficiência e adaptação que seria desafiador de ser alcançado por métodos manuais.

O exemplo em foco foi uma rede WDM ponto a ponto situada no estado do Ceará, cuja interligação ocorre através de fibras monomodo do tipo G.652, exibindo um coeficiente de dispersão elevado na faixa de 1550 nm. A simulação foi realizada no software *OptiSystem*, explorando diversas configurações.

Os parâmetros de entrada analisados consistiram na potência do sistema WDM, na potência de bombeamento do amplificador de fibra dopada com érbio (EDFA) e no comprimento da fibra compensadora de dispersão (DCF). Os parâmetros de qualidade de saída do sistema incluíram a potência total, o ganho total, o máximo Fator Q e o mínimo BER.

Os resultados das simulações computacionais corroboraram com as conclusões previamente obtidas a partir da análise de correlação, que tiveram resultados de correlação mais substanciais anotados para os parâmetros de saída ganho total, potência total e Fator Q.

A avaliação da eficácia dos algoritmos de inteligência artificial treinados se baseou no coeficiente de determinação (R^2), bem como nas métricas de erro MAE (*Mean Absolute Error*) e MSE (*Mean Squared Error*). Ficou evidente que, para o conjunto de dados simulados, o algoritmo de regressão *Histogram Gradient Boosting Regression* (HGBR) se destacou na análise dos parâmetros ganho total, potência total e Fator Q. Contudo, a avaliação da taxa de erro de bit para sistemas de fibras ópticas, abordada neste estudo, representou um desafio significativo, visto que os modelos não se adaptaram adequadamente ao cenário proposto.

Portanto, fica claro que a aprendizagem de máquina se revela como um campo promissor para aprimorar as redes ópticas. A utilização de algoritmos de

aprendizado de máquina proporciona soluções viáveis, eliminando a necessidade de estudar todas as possíveis situações e direcionando o planejamento de sistemas de comunicações ópticas para minimizar margens elevadas inseridas em projetos reais, que geram custos elevados e subaproveitam os recursos da rede.

Como sugestão para futuros trabalhos, é recomendada a expansão da base de dados e a aplicação do *deep learning* para exploração pelo aprendizado de máquina. Incentiva-se a adição de parâmetros para a análise de perdas não-lineares que possam apresentar maior correlação com a qualidade óptica da transmissão. Além disso, a introdução de linguagens de máquina mais robustas é encorajada para permitir novas investigações em cenários mais complexos de bases de dados.

REFERÊNCIAS

AGRAWAL, G. P. **Fiber-optic Communication Systems**. [S.l.]: New Jersey: [s.n.], p. 29 – 92. ISBN 978-0-470-50511-3., 2010.

BHARADIYA, Jasmin Praful. **Machine Learning and AI in Business Intelligence: Trends and Opportunities**. International Journal of Computer (IJC), v. 48, n. 1, p. 123-134, 2023.

BUHLMANN, P.; YU, B. Boosting. **WIREs Computational Statistics**, v. 2, n. 1, p. 69-74. [S.l.: s.n.], 2009.

Clemencon, S. e Vayatis, N. **Métodos de classificação baseados em árvore**. IEEE Trans. Inf. Teoria 55, 4316–4336. doi: 10.1109/TIT.2009.2025558, 2009.

CRIMINISI, A.; SHOTTON, J.; KONUKOGLU, E. **Decision Forests: A Unified Framework for Classification, Regression, Density Estimation, Manifold Learning and Semi-Supervised Learning**. Foundations and Trends in Computer Graphics and Vision, v. 7, n. 2-3, p. 81-227. [S.l.: s.n.], 2012.

HALLIDAY, D.; RESNICK, R. **Fundamentos de Física**. 8ª. ed. Rio de Janeiro: Moderna, v. 4, 2009.

HAUG, Charlotte J.; DRAZEN, Jeffrey M. **Artificial intelligence and machine learning in clinical medicine**. New England Journal of Medicine, v. 388, n. 13, p. 1201-1208, 2023.

HU, Bo-ning et al. **Analysis on Dispersion Compensation with DCF based on Optisystem**. In: 2010 2nd international conference on Industrial and Information Systems. IEEE, 2010. p. 40-43.

ITU - T G.652. **SERIES G: TRANSMISSION SYSTEMS AND MEDIA, DIGITAL SYSTEMS AND NETWORKS**. Transmission media and optical systems characteristics – Optical fiber cables; Characteristics of a single-mode optical fiber and cable. [S.l.], 2016.

ITU-R M.2370-0. **IMT Traffic Estimates for the Years 2020 to 2030**. 2015.

ITU-T G.694.1. **SERIES G: TRANSMISSION SYSTEMS AND MEDIA, DIGITAL SYSTEMS AND NETWORKS**. Transmission media and optical systems characteristics – Characteristics of optical systems / Spectral grids for WDM applications: DWDM frequency grid. [S.l.], 2020.

JUMIN, E.; BASARUDDIN, F. B.; YUSOFF, Y. B. M. **Solar radiation prediction using boosted decision tree regression model: A case study in Malaysia**. Environ Sci Pollut Res 28, 26571-26583, 2021. Disponível em: <https://doi-org.ez138.periodicos.capes.gov.br/10.1007/s11356-021-12435-6>.

KEISER, Gerd. **Comunicações por Fibras Ópticas**. AMGH Editora, 2014.

LIKEBUPT, et. al. **Boosted Decision Tree Regression: Component Reference - Azure Machine Learning**. [s.n.], 2022. Disponível em: <https://learn.microsoft.com/en-us/azure/machine-learning/component-reference/boosted-decision-tree-regression>.

LIMA, A. d. S. e. a. **Classificador Ensemble: Uma Abordagem Não Paramétrica Aplicado À Detecção De Diabetes**. In: Revista do Seminário Internacional de Estatística com R, v. 4, n. 2. [s.n.], 2019. Disponível em: <<https://periodicos.uff.br/anaisdoser/article/view/29318/17028>>.

NIC.BR. **Em nova marca recorde, IX.br ultrapassa os 31 Tbit/s de pico de troca de tráfego Internet**. 2023. Disponível em: <<https://nic.br/noticia/releases/em-nova-marca-recorde-ix-br-ultrapassa-os-31-tbit-s-de-pico-de-troca-de-trafego-internet/>>. Acesso em: 16 Set. 2023

OPTIWAVE. **System and Amplifier Design / OptiSystem**. 2023. Disponível em: <<https://optiwave.com/category/products/system-and-amplifier-design/optisystem/>>. Acesso em: 05 Jan. 2023.

RAI, Saloni; GARG, Amit Kumar. **Applications of machine learning techniques in next-generation optical WDM networks**. Journal of Optics, v. 51, n. 3, p. 772-781, 2022.

RUDRA, R. et al. **Applying Regression Models to Calculate the Qfactor of Multiplexed Video Signal based on Optisystem**. In: SAI Intelligent Systems Conference (IntelliSys). [S.l.: s.n.], 2015.

SHARIFANI, Koosha; AMINI, Mahyar. **Machine Learning and Deep Learning: A Review of Methods and Applications**. World Information Technology and Engineering Journal, v. 10, n. 07, p. 3897-3904, 2023.

SONI, Gaurav; KAUR, Rupinderjit. **Performance analysis of WDM link using Dispersion Compensating Fiber at different wavelengths**. In: 2014 International Conference on Contemporary Computing and Informatics (IC3I). IEEE, 2014. p. 1240-1244.

ZHANG, Lu et al. **A survey on QoT prediction using machine learning in optical networks**. Optical Fiber Technology, v. 68, p. 102804, 2022.