



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

ANA VALESKA PESSOA FERNANDES

**USO DE APRENDIZAGEM DE MÁQUINA PARA PROJETO E
ANÁLISE DE DESEMPENHO DE SISTEMAS DE COMUNICAÇÕES
ÓPTICAS**

FORTALEZA

2023

ANA VALESKA PESSOA FERNANDES

USO DE APRENDIZAGEM DE MÁQUINA PARA PROJETO E ANÁLISE
DE DESEMPENHO DE SISTEMAS DE COMUNICAÇÕES ÓPTICAS

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.

Co-orientador: 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)

- P475u Pessoa Fernandes, Ana Valeska.
USO DE APRENDIZAGEM DE MÁQUINA PARA PROJETO E ANÁLISE DE DESEMPENHO DE SISTEMAS DE COMUNICAÇÕES ÓPTICAS / Ana Valeska Pessoa Fernandes. - 2023.
85 f. : il. color.
- Dissertação (Mestrado) - Instituto Federal do Ceará, Mestrado em Engenharia de Telecomunicações, Campus Fortaleza, 2023.
Orientação: Prof. Dr. Glendo de Freitas Guimarães.
Coorientação: Prof. Dr. Yosdan Martínez Camejo.
1. WDM. 2. OptiSystem. 3. Aprendizagem de Máquina. 4. Aprendizagem 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

ATA DA DEFESA DE DISSERTAÇÃO

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE TELECOMUNICAÇÕES

Ata de defesa do Programa de Pós-graduação em Engenharia de Telecomunicações, do Curso de Mestrado Acadêmico em Engenharia de Telecomunicações (PPGET), ofertado pelo Instituto Federal de Educação, Ciência e Tecnologia do Ceará - IFCE, apresentado e defendido pela mestrandia **ANA VALESKA PESSOA FERNANDES**.

No dia 16 de fevereiro de 2023, às 14 horas, na sala 207A do Bloco Didático, foi realizada a defesa de dissertação da mestrandia **ANA VALESKA PESSOA FERNANDES** sob o título: "USO DE APRENDIZAGEM DE MÁQUINA PARA PROJETO E ANÁLISE DE DESEMPENHO DE SISTEMAS DE COMUNICAÇÕES ÓPTICAS". Obedecendo ao disposto no Regulamento do PPGET, a Banca Examinadora foi constituída pelos seguintes professores: Prof. Dr. **Glendo de Freitas Guimarães** (orientador) - IFCE *Campus* Fortaleza, Prof. Dr. **Yosdan Martínez Camejo** (coorientador) - IFCE *Campus* Fortaleza, Prof. Dr. **Régis Cristiano Pinheiro Marques** - (IFCE) e Prof. Dr. **Cícero Saraiva Sobrinho** - UNILAB.

O professor orientador apresentou o mestrando e os membros da Banca Examinadora bem como explicitou a dinâmica da defesa. Em continuidade, o presidente cedeu a palavra ao mestrando para expor seu trabalho de pesquisa. Uma vez concluída a exposição pelo mestrando, a Banca Examinadora procedeu às avaliações, sendo assegurado ao mestrando o direito de resposta ou de esclarecimento. Continuando o processo, a Banca Examinadora reuniu-se privativamente para emitir o parecer e, sequencialmente, informou ao mestrando que a sua dissertação foi considerada:

(☒) aprovada

(☐) reprovada

A Banca Examinadora indicou, ainda, ajustes e procedimentos necessários para a consolidação da pesquisa.

Nada mais havendo a tratar, o presidente da Banca Examinadora lavrou esta Ata de Exame de defesa que, após assinada pelos seus membros, será encaminhada à Coordenação do PPGET/IFCE para registro acadêmico na documentação do mestrando.

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. **Régis Cristiano Pinheiro Marques**

Instituto Federal de Educação, Ciência e Tecnologia do Ceará - IFCE

Prof. Dr. Cícero Saraiva Sobrinho

Universidade da Integração Internacional da Lusofonia Afro-Brasileira

Mestranda: ANA VALESKA PESSOA FERNANDES

Instituto Federal de Educação, Ciência e Tecnologia do Ceará - IFCE



Documento assinado eletronicamente por **Glendo de Freitas Guimaraes, Coordenador(a) do PPGET**, em 08/03/2023, às 08:50, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Cícero Saraiva Sobrinho, Usuário Externo**, em 08/03/2023, às 10:54, 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 08/03/2023, às 13:34, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Regis Cristiano Pinheiro Marques, Professor do Ensino Básico, Técnico e Tecnológico**, em 08/03/2023, às 16:10, 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 **4554041** e o código CRC **D9B4E025**.

Este trabalho é dedicado a Deus, minha
família e amigos.

AGRADECIMENTOS

Gostaria de expressar os meus sinceros agradecimentos a todos aqueles que de alguma forma possibilitaram a realização deste trabalho, em especial: A Deus, por guiar meus passos iluminando o caminho, dando força e sustentação durante essa caminhada.

Aos meus pais que me incentivaram na busca de melhorias com o uso do estudo como fator preponderante.

Ao Instituto Federal (IFCE), que em minha trajetória proporcionou um ambiente propício à troca de saberes e à construção do conhecimento. Ao meu orientador Glendo de Freitas, por ter acreditado em mim desde o início da vontade de cursar o mestrado, por ser uma referência tanto profissional como humana, pelas críticas construtivas que melhoraram a estrutura desse trabalho, pelas sugestões e questionamentos levantados. Aos colegas de profissão que me cederam e me incentivaram durante todos os dias compartilhando conhecimentos.

Aos participantes da banca examinadora e a todos os professores que me receberam em suas salas, compartilharam conhecimento, para que eu me torne uma profissional competente.

A todos os meus amigos pelas colaborações, em especial, Vanessa Diniz, Rogean Costa Silva e Zélia Lima que me incentivaram em todo o processo. Aos colegas de trabalho da PADTEC que auxiliaram com material de pesquisa para meu projeto.

“Insanidade é fazer sempre a mesma coisa e
esperar resultados diferentes”

(Albert Einstein)

RESUMO

A necessidade de estudo do aprimoramento da rede de comunicações ópticas e estimativa do crescente volume de tráfego móvel, especialmente com o advento do 5G e da internet das coisas, faz necessária a tratativa dos dados para aperfeiçoar o desempenho dessas redes. Estes dados podem ser obtidos e avaliados através de dados reais coletados, experimentais, modelados ou simulados. Este trabalho realizou a coleta de dados pelo método sintético de simulação no software *OptiSystem* para um sistema de multiplexação de comprimento de onda denso, onde foi utilizada uma rede óptica real para montar seu par simulado pelo referido software citado. Com essa base de dados coletada, foi realizada a modelagem dos dados através de diferentes algoritmos de inteligência artificial. Algoritmos regressores que têm como fim prever valores numéricos específicos mostraram-se mais apropriados aos objetivos desse trabalho. Estudos de diferentes parâmetros de saída como potência total, ganho total, máximo Qfator e mínimo BER e suas correlações com os parâmetros de entrada, potência do *Wavelength Division Multiplexing* (WDM) e bombeamento dos amplificadores de fibra óptica dopada por érbio (EDFA – *Erbium Doped Fiber Amplifiers*), foram praticados para análise. A efetividade dos três modelos de aprendizagem de máquina treinados foram avaliados através do coeficiente de determinação (R^2). O modelo *Boosted Decision Tree Regression* (BDTR) obteve uma melhor estimativa para as saídas potência total e ganho total, enquanto o modelo *Histogram Gradient Boosting Regression* (HGBR) apresentou uma melhor estimativa para as saídas máximo Qfator e mínimo BER. O conjunto de dados gerado por simulação foi confrontado com o treinado na *machine learning* (ML), confirmando a eficácia da predição dos valores alvos, que têm melhores correlações com as entradas, e ratificando que, para as saídas que tiveram menores correlações, foram obtidos resultados imprecisos. Como a execução da análise de parâmetros relacionados ao gerenciamento de perdas foi tomada como cerne deste estudo, e não aos relacionados ao gerenciamento de dispersão, as precisões para os parâmetros de saída foram as esperadas. A principal vantagem da utilização dos modelos de *machine learning* é que profissionais da área de óptica possam prever e aprimorar a rede visando minimizar as altas margens que são inseridas nos projetos reais e que oneram e levam à subutilização dos recursos da rede.

Palavras-chave: WDM. *OptiSystem*. Aprendizagem de Máquina. Amplificadores EDFA.

ABSTRACT

The need to study the improvement of optical communications networks and the estimated growing volume of mobile traffic, especially with the advent of 5G and the Internet of Things, makes it necessary to process data to improve the performance of these networks. This data can be obtained and evaluated through collected, experimental, modeled, or simulated data. This work collected data by the synthetic simulation method in OptiSystem software for a Dense Wavelength Division Multiplexing system, where we use an entire optical network to assemble its simulated pair using the mentioned software. We modeled the data using different artificial intelligence algorithms with this database collected. Regression algorithms that aim to predict specific numerical values proved to be more appropriate to the objectives of this work. We studied different parameters for the analysis, such as total power, total gain, maximum Q factor, minimum BER, and their correlations with the input parameters, Wavelength Division Multiplexing (WDM) power, and pumping of erbium-doped fiber amplifiers (EDFA). We evaluated the effectiveness of the three trained machine learning (ML) models using the coefficient of determination (R^2). The Boosted Decision Tree Regression (BDTR) model obtained a better estimate for the total power and total gain outputs, while the Histogram Gradient Boosting Regression (HGBR) model showed a better estimate for the maximum Q factor and minimum BER outputs. We compared the simulation-generated dataset with the one trained on the machine learning (ML), confirming the effectiveness of predicting target values, which have better correlations with the inputs, and ratifying that, for the outputs that had lower correlations, inaccurate results were obtained. Since performing the analysis of parameters related to loss management was taken as the focus of this study and not those related to dispersion management, the accuracy for the output parameters was as expected. The main advantage of using machine learning models is that optics professionals can predict and improve the network to minimize the high margins inserted in real projects that end up being costly and have an under-utilization of the network resources.

Keywords: WDM. OptiSystem. Machine learning. EDFA Amplifiers.

LISTA DE FIGURAS

Figura 1 - Desenho esquemático de uma fibra óptica.	26
Figura 2 - Desenho esquemático de uma fibra óptica monomodo.	27
Figura 3 - Desenho esquemático de uma fibra óptica multimodo.	27
Figura 4 - Diagrama do processo de dispersão da luz.	28
Figura 5 - Esquematização dos processos de emissão espontânea e estimulada.	32
Figura 6 - Modelo de bandas da emissão de um fóton.	33
Figura 7 - Topologia simplificada de uma rede DWDM.	36
Figura 8 - Processo de transmissão e recepção do sinal.	36
Figura 9 - Esquema de funcionamento de Multiplexadores.	38
Figura 10 - Configuração de um multiplexador de quatro canais.	39
Figura 11 - Esquema de funcionamento de Demultiplexadores.	39
Figura 12 - Esquema de um demultiplexador baseado em grade de difração, com uso de lente convencional.	40
Figura 13 - Esquema de um multiplexador de adição-extração baseado em comutadores ópticos.	41
Figura 14 - Representação esquemática de proteção de rota.	41
Figura 15 - Gráficos dos ganhos em função da potência de bombeamento de um amplificador e do comprimento do amplificador.	46
Figura 16 - Gráficos da figura de ruído e ganho em função do comprimento do amplificador.	47
Figura 17 - Modelos de regressão utilizados no aprendizado de máquina.	48
Figura 18 - Árvore de decisão Decision Tree Regression	49
Figura 19 - Método de aprendizado Decision Forest Regression.	51
Figura 20 - Sistema DWDM existente.	53
Figura 21 - Sistema DWDM e seus componentes da rede óptica simulada no OptiSystem.	54
Figura 22 - Esquemático treinamento dos dados.	57
Figura 23 - Gráfico das curvas para os bombeamentos extremos (20;20;20) e (35;35;35) e os médios (25;25;25) e (30;30;30) obtidas mediante simulação.	58
Figura 24 - Gráfico das curvas para os bombeamentos extremos (20;20;20) e (35;35;35) e os médios (25;25;25) e (30;30;30) obtidas mediante simulação.	59
Figura 25 - Gráfico das curvas para os bombeamentos extremos (20;20;20) e (35;35;35) e os médios (25;25;25) e (30;30;30) obtidas mediante simulação.	60

Figura 26 - Gráfico das curvas para os bombeamentos extremos (20;20;20) e (35;35;35) e os médios (25;25;25) e (30;30;30) obtidas mediante simulação.....	61
Figura 27 - Heatmap correlacionando o ganho total com os dados de entrada.	62
Figura 28 - Heatmap correlacionando o potência total com os dados de entrada.	63
Figura 29 - Heatmap correlacionando a variável máximo Qfator com as variáveis de entrada.....	64
Figura 30 - Heatmap correlacionando a variável mínimo BER com as variáveis de entrada. .	65
Figura 31 - Gráfico dos treinamentos realizados sobre o conjunto de dados utilizando os algoritmos de IA: BDTR, DFR e HGBR tendo como alvo o ganho total.	66
Figura 32 - Gráficos de barras dos valores obtidos para o parâmetro R^2 relacionados aos diferentes algoritmos de treinamento usados variando algumas porcentagens da base de dados utilizada no estudo tendo como alvo o ganho total	66
Figura 33 - Gráfico dos treinamentos realizados sobre o conjunto de dados utilizando os algoritmos de IA: BDTR, DFR e HGBR tendo como alvo a potência total.....	67
Figura 34 - Gráficos de barras dos valores obtidos para o parâmetro R^2 relacionados aos diferentes algoritmos de treinamento usados variando algumas porcentagens da base de dados utilizada no estudo tendo como alvo a potência total.....	67
Figura 35 - Gráfico dos treinamentos realizados sobre o conjunto de dados utilizando os algoritmos de IA: BDTR, DFR e HGBR tendo como alvo o Qfator.....	68
Figura 36 - Gráficos de barras dos valores obtidos para o parâmetro R^2 relacionado aos diferentes algoritmos de treinamento usados variando algumas porcentagens da base de dados utilizada no estudo tendo como alvo o máximo Qfator.....	68
Figura 37 - Gráfico dos treinamentos realizados sobre o conjunto de dados utilizando os algoritmos de IA: BDTR, DFR e HGBR tendo como alvo o Mín. BER.....	70
Figura 38 - Gráficos de barras dos valores obtidos para o parâmetro R^2 relacionado aos diferentes algoritmos de treinamento usados variando algumas porcentagens da base de dados utilizada no estudo tendo como alvo o mínimo BER.....	70
Figura 39 - (a) Comparação real x predição para a saída ganho total dos bombeamentos extremos inferiores (20;20;20); (b) Comparação real x predição para a saída ganho total dos bombeamentos extremos superiores (35;35;35); (c) Comparação real x predição para a saída ganho total dos bombeamentos médios (25;25;25); (d) Comparação real x predição para a saída ganho total dos bombeamentos médios (30;30;30).	72

Figura 40 - (a) Gráfico das curvas dos dados simulados referente aos bombeamentos dos EDFAs dos pontos extremos e médios para a saída ganho total; (b) Gráfico das curvas dos dados treinados referente aos bombeamentos dos EDFAs dos pontos extremos e médios para a saída ganho total.....	73
Figura 41 - (a) Gráfico das curvas dos dados simulados referente aos bombeamentos dos EDFAs dos pontos extremos e médios para a saída potência total; (b) Gráfico das curvas dos dados treinados referente aos bombeamentos dos EDFAs dos pontos extremos e médios para a saída potência total.	74
Figura 42 - (a) Comparação real x predição para a saída potência total dos bombeamentos extremos inferiores (20;20;20); (b) Comparação real x predição para a saída potência total dos bombeamentos extremos superiores (35;35;35); (c) Comparação real x predição para a saída potência total dos bombeamentos médios (25;25;25); (d) Comparação real x predição para a saída potência total dos bombeamentos médios (30;30;30).....	74
Figura 43 - (a) Comparação real x predição para a saída máximo Qfator dos bombeamentos extremos inferiores (20;20;20); (b) Comparação real x predição para a saída máximo Qfator dos bombeamentos extremos superiores (35;35;35); (c) Comparação real x predição para a saída máximo Qfator dos bombeamentos médios (25;25;25); (d) Comparação real x predição para a saída máximo Qfator dos bombeamentos médios (30;30;30).	76
Figura 44 - (a) Gráfico das curvas dos dados simulados referente aos bombeamentos dos EDFAs dos pontos extremos e médios para a saída máximo Qfator; (b) Gráfico das curvas dos dados treinados referente aos bombeamentos dos EDFAs dos pontos extremos e médios para a saída máximo Qfator.	77
Figura 45 - (a) Comparação real x predição para a saída mínimo BER dos bombeamentos extremos inferiores (20;20;20); (b) Comparação real x predição para a saída mínimo BER dos bombeamentos extremos superiores (35;35;35); (c) Comparação real x predição para a saída mínimo BER dos bombeamentos médios (25;25;25); (d) Comparação real x predição para a saída mínimo BER dos bombeamentos médios (30;30;30),.....	78
Figura 46 - (a) Gráfico das curvas dos dados simulados referente aos bombeamentos dos EDFAs dos pontos extremos e médios para a saída mínimo BER; (b) Gráfico das curvas dos dados treinados referente aos bombeamentos dos EDFAs dos pontos extremos e médios para a saída mínimo BER.	79

Figura 47 - Gráficos de barra para a comparação simulado x treinado para os melhores valores de saída referente aos parâmetros ganho total, potência total, máximo Qfator e mínimo BER.	80
--	----

LISTA DE TABELAS

Tabela 1 - Parâmetros do sistema DWDM simulado.	55
Tabela 2 - Classificação dos índices de correlação e suas interpretações.	56
Tabela 3 - Melhores parâmetros de saída.	61
Tabela 4 - Melhores parâmetros de saída (Simulado e Treinado).	80

LISTA DE ABREVIATURAS E SIGLAS

ASE	do inglês, amplified spontaneous emission
BDTR	do inglês, boosted decision tree regression
BER	do inglês, bit error rate
CW	do inglês, continuous wave
DCF	do inglês, dispersion compensating fiber
DFR	do inglês, decision forest regression
DL	do inglês, deep learning
DTR	do inglês, decision tree regression
DWDM	do inglês, dense wavelength division multiplexing
EDFA	do inglês, erbium doped fiber amplifier
FWM	do inglês, four wave mixing
GVD	do inglês, group velocity dispersion
HGBR	do inglês, histogram gradient boosting regression
IDE	do inglês, integrated development environment
IOT	do inglês, internet of things
Laser	do inglês, light amplification by stimulated emission of radiation
LED	do inglês, light emitting diode
LO	do inglês, local oscillator
MAPE	do inglês, mean absolute percentage error
ML	do inglês, machine learning
NRZ	do inglês, nonreturn to zero
QOT	do inglês, quality of transmission
ROADM	do inglês, reconfigurable optical add-drop multiplexer
RZ	do inglês, return to zero
SDN	do inglês, software defined networking
SNR	do inglês, signal to noise ratio
SRS	do inglês, stimulated raman scattering
WDM	do inglês, wavelengt division multiplexing

LISTA DE SÍMBOLOS

n	Índice de refração do meio
c	Velocidade da luz no vácuo
α	Coeficiente de atenuação
σ^2	Variância de fotocorrente
Γ	Fator de confinamento

SUMÁRIO

1 INTRODUÇÃO	21
1.1 OBJETIVOS	23
1.1.1 OBJETIVO GERAL	23
1.1.2 OBJETIVOS ESPECÍFICOS	23
1.2 ORGANIZAÇÃO DA DISSERTAÇÃO	23
2 FUNDAMENTAÇÃO TEÓRICA	25
2.1 FIBRA ÓPTICA	25
2.1.1 DISPERSÕES EM FIBRAS ÓPTICAS	28
2.1.1.1 Dispersão Modal.....	28
2.1.1.2 Dispersão Cromática	29
2.1.1.3 Dispersão por modo de polarização	29
2.1.2 ATENUAÇÃO.....	30
2.1.3 EFEITOS NÃO LINEARES	30
2.1.3.1 Espalhamento estimulado de luz.....	30
2.1.3.2 Modulação de fase não linear	31
2.1.3.3 Mistura de quatro ondas	31
2.2 TRANSMISSORES ÓPTICOS.....	31
2.2.1 EMISSÕES ESPONTÂNEA E ESTIMULADA	32
2.2.2 GERAÇÃO DO SINAL ÓPTICO.....	33
2.3 RECEPTORES ÓPTICOS	34
2.4 WDM	35
2.4.1 COMPONENTES DE DWDM	37
2.4.1.1 Filtros ópticos sintonizáveis	37
2.4.1.2 Multiplexadores e Demultiplexadores	37
2.4.1.3 Multiplexadores e Filtros de Adição-Extração	40
2.4.1.4 Acopladores-Estrela.....	41
2.4.1.5 Roteadores por comprimento de onda.....	42
2.5 AMPLIFICADORES ÓPTICOS	42
2.5.1 AMPLIFICADORES A FIBRA DOPADA COM ÉRBITO	43
2.5.1.1 Ganho do amplificador	43
2.5.1.2 Ruído do amplificador	46

2.6 APRENDIZADO DE MÁQUINA (ML)	47
2.6.1 APRENDIZADO SUPERVISIONADO	47
2.6.1.1 Boosted Decision Tree Regression (BDTR)	48
2.6.1.2 Histogram Gradient Boosting Regression (HGBR)	50
2.6.1.3 Decision Forest Regression (DFR)	50
2.6.2 APRENDIZADO NÃO SUPERVISIONADO	51
3 METODOLOGIA	52
3.1 CONFIGURAÇÃO DA REDE E COLETA DE DADOS	52
3.1.1 REDE ÓPTICA REAL	52
3.1.2 LEVANTAMENTO DOS DADOS	53
3.2 ANÁLISE E TREINAMENTO DOS DADOS	55
3.2.1 COEFICIENTE LINEAR DE PEARSON	55
3.2.2 TREINAMENTO DA BASE DE DADOS	56
4 RESULTADOS E DISCUSSÕES	58
4.1 SIMULAÇÕES DO OPTISYTEM	58
4.1.1 GANHO TOTAL DOS BOMBEAMENTOS EXTREMOS E MÉDIOS	58
4.1.2 POTÊNCIA TOTAL DOS BOMBEAMENTOS EXTREMOS E MÉDIOS	59
4.1.3 MÍNIMO BER DOS BOMBEAMENTOS EXTREMOS E MÉDIOS	59
4.1.4 MÁXIMO QFATOR DOS BOMBEAMENTOS EXTREMOS E MÉDIOS	60
4.1.5 MELHORES PARÂMETROS DE SAÍDA	61
4.2 ANÁLISE DE CORRELAÇÃO	62
4.2.1 GANHO TOTAL	62
4.2.2 POTÊNCIA TOTAL	62
4.2.3 MÁX. QFATOR	63
4.2.4 MÍNIMO BER	64
4.3 TREINAMENTO DOS MODELOS	65
4.3.1 GANHO TOTAL	65
4.3.2 POTÊNCIA TOTAL	66
4.3.3 MÁXIMO QFATOR	67
4.3.4 MÍNIMO BER	69
4.4 COMPARAÇÃO ENTRE OS VALORES SIMULADOS E TREINADOS	71
4.4.1 GANHO TOTAL DOS BOMBEAMENTOS EXTREMOS E MÉDIOS	71
4.4.2 CURVAS CONSOLIDADAS DO GANHO TOTAL DOS BOMBEAMENTOS EXTREMOS E MÉDIOS	72
4.4.3 POTÊNCIA TOTAL DOS BOMBEAMENTOS EXTREMOS E MÉDIOS	73

4.4.4	CURVAS CONSOLIDADAS DO POTÊNCIA TOTAL DOS BOMBEAMENTOS EXTREMOS E MÉDIOS	73
4.4.5	MÁXIMO QFATOR DOS BOMBEAMENTOS EXTREMOS E MÉDIOS	75
4.4.6	CURVAS CONSOLIDADAS DO MÁXIMO QFATOR DOS BOMBEAMENTOS EXTREMOS E MÉDIOS	76
4.4.7	MÍNIMO BER DOS BOMBEAMENTOS EXTREMOS E MÉDIOS	77
4.4.8	CURVAS CONSOLIDADAS DO MÍNIMO BER DOS BOMBEAMENTOS EXTREMOS E MÉDIOS	77
4.4.9	COMPARAÇÃO SIMULADO X TREINADO PARA OS MELHORES PARÂMETROS DE SAÍDA	79
5	CONCLUSÕES	81
	REFERÊNCIAS	82
	APÊNDICE A – MÍNIMO BER PARA OS BOMBEAMENTOS EXTREMOS E MÉDIOS	84
	APÊNDICE B - MÁXIMO QFATOR PARA OS BOMBEAMENTOS EXTREMOS E MÉDIOS.....	85

1 INTRODUÇÃO

O volume de tráfego móvel vem crescendo rapidamente, e com o advento do 5G e da internet das coisas (IoT - *internet of things*) esse aumento será exponencial. A estimativa é que o tráfego móvel chegará a 5016 exabytes (EB) em 2030, conforme ITU-R M.2370-0 (2015). A rede óptica é a infraestrutura cabeada que suportará a transmissão de dados durante essa evolução das comunicações, e as redes de *backbone*, em conjunto com os *data centers*, serão a espinha dorsal que suportará esse processo, já a tecnologia de multiplexação por divisão de comprimento de onda (WDM - *Wavelength Division Multiplexing*) será o suporte de transmissão para a exploração de grande largura de banda oferecida por fibras ópticas.

A inteligência artificial se encontra sendo amplamente explorada em diversos campos da ciência, incluindo, dessa forma, o âmbito das Telecomunicações. Estudar fibras por simulação numérica tem suas limitações e custo computacional temporal demorado, levando a difundirmos dessa forma, como uma das soluções, o uso de algoritmos que fornecerão soluções viáveis sem a necessidade de estudar todos os cenários possíveis. Suas aplicações estão difundidas em diferentes campos de estudo, como por exemplo, sistemas de comunicações ópticas.

Considerando que há a necessidade de estudo do aprimoramento da rede de comunicações ópticas e as novas aplicações de inteligência artificial para solução de problemas, abre-se espaço para esse e novos estudos. Dessa forma, este trabalho irá analisar o uso de aprendizado de máquina para treinar bases de dados usando os algoritmos de *Boosted Decision Tree Regression* (BDTR), *Decision Forest Regression* (DFR) e *Histogram Gradient Boosting Regression* (HGBR).

Para manter o acordo de nível de serviço entre o usuário e o provedor do serviço é necessário manter a qualidade de transmissão (QoT - *Quality of Transmission*), portanto técnicas de previsão de QoT são geralmente usadas para garantir a qualidade dos caminhos de luz, podendo ser utilizado o método analítico que levará em conta a maioria das deficiências físicas que são complexas, precisas, mas são computacionalmente pesados demais para serem apropriados para dinâmicas de tempo real, ou utilizando fórmulas de alta margem, que irá onerar o projeto final levando à subutilização dos recursos da rede. Com o progresso da aprendizagem de máquina (ML – *Machine Learning*) e da rede definida por software (SDN – *software defined networking*) um espaço para outra abordagem para a análise da qualidade da

rede é vislumbrado. O trabalho publicado em 2022 pelos autores C. Manso et al. (2022) demonstrou uma arquitetura nativa em nuvem, com sua escalabilidade avaliada através de diferentes preditores de ML e validada experimentalmente em uma rede de tecnologia WDM.

As crecentes demandas de tráfego fazem com que as operadoras de rede busquem soluções que visem melhorar a capacidade de transmissão óptica e suas velocidades, portanto as abordagens de rede definidas por *software* para controle de gerenciamento de rede WDM se encontra em plena expansão. No trabalho desenvolvido pelos autores A. D’Amico et al. (2021) foi proposta a utilização de um algoritmo de aprendizado de máquina (ML) treinado usando diferentes cargas espectrais em forma de emissão espontânea amplificada (ASE – *amplified spontaneous emission*) para prever o componente da relação sinal ruído (SNR – *signal to noise ratio*), pois, em geral, o ASE é o principal contribuinte para o SNR e o mais desafiador para avaliar em um cenário com cargas espectrais variadas devido às flutuações nas respostas do amplificador óptico; esse trabalho utilizou um experimento em um sistema de linha óptica ponto a ponto, incluindo nove (09) amplificadores de fibra dopada com érbio (EDFA), cada um com valores variáveis de ganho e inclinação, e oito (08) fibras que são caracterizadas por parâmetros físicos distintos.

R. Rudra et al. (2015) apresentaram dados extraídos por simulação utilizando o *software Optisystem* que é o mesmo simulador óptico utilizado neste trabalho. No estudo de R. Rudra et al. (2015) foram analisados os parâmetros de entrada, tais como, frequência, espaçamento de frequência, taxa de bits e comprimento da fibra do sistema de multiplexação de comprimento de onda denso (DWDM – *Dense Wavelength Division Multiplexing*), prevendo com precisão parâmetros de saída, como Fator de qualidade (Qfator), taxa de erro de bit (BER – *bit error rate*), altura e valor limite, usando 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.

L. Zhang et al. (2022) desenvolveram um trabalho que fornece uma visão geral das aplicações das tecnologias de aprendizado de máquina (ML) na previsão de qualidade de transmissão (QoT), onde foram apresentados os principais fatores de influência de QoT, bem como suas métricas e estratégias. Posteriormente foram apresentados os algoritmos de ML, suas estruturas e a construção do modelo de previsão de QoT foram brevemente demonstrados.

1.1 OBJETIVOS

Tomando como ponto de partida os argumentos e explicações previamente citados, serão apresentados os objetivos relacionados à presente pesquisa.

1.1.1 Objetivo Geral

O objetivo desta dissertação de mestrado é avaliar a possibilidade de uso de técnicas de inteligência artificial para modelagem de redes de comunicações ópticas com foco em simplificar a análise multiparamétrica para melhoria da rede.

1.1.2 Objetivos Específicos

- Simular uma rede óptica utilizando o *software OptiSystem* e avaliar os parâmetros de entrada, potência do WDM e potência dos bombeamentos dos amplificadores de fibra dopada por érbio (EDFA), correlacionando estes, com os parâmetros de saída: potência total, ganho total, máximo Qfator e mínimo BER;
- Avaliar algoritmos de aprendizagem de máquina para correlacionar os parâmetros de entrada aos parâmetros de saída;
- Analisar o algoritmo que obteve melhor desempenho para cada alvo: potência total, ganho total, máximo Qfator e mínimo BER;
- Avaliar se, utilizando apenas os parâmetros de entrada com foco em gerenciamento de perdas, os algoritmos de inteligência artificial terão eficiência para todos os parâmetros de saída.

1.2 ORGANIZAÇÃO DA DISSERTAÇÃO

Esta dissertação está 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 e descreve os efeitos lineares e não lineares atuantes nesta. Também será apresentada a base conceitual dos transmissores e receptores ópticos. Será apresentada a técnica WDM e o detalhamento dos principais componentes que foram desenvolvidos pra implementar essa nova tecnologia, além do descritivo dos fundamentos da amplificação óptica e do detalhamento referente ao aprendizado de máquina.

Em seguida, no Capítulo 3, é apresentada a metodologia. Foi 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 são apresentados os resultados em forma de gráficos e tabelas relativas às coletas de dados simulados no *OptiSystem* e posteriormente esses dados são usados no treinamento do aprendizado de máquina utilizando os algoritmos de *Boosted Decision Tree Regression* (BDTR), *Decision Forest Regression* (DFR) e *Histogram Gradient Boosting Regression* (HGBR).

O Capítulo 5 descreve as considerações finais e uma conclusão geral, ressaltando as principais contribuições deixadas durante este trabalho de mestrado. Por fim, sugestões para trabalhos futuros são apresentadas.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo serão abordados os efeitos lineares e não lineares que ocorrem nas fibras ópticas. Também será apresentada a base conceitual dos transmissores e receptores ópticos. Será apresentada a técnica WDM e o detalhamento dos principais componentes que foram desenvolvidos pra implementar essa nova tecnologia, além do descritivo dos fundamentos da amplificação óptica e o detalhamento referente à aprendizagem de máquina que é um ramo da inteligência artificial.

2.1 FIBRA ÓPTICA

A invenção do laser (*light amplification by stimulated emission of radiation*) possibilitou desenvolver novos meios para usar a luz para transmissão de dados. Em 1970 a perda em fibras ópticas foi reduzida possibilitando sua utilização para comunicação; em 1979 houve novo progresso quando a perda atingiu apenas 0,2 dB/km levando a revolução na tecnologia de ondas luminosas, o que desencadeou a era da comunicação por fibras ópticas (AGRAWAL, 2010).


Antes da chegada da década de 70, as fibras eram inicialmente utilizadas na obtenção de imagens médicas em curtas distâncias (DUTTA; STROSCIOS, 2000). Cada vez mais se necessita que os dados sejam transmitidos e processados com maiores taxas e com mais segurança, e com o avanço das fibras ópticas isto vem tornando-se realidade, visto que o sinal transportado em seu núcleo são pulsos de ondas eletromagnéticas.

Fibras ópticas são produzidas primariamente a partir de sílica, o que torna sua estrutura com características dielétricas. Possuem um núcleo e uma casca que os revestem com índice de refração diferente, ou seja, o índice de refração do núcleo é maior que o da casca, o que torna possível o confinamento da luz, fenômeno conhecido como reflexão interna total. Para que ocorra tal fenômeno, a luz deve sair de um meio com índice de refração maior para um meio com menor índice de refração, e o ângulo de incidência deve ser superior ao ângulo crítico (medido em relação à interface do núcleo e seu revestimento) permitindo que um raio de luz sofra sucessivas reflexões (GONÇALVES, 2012).

A diferença entre índices de refração é realizada com a dopagem do núcleo ou da casca ou de ambos com material apropriado. Dopantes como dióxido de germânio e pentóxido de

fósforo (GeO_2 e P_2O_5) aumentam o índice de refração da sílica e são adequados para o núcleo. Por sua vez, dopantes como trióxido de boro (B_2O_3) e flúor diminuem o índice de refração da sílica e são adequados à casca (AGRAWAL, 2010). Além do núcleo e da casca, as fibras são revestidas por material externo polimérico, filme metálico ou acrilato, os quais servem para isolar e proteger o material vítreo, chamado de capa, como pode-se visualizar na Figura 1.

Figura 1 - Desenho esquemático de uma fibra óptica.




Fonte: Modificada de PADTEC (2019)

As fibras ópticas são classificadas de acordo com os modos de propagação. O número de modos da fibra está diretamente relacionado com o diâmetro do núcleo e inversamente proporcional ao comprimento de onda utilizado (TRONCO; ÁVILA, 2007). Quanto aos modos, as fibras são classificadas da seguinte maneira:

- Monomodo: As fibras monomodo, Figura 2, suportam apenas um modo de propagação, ou seja, os raios de luz percorrem o interior da fibra por um só caminho, tendo com isso o núcleo reduzido (AGRAWAL, 2002). Por possuírem suas dimensões mais reduzidas, essas têm sua fabricação mais complexa; no que diz respeito à banda passante, mais larga, essa fibra tem característica superior às fibras multimodo, pois as monomodo aumentam a capacidade de transmissão, apresentam atenuação mais baixa, expandindo com isso a distância entre as transmissões sem o uso de repetidores.


Figura 2 - Desenho esquemático de uma fibra óptica monomodo.



Fonte: Modificada de PADTEC (2019)

- Multimodo: O pulso luminoso de entrada excita vários modos de propagação, pois este tipo de fibra, vista na Figura 3, possui um diâmetro de núcleo maior em comparação com as fibras monomodo, desta forma, a luz pode se propagar por diferentes caminhos. A fonte de luz utilizada geralmente são diodos emissores de luz (LED - *Light Emitting Diode*).

Figura 3 - Desenho esquemático de uma fibra óptica multimodo.



Fonte: Modificada de PADTEC (2019)

O sinal transmitido por uma fibra sofre com alguns fenômenos que são inerentes à propagação deste em um meio dielétrico, como por exemplo, efeitos não lineares e efeitos lineares. Serão descritos alguns desses efeitos em seguida.

O termo dispersão é utilizado para descrever o efeito de alargamento dos pulsos que se propagam pelas fibras e pode-se classificá-las como: dispersão modal, dispersão cromática e dispersão por modo de polarização. A dispersão é responsável por causar distorção digital e analógica do pulso de entrada ao longo do caminho óptico. Os mecanismos de dispersão causam um aumento da largura temporal dos pulsos luminosos à medida que se propagam pelo canal. Cada pulso é ampliado sobrepondo-se aos pulsos vizinhos, tornando-se indistinguíveis na saída da fibra e a largura de banda máxima é limitada pela dispersão causada no sinal (SENIOR, 2009).

2.1.1 Dispersões em fibras ópticas

Neste tópico serão expostas as dispersões que afetam uma fibra óptica.


2.1.1.1 Dispersão Modal

A dispersão modal é causada pela diferença dos tempos de propagação dos diferentes modos. Esta dispersão é a ampliação do pulso luminoso que ocorre apenas em fibras multimodo, pois é resultado das diferenças no atraso de propagação entre os modos no seu interior. Devido às diferentes velocidades (v) dos modos com índice de refração (n) distinto, onde (c) é a velocidade da luz no vácuo. Observa-se na Figura 4 o processo da dispersão da luz em seus diferentes modos (m), pois cada modo possui índice de refração diferente e terá velocidade divergente ao percorrer variações de tempo (T) em distância (L) (GONÇALVES, 2012).

$$v = \frac{c}{n} \quad (2.1)$$

Em fibras puramente monomodo não ocorre este tipo de dispersão, portanto, o alargamento dos pulsos nestas se deve aos efeitos de dispersão cromática, os quais serão descritos mais adiante.

Figura 4 - Diagrama do processo de dispersão da luz.



Fonte: Autora.

Desta forma, quando diferentes raios viajam por percursos de diferentes comprimentos, na saída da fibra esses raios se dispersam no tempo, ainda que coincidam na entrada e viajem com a mesma velocidade ao longo da fibra. Um pulso curto (chamado de impulso), por outro lado, se alargaria consideravelmente devido aos diferentes comprimentos de percursos. Sendo assim, estima-se o alargamento temporal dos pulsos considerando os raios que viajam pelos percursos de menor e de maior comprimento, este alargamento do pulso

de saída limitará a taxa de transmissão devido à necessidade de distanciar um pulso do outro para evitar a taxa de erro (BER) (AGRAWAL, 2010).

2.1.1.2 Dispersão Cromática

Esta dispersão, também conhecida como dispersão por velocidade de grupo (GVD - *group velocity dispersion*), está dividida em dois tipos: dispersão material e dispersão do guia de onda. Trata-se do resultado da largura de linha espectral finita da fonte óptica, pois, como as fontes ópticas não emitem uma única frequência, mas uma banda de frequências distintas, pode haver uma defasagem entre os sinais de propagação com relação aos diferentes componentes espectrais do sinal transmitido. Essa diferença no atraso de propagação ocasiona o alargamento de cada modo transmitido na fibra (SENIOR, 2009).

A dispersão cromática também pode ser explicada pelo fato de que a relação do índice de refração da sílica (vidro) utilizado no núcleo da fibra ser dependente da frequência óptica.

Diferentes frequências que compõem o sinal, que têm diferentes índices de refração, irão variar suas velocidades ocasionando espaçamento do sinal de saída, esses efeitos ocorrem em fibra mono e multimodo, ocasionando a limitação da taxa de transmissão devido ao afastamento dos pulsos para evitar a taxa de erro (BER). A dispersão cromática quando ocorre em fibras monomodo, a energia do sinal é confinada em um único modo, no entanto, as diferentes componentes espectrais do pulso viajam com velocidades ligeiramente diferentes, daí o nome, velocidade de grupo (AGRAWAL, 2010).

2.1.1.3 Dispersão por modo de polarização

Uma potencial fonte de alargamento temporal de pulsos está relacionada à birrefringência da fibra que é ocasionada por pequenos desvios da perfeita simetria cilíndrica devido aos diferentes índices modais associados às componentes de polarizações ortogonais do modo fundamental da fibra. Ao excitar as duas componentes de polarização, o pulso de entrada se alargará à medida que as duas componentes se dispersam ao longo da fibra devido às diferentes velocidades de grupo. A dispersão por modo de polarização ou PMD se torna um fator limitante para sistemas de ondas luminosas projetados para operação em longas distâncias e altas taxas de bits (AGRAWAL, 2010).

2.1.2 Atenuação

Outro fator limitante do desempenho de sistemas de comunicações são as perdas em fibras, pois reduzem a potência do sinal que chega ao receptor e este requer certa quantidade mínima de potência para a recuperação do sinal ao final do caminho percorrido, assim, a distância de transmissão é limitada por essas perdas (AGRAWAL, 2010).

O coeficiente de atenuação (α) pode ser obtido utilizando a lei de Beer:

$$\frac{dP}{dz} = -\alpha P, \quad (2.2)$$

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

$$P_{out} = P_{in} \exp(-\alpha L), \quad (2.3)$$

O coeficiente de atenuação será expresso em unidades de dB/km usando a relação:

$$\alpha \left(\frac{dB}{km} \right) = -\frac{10}{L} \log_{10} \left(\frac{P_{out}}{P_{in}} \right) \cong 4.343\alpha. \quad (2.4)$$

Sendo este o principal parâmetro para perdas de sinal em fibras.

2.1.3 Efeitos não lineares

Detalha-se nesse momento, os efeitos não lineares que afetam a fibra óptica.

2.1.3.1 Espalhamento estimulado de luz

Pode-se ter espalhamento elástico em que a frequência da luz espalhada permanece inalterada, tendo como exemplo o espalhamento Rayleigh e há o espalhamento inelástico onde a frequência da luz espalhada é deslocada para baixo, tendo como exemplos o espalhamento Raman e espalhamento Brillouin, os quais podem ser entendidos como o espalhamento de um fóton para um fóton de menor energia. Os processos de espalhamento resultam em uma perda de potência na frequência incidente. Entretanto, as correspondentes seções retas de espalhamento

são suficientemente pequenas para que, em baixos níveis de potência, a perda seja desprezível (AGRAWAL, 2010).

2.1.3.2 Modulação de fase não linear

Em altas intensidades todos os materiais possuem comportamento não linear e seus índices de refração aumentam com a intensidade, sendo a resposta inarmônica de elétrons a campos ópticos, resultando em uma suscetibilidade não linear. Esses fenômenos levam à automodulação de fase que é o próprio pulso gerando novas frequências e se modulando. Com isso o pulso se contrai tornando-se mais estreito no tempo, compensando assim o efeito da dispersão que é o alargamento temporal do pulso. Há ainda a modulação de fase cruzada definida quando há interferência de um canal em outro, sendo conhecida também como colisão de canais. (AGRAWAL, 2010).

2.1.3.3 Mistura de quatro ondas

Esse fenômeno conhecido como FWM – *Four Wave Mixing* ocorre quando três campos ópticos com frequências distintas irão gerar outro campo óptico cuja frequência está relacionada às outras frequências que o geraram. FWM também pode ser útil para sistemas de ondas luminosas e muitas vezes é usado para demultiplexação de canais individuais, quando multiplexação por divisão no tempo é usada no domínio óptico (AGRAWAL, 2010).

2.2 TRANSMISSORES ÓPTICOS


A fibra é utilizada como canal de comunicação que recebe o sinal já convertido pelo transmissor óptico, em que a conversão de elétrico para óptico é o principal papel deste. As fontes ópticas utilizadas pelas comunicações ópticas são os diodos emissores de luz (LED – *Light Emitting Diode*) e *lasers* de semicondutor. O LED é uma luz não coerente por emissão espontânea e possui largura do espectro larga, enquanto o *Laser* é a amplificação de luz coerente por emissão estimulada de radiação e possui largura do espectro estreita (AGRAWAL, 2010).

2.2.1 Emissões Espontânea e Estimulada

A emissão segue-se quando um átomo que está no estado excitado retorna ao estado básico, emitindo um fóton de luz, fenômeno que ocorre por dois processos chamados de emissão espontânea e estimulada. No caso de emissão espontânea, este terá mesmo comprimento de onda, entretanto, não terá a mesma frequência, fase, polarização e irá gerar ruído no sinal de saída. Em contraponto, a emissão estimulada é iniciada por um fóton existente chamado de fóton estimulante que ocasionará um fóton gêmeo, com mesmo comprimento de onda, frequência, fase e polarização (AGRAWAL, 2010).

A diferença de energia entre E2 e E1 irá gerar o fóton. Os processos ocorridos entre os estados de energia do átomo podem ser vistas na Figura 5.

Figura 5 - Esquematização dos processos de emissão espontânea e estimulada.




Fonte: Autora

Em um laser de semicondutor há a formação de bandas de energia que são geradas quando se fundem os níveis individuais de energia com associação de um único átomo, essas bandas são as de valência e de condução, representam a banda mais elevada preenchida com elétrons e a primeira banda que contém poucos elétrons. Quando alguns dos elétrons forem elevados à banda de condução por meio de bombeamento elétrico, os estados vazios deixados na banda de valência representam as lacunas (AGRAWAL, 2010).

A luz é formada quando há a recombinação que é o processo quando um elétron próximo do fundo da banda de condução se recombina com uma lacuna na banda de valência. Nessa representação foi utilizado um diagrama $E - k$, sendo $k = p/\hbar$ o número de onda de um elétron com momento p e energia E . O fóton emitido nesse processo de recombinação transporta energia $h\nu \cong E_g$ em que E_g é banda proibida de energia (*bandgap*) do semicondutor conforme Figura 6.

Figura 6 - Modelo de bandas da emissão de um fóton.



Fonte: Modificada de AGRAWAL (2010)

2.2.2 Geração do sinal óptico

Em um sistema de comunicação óptica é necessária a conversão do sinal elétrico em sinal óptico com a mesma informação original. Mesmo que os sinais elétricos estejam na forma analógica, estes serão invariavelmente transformados para uma representação em uma sequência de bits digitais nos formatos com retorno ao zero (RZ – *return to zero*) ou sem retorno ao zero (NRZ – *nonreturn to zero*) que são uma sequência de bits 0 e 1. Há duas técnicas conhecidas para gerar essa sequência de bits ópticos que são modulação direta ou externa.

Na modulação direta o próprio laser é polarizado próximo ao limiar e excitado pela sequência de bits elétricos, aumentando com isso consideravelmente a corrente aplicada acima do limiar do laser para criar pulsos ópticos que representam bits digitais, o qual é a forma mais fácil de carregar informação em uma portadora óptica. Entretanto, a principal desvantagem dos *lasers* modulados diretamente para distâncias grandes e altas taxas de transmissão é a modulação de fase residual que acompanha a modulação de intensidade desejada levando, dessa forma, à distorção do sinal (AGRAWAL, 2010).

Com relação à modulação externa, esta possui melhor desempenho para largura de bandas maiores e é, todavia, mais complexa e custosa. O esquema de modulação externa é constituído por um transmissor de elevada velocidade, onde o *laser* é alimentado por uma corrente constante de forma a gerar na saída uma onda contínua (CW – *continuous wave*)

que irá ser recebida pelo modulador óptico externo cujas propriedades ópticas podem ser modificadas por um campo elétrico aplicado externamente (AGRAWAL, 2010).

O formato de representação dos bits analógicos em digitais pode ser feito de duas maneiras: com o retorno ao zero (RZ – *Return to zero*) ou sem o retorno ao zero (NRZ – *No return to zero*). Na codificação RZ, cada pulso óptico é mais curto do que a largura do bit slot, e sua amplitude volta a zero antes que acabe a duração do bit. Na codificação NRZ, o pulso óptico permanece em 0 ou 1 em toda a duração do bit, e sua amplitude não retorna a zero entre dois ou mais bits 1 seguidos. Em consequência, a largura do pulso é variada dependendo da sequência de bits. No formato RZ, a largura dos pulsos é constante. Na codificação RZ os pulsos são mais estreitos no tempo e consequentemente mais largo na frequência, já para a codificação NRZ têm-se pulsos mais largos no tempo e mais estreitos na frequência. O formato NRZ é usado com maior frequência na prática, devido a menor largura de banda. No trabalho desenvolvido foi utilizado o gerador de pulsos NRZ (AGRAWAL, 2010).

2.3 RECEPTORES ÓPTICOS

A função de um receptor óptico é converter o sinal óptico de volta à forma elétrica recuperando os dados que foram transmitidos através do sistema óptico. O principal componente do receptor é um fotodetector, que converterá a luz em eletricidade por meio do efeito fotoelétrico. O receptor deverá ter alta sensibilidade, baixo ruído, alta confiabilidade, além de baixo custo e ter dimensões compatíveis com as do núcleo da fibra (AGRAWAL, 2010).

O mecanismo fundamental responsável pelo processo de fotodetecção é a absorção óptica. Além do fotodetector, outros elementos essenciais, como o pré-amplificador, estão presentes para o processamento do sinal.

Há dois métodos de detecção óptica que são com receptores não coerentes e receptores coerentes, existindo assim duas técnicas principais para detectar o sinal transmitido, receptores por detecção direta e receptores por detecção coerente (homódina e heteródina).

A detecção direta é um processo que basicamente capta o número de fótons, ao detectar o sinal óptico incidente e posteriormente converte-o num sinal elétrico, já na detecção coerente, o sinal de entrada é combinado com uma portadora ótica gerada por um

oscilador local (LO – *Local Oscillator*), um *laser* de pequena largura espectral que funciona como um amplificador óptico (AGRAWAL, 2010).

2.4 WDM


Um sistema monocanal caracteriza-se pela existência de uma portadora óptica que trafega por um par de fibra. Já o desenvolvimento de sistema multicanal, onde várias portadoras ópticas em diferentes comprimentos de onda são moduladas e transmitidas em uma mesma fibra, se desenvolveu a partir 1990 e sistemas WDM tornaram-se disponíveis comercialmente em 1996 (AGRAWAL, 2010).

A técnica WDM (*Wavelength Division Multiplexing*) permite a exploração de grande largura de banda oferecida por fibras ópticas por meio da multiplexação por divisão de comprimento de onda denso (DWDM), uma subdivisão do WDM que tem suas grades espectrais definidas pela recomendação do ITU-T G.694.1 (ITU-T, 2020), a qual suporta uma variedade de espaçamentos de canal fixo, variando de 12,5 GHz a 100 GHz ou mais largos (múltiplos inteiros de 100 GHz), bem como uma grade flexível. Pode-se ter 80 canais com espaçamento entre eles de 100 GHz (0,8 nm), sendo 40 canais na banda C e 40 canais na banda L e simultaneamente haverá acréscimo de canais de acordo com o referido espaçamento.

É possível verificar a topologia simplificada de uma rede DWDM na Figura 7, onde as saídas de vários transmissores, cada um operando em sua própria frequência portadora (ou comprimento de onda), são multiplexados e enviados por uma única fibra para outra extremidade, em que um demultiplexador envia cada canal ao seu receptor.

Os sistemas DWDM usam na transmissão um grande número de *lasers* cujas frequências são escolhidas para combinar precisamente com a grade de frequências do ITU-T G.694.1 (ITU-T, 2020). Pode-se ter *lasers* com frequência fixa ou sintonizável, atualmente os mais utilizados juntamente com um multiplexador.


Figura 7 - Topologia simplificada de uma rede DWDM.



Fonte: Modificada de PADTEC (2019)

Na recepção, são utilizados fotodiodos em conjunto com um demultiplexador, que pode ser visualizado na Figura 8 o esquema simplificado de transmissor e receptor que compõem uma placa chamada de Transponder. Entre as principais funções de um transponder está a de conversão de um sinal óptico de entrada (cliente) nas janelas ópticas de 850, 1310 ou 1550 nm para um sinal digital óptico de saída (rede) em um dos canais da grade DWDM (janela de 1550 nm) utilizando a modulação NRZ ou RZ.

Figura 8 - Processo de transmissão e recepção do sinal.



Fonte: Autora

2.4.1 Componentes de DWDM

A tecnologia para sistemas de comunicações por fibra óptica DWDM demanda diversos componentes, dentre os quais são destacados os multiplexadores que combinam as saídas de vários transmissores e lançam o sinal combinado em uma única fibra óptica; os demultiplexadores, que separam o sinal multicanal recebido em canais individuais, destinados a diferentes receptores; os acopladores-estrela, que mixam as saídas de vários transmissores e difundem o sinal mixado a múltiplos receptores; os filtros ópticos sintonizáveis, que separam um canal em um específico comprimento de onda, que pode ser alterado por sintonia de banda passante por filtro óptico; os multiplexadores de adição-extração (*add-drop*) e os roteadores ópticos capazes de distribuir um sinal a diferentes portas. Esses principais componentes serão explanados a seguir (AGRAWAL, 2010).

2.4.1.1 Filtros ópticos sintonizáveis

O papel de um filtro óptico sintonizável em um sistema DWDM é o de selecionar um canal desejado no receptor, onde a largura de banda do filtro deve ser grande para transmitir o canal desejado e pequena para bloquear canais vizinhos. Todos os filtros ópticos requerem um mecanismo de seleção de comprimento de onda e são classificados em duas grandes categorias, se tem interferência ou difração óptica e o mecanismo físico em que são baseados.


Cita-se alguns tipos de filtros, tais como: filtro de Fabry-Perot; filtro de Mach-Zender, filtro de Michelson e filtro acusto-óptico. As propriedades comuns nos filtros ópticos sintonizáveis são a grande faixa de sintonia, maximizando dessa forma o número de canais a serem selecionados, a interferência desprezível para que não haja interferência de canais adjacentes, a alta velocidade de sintonia, minimizando o tempo de acesso, a pequena perda de inserção, a estabilidade contra mudanças ambientais, o baixo custo e a insensibilidade à polarização (AGRAWAL, 2010).

2.4.1.2 Multiplexadores e Demultiplexadores

Multiplexadores e demultiplexadores são os componentes fundamentais em qualquer sistema de comunicação óptica DWDM, visto que serão esses que irão realizar a função que definiu a evolução da tecnologia multicanal, que é o envio de várias portadoras por uma mesma fibra óptica, aumentando dessa maneira a capacidade de transmissão. O

multiplexador irá acoplar todos os canais (comprimentos de onda) que serão transmitidos pela mesma fibra óptica. Visualiza-se na Figura 9 o esquema básico demonstrando a funcionalidade deste componente.


Figura 9 - Esquema de funcionamento de Multiplexadores.



Fonte: Modificada de PADTEC (2019)

A Figura 10 ilustra o conceito básico e mostra a configuração de um multiplexador de quatro canais, que consiste em três interferômetros Mach-Zender. Um braço de cada interferômetro é maior do que o outro para prover uma defasagem dependente de comprimento de onda entre eles. Uma porta de saída irá conter a potência de entrada total das duas portas em diferentes comprimentos de onda devido à diferença de percurso escolhida para esse fim (AGRAWAL, 2010).


Figura 10 - Configuração de um multiplexador de quatro canais.



Fonte: Modificada de AGRAWAL (2010)

Demultiplexadores fazem exatamente o inverso, ou seja, recebem todos os canais (comprimentos de onda) em sua entrada e na saída do módulo, por sua vez, todos os canais são igualmente separados (demultiplexados), Figura 11.


Figura 11 - Esquema de funcionamento de Demultiplexadores.



Fonte: Modificada de PADTEC (2019)

Há demultiplexadores baseados em difração que empregam um elemento com dispersão angular, como uma grade de difração, que dispersa a luz incidente espacialmente nos vários comprimentos de onda componentes, utilizando o fenômeno de difração de Bragg em uma grade de difração, como exemplifica a Figura 12, através do uso de uma lente convencional. Para os demultiplexadores baseados em interferências são utilizados dispositivos como filtros e acopladores direcionais ópticos (AGRAWAL, 2010).

Figura 12 - Esquema de um demultiplexador baseado em grade de difração, com uso de lente convencional.




Fonte: Modificada de AGRAWAL (2010)

2.4.1.3 Multiplexadores e Filtros de Adição-Extração

Os Multiplexadores de adição-extração são necessários em sites nos quais um ou mais canais precisam ser extraídos ou adicionados, sem alterar a integridade dos demais canais que trafegam na rota. O multiplexador de adição-extração óptico reconfigurável (ROADM – *Reconfigurable Optical Add-Drop Multiplexer*) contém um banco de comutadores ópticos entre um par demultiplexador-multiplexador, onde o demultiplexador irá separar todos os canais, comutar opticamente, extrair, adicionar ou passar canais individuais e o multiplexador irá combinar o sinal completo novamente e amplificar o sinal óptico e equalizar as potências dos canais, o esquemático pode ser observado na Figura 13 (AGRAWAL, 2010).

Podem ainda ser utilizadas grades de difração de Bragg para realizar filtros de adição- extração, onde a grade será fabricada na parte central de um acoplador direcional, ou circuladores ópticos que são empregados em combinação com a grade de difração em fibra.

Figura 13 - Esquema de um multiplexador de adição-extração baseado em comutadores ópticos.




Fonte: Modificada de AGRAWAL (2010)

2.4.1.4 Acopladores-Estrela

Os acopladores-estrela têm como função combinar os sinais ópticos que entram em suas portas de entrada e dividi-los igualmente em suas portas de saída. Não é fundamental que o número de entradas seja igual ao número de saídas (AGRAWAL, 2010). Um acoplador 50/50 terá a funcionalidade de realizar proteção de uma rota, pois irá distribuir o sinal óptico pelas duas vias ópticas fazendo, com isso, a função de proteção da rota principal, um esquemático de proteção de rota pode ser percebido conforme Figura 14.

Figura 14 - Representação esquemática de proteção de rota.



Fonte: Autora

2.4.1.5 Roteadores por comprimento de onda

Os roteadores por comprimento de onda são dispositivos passivos, combinam a funcionalidade de um acoplador-estrela com operações de multiplexação e demultiplexação. Supondo um roteador de $N \times N$ (entradas/saídas), verifica-se que os sinais que chegam pelas N portas de entrada são demultiplexados nos canais individuais e direcionados às N portas de saída do roteador de modo que o sinal WDM em cada porta seja composto de canais que chegam por diferentes portas de entrada. Uma variação desses roteadores é o WGR (roteador de grade de guia de onda) e corresponde a um roteador com grau integrado em um guia de onda. Neste caso, tem-se um acoplador estrela $N \times M$ distribuindo igualmente a potência de N canais de entrada para M portas de saída. Uma grade integrada ao guia de onda separa em seguida os diferentes canais seletivamente de acordo com o comprimento de onda e um outro acoplamento estrela $M \times N$ distribui os sinais demultiplexados para as N saídas do dispositivo. Desta maneira é possível distribuir o sinal vindo de N pontos da rede para outros N pontos, sendo o comprimento de onda o parâmetro de reconhecimento de distribuição. (AGRAWAL, 2010).

2.5 AMPLIFICADORES ÓPTICOS

Os amplificadores ópticos são capazes de amplificar múltiplos canais WDM simultaneamente e se tornaram a melhor solução perante a outra técnica de gerenciamento de perda disponível que utilizava regeneradores optoeletrônicos, em que era necessário inicialmente a conversão no domínio elétrico e depois a regeneração no domínio óptico, técnica cara para a tecnologia WDM. Os amplificadores ópticos foram desenvolvidos durante a década de 1980 e o uso em sistemas de comunicações ópticas se tornou comum durante a década de 1990. As perdas da fibra devem ser compensadas no sistema óptico geralmente para enlaces superiores a 100 km ou caso a qualidade do cabo óptico esteja com atenuação alta e o estudo para um determinado projeto demonstre necessidade de amplificação inferior a 100 km, devido aos efeitos cumulativos que terminam por deixar o sinal tão fraco que não é possível recuperar a informação no receptor (AGRAWAL, 2010).

Os amplificadores ópticos resolvem os problemas das perdas, entretanto, ao mesmo tempo, pioram o problema da dispersão, pois efeitos dispersivos se acumulam ao longo de toda a cadeia de amplificadores. Sistemas WDM de longas distâncias que fazem uso de amplificadores são, muitas vezes, limitados tanto por efeitos dispersivos e não

lineares quanto pelas perdas da fibra, e, na prática, é possível gerenciar o problema da dispersão por meio de compensadores de dispersão. Para esse trabalho foi objetivado o estudo das perdas ópticas e não no gerenciamento de dispersão (AGRAWAL, 2010).

Dependendo do esquema de amplificação empregado, classificam-se os amplificadores em duas categorias: concentrados ou distribuídos. Existem três tipos de amplificadores, os baseados em fibra dopada com érbio (EDFA – *Erbium Doped Fiber Amplifier*), os amplificadores Raman, que exploram o fenômeno não linear de espalhamento estimulado Raman (SRS – *stimulated raman scattering*), além dos amplificadores híbridos que utilizam as duas técnicas em um mesmo módulo (placa). Para o estudo dessa pesquisa foram utilizados os amplificadores EDFA que irão ser explicados com mais detalhes a seguir.

2.5.1 Amplificadores a Fibra Dopada com Érbio

Amplificadores ópticos EDFA são os preferidos para aplicações WDM devido a sua largura de banda ser grande e o ganho provido pelo EDFA ser praticamente insensível à polarização. Neste modelo de amplificador as propriedades como comprimento de onda de operação e largura de banda de ganho são determinadas por dopantes e a sílica desempenha papel de meio hospedeiro; o dopante mais utilizado para a fabricação de EDFA é o érbio e esses amplificadores revolucionaram a comunicação por fibra ótica (AGRAWAL, 2010).

O núcleo da fibra em um EDFA irá conter íons de érbio (Er^{3+}) e o bombeamento destes em um adequado comprimento de onda provê ganho óptico por meio de inversão de população, conforme já demonstrado na Figura 5. O espectro de ganho depende do esquema de bombeamento, assim como da presença de outros dopantes, como germânia e alumina no núcleo da fibra. A natureza amorfa da sílica alarga os níveis de energia de Er^{3+} em bandas (AGRAWAL, 2010).

2.5.1.1 Ganho do amplificador

O ganho de um amplificador EDFA tem vários parâmetros, tais como, concentração de íons de érbio, comprimento do amplificador, raio do núcleo e potência de bombeamento. Adapta-se o modelo de equação de taxa de três níveis utilizado por *lasers* e às vezes se faz necessário acrescentar um quarto nível incluindo a absorção de estado excitado.

É possível alcançar um considerável entendimento com o uso de um modelo de dois níveis, válido quando o ruído amplificado de emissão espontânea (ASE – *Amplified Spontaneous Emission*) e a absorção de estado excitado são desprezíveis. O modelo assumirá que o nível superior do sistema de três níveis permanece praticamente vazio, devido à rápida transferência da população bombeada para o estado excitado (AGRAWAL, 2010).

Considera-se as diferentes seções retas de emissão (σ^e) e de absorção (σ^a) para os campos de bombeio e de sinal. N_1 e N_2 são as densidades de população, na frequência ω_j , com $j = p, s$, satisfazendo as duas Equações 2.5 e 2.6 de taxa:

$$\frac{\partial N_2}{\partial t} = (\sigma_p^a N_1 - \sigma_p^e N_2) \phi_p + (\sigma_s^a N_1 - \sigma_s^e N_2) \phi_s - \frac{N_2}{T_1}, \quad (2.5)$$

$$\frac{\partial N_1}{\partial t} = (\sigma_p^e N_2 - \sigma_p^a N_1) \phi_p + (\sigma_s^e N_2 - \sigma_s^a N_1) \phi_s + \frac{N_2}{T_1}, \quad (2.6)$$

Onde T_1 é o tempo de vida espontâneo do estado excitado (da ordem de 10 ms para EDFAs) e as grandezas ϕ_p e ϕ_s representando o fluxo de fóton para as ondas de bombeamento e de sinal, definido como $\phi_j = P_j / (a_j h V_j)$, em que P_j é a potência óptica, σ^j é a seção reta de transição na frequência V_j e a_j é a área da seção reta do modo da fibra com $j = p, s$ (AGRAWAL, 2010).

As potências de bombeamento e de sinal irão variar ao longo do comprimento do amplificador, em função da absorção, da emissão estimulada e da emissão espontânea. Desprezando a contribuição da emissão espontânea, P_s e P_p , onde α e α' levarão em conta as perdas da fibra nos comprimentos de sinal e de bombeio e os fatores de confinamento Γ_s e Γ_p levam em conta o fato de a região dopada no núcleo prover ganho para todo o modo da fibra, portanto irão satisfazer as Equações 2.7 e 2.8:

$$\frac{\partial P_s}{\partial z} = \Gamma_s (\sigma_s^e N_2 - \sigma_s^a N_1) P_s - \alpha P_s, \quad (2.7)$$

$$s \frac{\partial P_p}{\partial z} = \Gamma_p (\sigma_p^e N_2 - \sigma_p^a N_1) P_p - \alpha' P_p, \quad (2.8)$$

O parâmetro assumirá valores +1 ou -1 dependendo do sentido de propagação da bomba, assumindo o valor $s = -1$, no caso de bombeamento contrapropagante (AGRAWAL, 2010).

As equações podem ser resolvidas, onde perdas da fibra, α e α' , podem ser tomadas como zero, visto que o comprimento da fibra é suficientemente curto. Percebe-se que $N_1 + N_2 = N_b$ e sendo N_t a densidade total de íons, pode-se resolver apenas a Equação 2.5, para N_2 . Observando que os termos de absorção e emissão estimulada nas equações de campo e população estão relacionados, a solução de estado estacionário da Equação 2.5, obtida igualando a derivada temporal a zero, sendo $a_d = \Gamma_s a_s = \Gamma_p a_p$ área da seção reta da porção dopada do núcleo da fibra será escrita conforme Equação 2.9:

$$N_2(z) = -\frac{T_1}{hV_s a_d} \frac{\partial P_s}{\partial z} - \frac{s T_1}{hV_p a_d} \frac{\partial P_p}{\partial z}, \quad (2.9)$$


Substituindo essa solução nas equações 2.7 e 2.8 e integrando-a no comprimento da fibra, as potências P_s e P_p na saída da fibra podem ser obtidas em forma analítica (AGRAWAL, 2010).

A abordagem descrita é essencial quando a potência de sinal total no interior do amplificador é suficientemente alta para causar saturação de ganho, entretanto no regime de pequeno sinal, em que o EDFA permanece saturado, pode ser desprezado o termo ϕ_p nas equações 2.5 e 2.6 e o coeficiente de ganho $g(z) = (\sigma_s^e N_2 - \sigma_s^a N_1)$ não depende da potência de sinal P_s . A equação 2.7 sendo integrada tem-se o ganho total do amplificador G para um EDFA de comprimento L fornecido pela Equação 2.10:

$$G = \exp \left[\Gamma_s \int_0^L [g(z) - \alpha] dz \right] \quad (2.10)$$

Verifica-se nas imagens da Figura 15 que o ganho do amplificador que inicialmente aumenta de forma exponencial com a potência de bombeamento, depois diminuirá quando a potência ultrapassar certo valor, fato explicado devido à última porção do amplificador permanecer sem bombeamento e absorver o sinal amplificado; ainda na Figura 15 mostra que é possível obter um ganho de 35 dB com potência de bombeio de 5 mW, com comprimento $L = 30$ m e bombeamento em $1,48 \mu\text{m}$. Sendo possível projetar amplificadores com alto ganho obtido para comprimentos de amplificador de apenas alguns metros (AGRAWAL, 2010).

Figura 15 - Gráficos dos ganhos em função da potência de bombeamento de um amplificador e do comprimento do amplificador.



Fonte: Modificada de AGRAWAL (2010)

2.5.1.2 Ruído do amplificador


O ruído de um amplificador EDFA é o fator limitante em redes de comunicações óticas. A relação sinal ruído (SNR) do sinal amplificado será degradada devido à emissão espontânea que adiciona ruído ao sinal durante a amplificação. A SNR se refere à potência elétrica que é gerada quando o sinal óptico é convertido em uma corrente elétrica (AGRAWAL, 2010).

A figura de ruído do amplificador é o parâmetro F_n que irá quantificar a degradação do sinal em função da emissão espontânea amplificada (ASE) e poderá ser definida conforme Equação 2.11.

$$F_n = \frac{(SNR)_{in}}{(SNR)_{out}} \quad (2.11)$$

Pode-se verificar na Figura 16 que o ruído e o ganho do amplificador variam com o comprimento do amplificador com diversos valores de P_p/P_p^{sat} , quando um sinal em 1,55 μm e potência de entrada de 1 mW é amplificado; os resultados indicam que uma figura de ruído próxima de 3 dB pode ser obtida para um amplificador de alto ganho. Pelo que os baixos níveis de ruído no EDFA o tornam a escolha ideal pra sistemas ópticos WDM (AGRAWAL, 2010).

Figura 16 - Gráficos da figura de ruído e ganho em função do comprimento do amplificador.



Fonte: Modificada de AGRAWAL (2010)

2.6 APRENDIZADO DE MÁQUINA (ML)

Arthur Lee Samuel, engenheiro do MIT, definiu em 1959 o aprendizado de máquina como “um campo de estudo que dá aos computadores a habilidade de aprender sem terem sido programados para tal”. Ao se criar um modelo de aprendizado de máquina, não foram detalhados cada passo a ser executado, o conhecimento é adquirido sem que seja necessário informar ao computador detalhadamente os movimentos sequenciados para que ele aprenda o que precisa, isso porque o conhecimento é obtido, não havendo necessidade que tudo esteja categoricamente programado. A partir de modelos estatístico/matemáticos que reconhecem padrões em estruturas de dados, criando a possibilidade que eles aprendam com seus erros e façam previsões em cima do que foi aprendido em um conjunto de dados de treinamento. Há duas formas de aprendizado que esses modelos podem ser definidos, nas quais serão detalhadas a seguir (BISHOP, 2006).


2.6.1 Aprendizado Supervisionado

Nos modelos de aprendizagem de máquina supervisionado somos capazes de calibrar o nível de assertividade e de precisão de um modelo. Ele tem como objetivo adquirir informações de relacionamento ou correlação entre entrada e saída de um sistema, baseado em um conjunto de treinamento. Modelos de aprendizado de máquina supervisionados são em geral os mais utilizados. Esses podem solucionar problemas de classificação, métodos que procuram explicar uma variável categórica, com duas categorias (binária) ou mais ou ainda os problemas que podem ser solucionados por regressão que buscam encontrar como uma variável evolui em

relação as outras. Métodos de regressão são os que melhores se encaixam no objetivo desse trabalho. (BISHOP, 2006).

A classificação é o processo de categorizar um determinado conjunto de dados em classes. Em contrapartida, os modelos de regressão são utilizados quando se quer prever valores, por exemplo, prever o preço de um carro ou o número de pacotes de viagem que serão vendidos em determinado mês, e assim por diante. Há vários modelos de regressão e suas possibilidades são descritas pela Figura 17. Podem existir ainda modelos de aprendizado de máquina mistos, que podem utilizar partes de regressão para fazer classificação, ou o oposto (BISHOP, 2006).

Figura 17 - Modelos de regressão utilizados no aprendizado de máquina.



Fonte: Autora


Ao analisar a Figura 17, identifica-se que a primeira subdivisão dos modelos de regressão se refere ao número de variáveis envolvidas, modelos de regressão simples abrangem apenas uma variável, enquanto os múltiplos duas ou mais. Em seguida, para cada um dos tipos descritos ainda existe outra ramificação que divide esses modelos em lineares ou não lineares. Nos modelos supervisionados o procedimento mais comum para realizar uma análise de dados é dividir o conjunto de dados em duas partes: treino e teste. O modelo de aprendizado de máquina é então treinado no conjunto de dados (*dataset*) de treino, logicamente. Posteriormente, o modelo é aplicado para realizar previsões no conjunto de dados de teste, momento no qual é feita uma avaliação da qualidade das previsões (BISHOP, 2006).

A seguir, serão descritos os algoritmos que apresentaram melhores desempenho e, desta forma, foram utilizados no treinamento da base de dados do estudo.

2.6.1.1 Boosted Decision Tree Regression (BDTR)

A árvore de decisão ou *Decision Tree Regression* (DTR) é um modelo de aprendizado de máquina que trabalha com tarefas de regressão. A DTR é uma estrutura similar a um fluxograma. 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. O nó raiz é o nó mais alto em uma árvore. Um exemplo disto pode ser visualizado na Figura 18. O método de classificação mediante um DTR baseia-se na maximização do ganho de informação. (Clemencon, S. e Vayatis, N., 2009).

Figura 18 - Árvore de decisão Decision Tree Regression



Fonte: Autora

Diferentes tipos de modelos de *machine learning* têm vantagens diferentes. O modelo de árvore de decisão é excelente para lidar com dados tabulares, com recursos categóricos ou numéricos. Diferente dos modelos lineares, as árvores de decisão são capazes de capturar a interação não linear entre os recursos e o alvo. Os modelos baseados em árvore não são projetados para funcionar com recursos muito esparsos. Ao lidar com dados de entrada esparsos (por exemplo, recursos categóricos com grandes dimensões), pode-se pré-processar os recursos esparsos para gerar estatísticas numéricas ou mudar para um modelo linear, que é mais adequado para tais cenários (LIKEBUPT, et. Al. 2022).

Algoritmos utilizam a técnica de *Boosting*, que é um método de conjunto realizado por meio da combinação linear dos chamados aprendizes fracos ou *weak learners* (BUHLMANN; YU, 2009).

De acordo com (LIMA, 2019), o método *ensemble* trata-se de uma técnica de aprendizado de máquina que funciona, fazendo uso da combinação do resultado de múltiplos modelos com o propósito de construir um melhor modelo de predição. Existem

diversos algoritmos de *Boosting*: *AdaBoost*, *MART Gradient Boosting* e *Gradient Boosting* são alguns exemplos.

Pode-se dizer que o *Boosted Decision Tree Regression* é um algoritmo de regressão construído a partir de duas técnicas: *Decision Tree* e *Boosting* (JUMIN; BASARUDDIN; YUSOFF, 2021), em que a parte de *Boosting* é baseada em uma eficiente implementação do algoritmo *Multiple Additive Regression Trees*.

2.6.1.2 Histogram Gradient Boosting Regression (HGBR)

Árvore de regressão de aumento de gradiente é baseada em histograma. Usando o modelo para uma quantidade maior de amostras, resultará em lentidão no treinamento dos dados, fator preponderante de problemas do aumento de gradiente. O treinador de árvores que é adicionado ao conjunto pode ser acelerado discretizando as variáveis de entrada contínuas para algumas centenas de valores únicos, então os conjuntos de aumento de gradiente que implementam essa técnica e adaptam o algoritmo de treinamento em torno das variáveis de entrada sob essa transformação são chamados de conjuntos de aumento de gradiente baseados em histogramas. Este estimador é muito mais rápido que o *Gradient Boosting Regressor* para grandes conjuntos de dados (BISHOP, 2006).


2.6.1.3 Decision Forest Regression (DFR)

Este modelo de regressão também consiste em um conjunto de árvores de decisão, ou seja, são modelos não paramétricos que executam uma sequência de testes simples para cada instância, percorrendo uma estrutura de dados de árvore binária até que um nó folha (decisão) seja alcançado. Uma árvore de regressão divide um problema complexo de regressão não linear em um conjunto de problemas menores que podem ser tratados mais facilmente por modelos mais simples (por exemplo, modelos lineares). Uma DRF é uma coleção de árvores de regressão treinadas aleatoriamente, como pode ser observado no diagrama da Figura 19.

O aspecto chave do modelo florestal é o fato de que suas árvores componentes são todas aleatoriamente diferentes umas das outras. Isso leva à descorrelação entre as previsões de árvores individuais e, por sua vez, resulta em generalização e robustez aprimoradas. O modelo do conjunto tem como saída a combinação de todas as previsões

de árvore em uma única previsão de floresta que pode ser feita por uma simples operação de média (CRIMINISI, A.; SHOTTON, J.; KONUKOGLU, E, 2012).

Figura 19 - Método de aprendizado Decision Forest Regression



Fonte: Modificada de CRIMINISI, A.; SHOTTON, J.; KONUKOGLU, E (2012)

2.6.2 Aprendizado Não Supervisionado

No aprendizado não supervisionado o tratamento é diferente, consiste em treinar uma máquina a partir de dados que não estão rotulados e/ou classificados. Os algoritmos que fazem isso buscam descobrir padrões ocultos que agrupam as informações de acordo com diferenças ou semelhanças. Desta forma, como não há uma variável específica a ser explicada (ou seja, não há um alvo), então não há sentido em treinar o conjunto de dados, pois também não será possível avaliar a assertividade do modelo. No aprendizado de máquina não supervisionado procura-se encontrar itens semelhantes, como padrões e perfis.

Dentre os métodos de aprendizado não supervisionado é utilizado às vezes a técnica chamada de agrupamento (*Clustering*), entretanto há outras técnicas como redução de dimensionalidade (*Dimensionality Reduction*) e regras de associação (*Association Rules*) (BISHOP, 2006).

3 METODOLOGIA

O método sintético de simulação no *software OptiSystem* foi utilizado para coleta de dados, predição de parâmetros e gerenciamento de perdas e QoT, posteriormente, esses dados foram usados para treinamento de inteligência artificial utilizando diferentes métodos de aprendizado de máquina (ML).

3.1 CONFIGURAÇÃO DA REDE E COLETA DE DADOS

O ponto inicial para aplicação de qualquer algoritmo de aprendizado de máquina é a coleta e posterior formatação dos dados. Há quatro métodos utilizados para coleta das amostras: diretamente em redes existentes (reais), redes experimentais, simulação ou uso de ferramenta de modelagem. Para o desenvolvimento desse projeto foi utilizada a coleta de dados por simulação utilizando o *software OptiSystem 7.0* da empresa canadense *Optiwave*.


O simulador *OptiSystem* é uma ferramenta computacional que permite que sejam realizadas simulações de sistemas de telecomunicações e de outras aplicações. Dispõe de várias bibliotecas com vários componentes utilizados em sistemas reais, permitindo ao usuário planejar, testar e simular enlaces ópticos.

A interface gráfica controla o *layout* dos componentes ópticos, modelos de componentes gráficos e apresentação. A biblioteca do *software* possui componentes ativos e passivos que irão atender aos variados usuários, permitindo a varredura de parâmetros visando analisar o efeito de especificações de dispositivos sobre o desempenho do sistema (OPTIWAVE, 2023).

3.1.1 Rede óptica real

Foi utilizada uma rede óptica existente de um provedor de internet do Ceará para simular dados como referência a uma rede óptica usual de uma planta de telecomunicações, que utilizará o canal 31 (frequência 193,1 THz) com taxa de transmissão de 10GHz, visto na Figura 20.

Figura 20 - Sistema DWDM existente.




Fonte: Autora

3.1.2 Levantamento dos dados

Inicialmente é montada a rede óptica no *OptiSystem* e são definidos quais os dados serão utilizados como parâmetros de entrada. O sistema, mostrado na Figura 21, foi simulado repetidamente para diferentes configurações.

As potências do transmissor WDM foram utilizadas como parâmetros de entrada, estes foram simulados com 6 configurações (2, 4, 6, 8, 10 e 12) dBm, e as potências do *pump* (bombeamento) dos amplificadores EDFA da rede óptica foram simulados com 16 configurações (de 20 a 35) dBm objetivando análise dos parâmetros relacionados ao gerenciamento de perdas, totalizando 366 interações. Os parâmetros de saída simulados foram o ganho total, a potência total, o mínimo BER e o máximo Qfator, o resultado dos mesmos foram salvos como arquivos de texto para posterior análise.

Figura 21 - Sistema DWDM e seus componentes da rede óptica simulada no OptiSystem.



Fonte: Autora

As potências do transmissor WDM e as potências dos bombeamentos (*pump*) dos amplificadores EDFA da rede óptica foram os parâmetros de entrada utilizados, que são diretamente relacionados ao gerenciamento de perdas e indiretamente relacionadas ao de qualidade do sistema (QoT). O transmissor WDM foi configurado para 40 canais e o canal de 10 GHz foi setado com a frequência de 193,1 THz, que corresponde ao canal 31 da banda C de transmissão óptica. A frequência de espaçamento entre os canais foi de 100 GHz e utilizada a modulação NRZ, conforme recomendação ITU-T G.694.1 (ITU-T, 2020). Os principais parâmetros do WDM são mostrados na Tabela 1.

O multiplexador WDM foi configurado com as mesmas configurações de quantidade de canais e definições das frequências de cada canal correspondente aos transmissores ópticos. Há um amplificador EDFA na saída do primeiro site em Fortaleza, onde o sinal óptico irá trafegar até o site de São Luís do Curu, distante 96 km, utilizando uma fibra óptica monomodo com características fixas: atenuação de 0,2 db/km e janela 1550 nm conforme recomendação ITU-T G.652 (ITU-T, 2016). Foi inserida uma fibra compensadora de dispersão (DCF – *Dispersion Compensating Fiber*), que é um componente disponível na biblioteca para compensar a dispersão cromática, em cada ponto final dos sites de São Luís do Curu, Itapajé e Itapipoca, visto que esse efeito não será abordado durante esse estudo. Nos sites de São Luís do Curu e Itapajé haverá apenas amplificação óptica, no qual foram usados amplificadores de linha e fibras ópticas com as mesmas características definidas anteriormente. Já no site final de Itapipoca, há o demultiplexador configurado com as mesmas características definidas anteriormente no

multiplexador. Nele será extraído o canal 31 para um receptor óptico. Foi inserido um monitor de dados chamado *BER Analyzer*, disponibilizado no banco de analisadores da biblioteca do software, que irá fornecer os resultados dos parâmetros de saída: ganho total, potência total, mínimo BER e máximo Qfator.

Tabela 1 - Parâmetros do sistema DWDM simulado.

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

Fonte: Autora

3.2 ANÁLISE E TREINAMENTO DOS DADOS

Posteriormente foi realizada a análise e conversão dos dados em uma forma adequada que pode ser aceita pelo *software* ou ambiente de desenvolvimento integrado (IDE - *Integrated Development Environment*) que executa o regressor. Neste caso, o regressor está sendo executado nas plataformas *Azure ML* (classic), *Anaconda Navigator* e *Google Colab*, que pode aceitar arquivos de dados no formato “.csv”. Portanto, o objetivo desta etapa é ler os dados coletados, separar parte para treinamento e parte para avaliação e utilizá-los no treinamento do modelo e avaliar o mesmo.

A linguagem de programação *Python* foi escolhida como candidata adequada para realizar esta etapa por ser uma ferramenta eficiente para análise de dados. *Python 3.9* foi executado no *Jupyter Notebook* IDE para esta finalidade.

3.2.1 Coeficiente linear de Pearson

Neste ponto, serão montados mapas de calor/*heatmap* a fim de observar a correlação entre os dados de entrada (conhecidos como *features*) e cada uma das possíveis saídas (conhecidas como *target*) que, no caso, vem a ser ganho total, potência total, máximo Qfator e mínimo BER. Como medida de correlação de um dado conjunto de n pares de variáveis (x_i , y_i), foi utilizado o coeficiente de correlação (linear) de Pearson, definido pela Equação 3.1:

$$r_p = \frac{\sum_{i=1}^n (x_i - \bar{x}) ((y_i - \bar{y}))}{[\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2]^{\frac{1}{2}}} \quad (3.1)$$

Onde sabe-se que o valor de $-1 \leq r_p \leq 1$, e na prática, se o valor r_p estiver próximo de -1 ou +1, pode-se dizer que as variáveis tem correlação muito forte; por outro lado, se o valor de r_p estiver próximo de zero, diz-se que as variáveis não tem correlação. Demais classificações para os índices podem ser observados na Tabela 2.

Tabela 2 - Classificação dos índices de correlação e suas interpretações.

Correlação	Interpretação
0,00	Sem correlação
> 0,00 a $\pm 0,19$	Correlação muito fraca
$\pm 0,20$ a $\pm 0,39$	Correlação fraca
$\pm 0,40$ a $\pm 0,69$	Correlação moderada
$\pm 0,70$ a $\pm 0,89$	Correlação forte
$\pm 0,90$ a $\pm 1,00$	Correlação muito forte

Fonte: Autora

3.2.2 Treinamento da base de dados

Os dados obtidos através da simulação no *Optisystem* foram analisados em diferentes algoritmos de IA, dentre os quais: BDTR, DFR e HGBR.

Antes mesmo da aplicação do algoritmo para treinamento do modelo que realizará a predição, é necessário dividir a base de dados original em duas partes: uma para treinamento do modelo e outra para avaliação do modelo. Geralmente costuma-se utilizar uma relação de 70% da base para treinamento e 30% da base para avaliação ou, ainda, 80% da base para treinamento e os 20% restantes para teste (Figura 22). A parte separada para avaliação será utilizada para verificação por meio de parâmetros estatísticos (tais como, coeficiente de determinação) do quanto o modelo, após a fase de aprendizado, está se adequando ao problema que lhe é apresentado.

Também faz-se necessário a escolha de quais serão as colunas da tabela que serão utilizadas como base para a previsão do valor de outra coluna. Aqui, foram selecionadas como base (as chamadas *features*) todas colunas excetuando-se as colunas que seriam


candidatas ao target (Máximo Qfator, Mínimo BER, Ganho total e Potência total). *Target* ou alvo refere-se à coluna que se deseja prever o valor.

Uma vez ajustado o modelo, foi avaliado a qualidade do ajuste e um dos indicadores mais utilizados para essa finalidade é o coeficiente de determinação definido conforme Equação 3.2:

$$R^2 = \frac{SQ_{Tot} - SQ_{Rest}}{SQ_{Tot}} = \frac{SQ_{Reg}}{SQ_{Tot}} = 1 - \frac{SQ_{Rest}}{SQ_{Tot}} \quad (3.2)$$

Em que o termo $SQ_{Tot} = \sum_{i=1}^n (y_i - \bar{y})^2$ é a soma de quadrados total e $SQ_{Rest} = \sum_{i=1}^n (y_i - \hat{y})^2$ é a soma dos quadrados dos erro e $SQ_{Reg} = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$ é a soma dos quadrados de regressão. Esse coeficiente mede a porcentagem da variação total dos dados em relação a sua média que é explicado pelo modelo de regressão. Os valores de R^2 variam no intervalo $[0,1]$ e quanto mais perto de 1 são esses valores mais precisos são os resultados, ou seja, a porcentagem da variação (erro) dos dados é menor em relação a sua média. Este indicador em conjunto com outras ferramentas irá avaliar o ajuste para os dados em investigação.

Figura 22 - Esquemático treinamento dos dados



Fonte: Autora

4 RESULTADOS E DISCUSSÕES

Neste capítulo serão apresentados os resultados em forma de gráficos e tabelas relativos às coletas de dados simulados no *OptiSystem*. Será realizada a análise de correlação entre as variáveis, e, posteriormente, esses dados serão treinados pelo uso do aprendizado de máquina utilizando os algoritmos *Boosted Decision Tree Regression* (BDTR), *Decision Forest Regression* (DFR) e *Histogram Gradient Boosting Regression* (HGBR).


4.1 SIMULAÇÕES DO OPTISYTEM

A seguir serão apresentados graficamente os dados simulados no *software OptiSystem* para os diferentes alvos.

4.1.1 Ganho total dos bombeamentos extremos e médios

As curvas para os bombeamentos extremos para os EDFAs 1, 2 e 3 (20;20;20) e (35;35;35) e os médios (25;25;25) e (30;30;30) foram expressas graficamente (Figura 23), demonstrando que os melhores resultados de ganho total para os bombeamentos com EDFAs ópticos foram obtidos com os valores de (35;35;35) dBm.

Figura 23 - Gráfico das curvas para os bombeamentos extremos (20;20;20) e (35;35;35) e os médios (25;25;25) e (30;30;30) obtidas mediante simulação.




Fonte: Autora

4.1.2 Potência total dos bombeamentos extremos e médios

As curvas para os bombeamentos extremos (20;20;20) e (35;35;35) e os médios (25;25;25) e (30;30;30) foram expressas graficamente e obtiveram os melhores resultados de potência total para os bombeamentos com os EDFAs ópticos com os valores de (35;35;35) dBm, conforme pode ser visualizado na Figura 24.

Figura 24 - Gráfico das curvas para os bombeamentos extremos (20;20;20) e (35;35;35) e os médios (25;25;25) e (30;30;30) obtidas mediante simulação.




4.1.3 Mínimo BER dos bombeamentos extremos e médios

As curvas para os bombeamentos extremos e os médios foram expressas graficamente (Figura 25), onde foi demonstrado que houve ausência de sinal com valores de mínimo BER igual a 1 para os bombeamentos com os EDFAs ópticos com configuração de (35;35;35) dBm com potências do WDM em 6 e 10 dBm e para os bombeamentos com os EDFAs ópticos com as configurações de (30;30;30) dBm e potências do WDM em 4 e 8 dBm.

Melhores resultados foram obtidos para os bombeamentos com os EDFAs ópticos com configuração de (20;20;20) dBm para a potência do WDM em 10 dBm, podendo ser melhor visualizado na base de dados simulada, disponibilizada nos apêndices.

Figura 25 - Gráfico das curvas para os bombeamentos extremos (20;20;20) e (35;35;35) e os médios (25;25;25) e (30;30;30) obtidas mediante simulação.




Fonte: Autora

4.1.4 Máximo Qfator dos bombeamentos extremos e médios

A ausência de sinal é percebida quando valores de Qfator são zerados. Este cenário foi visualizado para os bombeamentos com os EDFAs ópticos com configuração de (35;35;35) dBm para potências do WDM em 6 e 10 dBm e para os bombeamentos com os EDFAs ópticos com configuração de (30;30;30) dBm para potências do WDM em 4 e 8 dBm (Figura 26).

Foram obtidos melhores resultados os bombeamentos com os EDFAs ópticos com configuração de (25;25;25) dBm para potência do WDM em 8 dBm, podendo ser melhor visualizado na base de dados simulada, disponibilizada no apêndice.

Figura 26 - Gráfico das curvas para os bombeamentos extremos (20;20;20) e (35;35;35) e os médios (25;25;25) e (30;30;30) obtidas mediante simulação.



Fonte: Autora

4.1.5 Melhores parâmetros de saída

Na Tabela 3 foram mostrados os melhores resultados dos parâmetros de saída. Foi alcançado melhor resultado de ganho total para os bombeamentos com os EDFAs ópticos com configuração de (23;23;30) dBm para potência de entrada do WDM em 2 dBm; o melhor resultado de potência total foi atingido para os bombeamentos com os EDFAs ópticos com configuração de (28;28;35) dBm para potência de entrada do WDM em 12 dBm; já o menor BER foi obtido para os bombeamentos com os EDFAs ópticos com configuração de (26;26;25) dBm para potência de entrada do WDM em 6 dBm e já para o maior Qfator foram obtidos para os bombeamentos com os EDFAs ópticos com configuração de (27;30;27) dBm para potência de entrada do WDM em 2 dBm.

Tabela 3 - Melhores parâmetros de saída.

WDM Potência entrada	EDFA 1 Potência Bombeamento	EDFA 2 Potência Bombeamento	EDFA 3 Potência Bombeamento	Parâmetros de saída	Simulado
2	23	23	30	Ganho Total	-19,7277906164077
12	28	28	35	Potência Total	-34,2008636394358
6	26	26	25	Min. BER	0,0000000117176
2	27	30	27	Máx. Qfator	5,5224088914798

Fonte: Autora


4.2 ANÁLISE DE CORRELAÇÃO

Nessa etapa foram elaborados mapas de calor para medir a relação matemática entre as variáveis.

4.2.1 Ganho Total

Com enfoque na análise no ganho total, um *heatmap* (Figura 27) foi concebido onde pode-se inferir que a potência do bombeamento, tanto para o EDFA 1 quanto para o EDFA 2, possui uma correlação muito fraca. Em contrapartida, a variável potência do bombeamento do EDFA 3 possui correlação moderada. Também foi observado que a variável potência de entrada do WDM possui correlação forte.


Figura 27 - Heatmap correlacionando o ganho total com os dados de entrada.



4.2.2 Potência total

Um outro heatmap (Figura 28) foi elaborado para a avaliação da potência total. Como pode ser observado, a variável potência do WDM possui correlação muito fraca. A potência de bombeamento dos EDFA 1 e 2 possui uma correlação fraca. Por outro lado, potência total e a potência do bombeamento do EDFA 3 possuem correlação muito forte.

Figura 28 - Heatmap correlacionando o potência total com os dados de entrada.




Fonte: Autora

4.2.3 Máx. QFator

Buscando analisar máximo Qfator, foi obtido nível de correlação muito fraca com a variável potência do WDM. Já com a variável potência bombeamento do EDFA 2 houve correlação fraca. No entanto, as variáveis potência do bombeamento dos EDFAs 1 e 3 possuem uma correlação moderada. O seguinte heatmap foi gerado (Figura 29).


Figura 29 - Heatmap correlacionando a variável máximo Qfator com as variáveis de entrada.



4.2.4 Mínimo BER

Por fim, buscando analisar o mínimo BER, foi gerado o *heatmap* mostrado a seguir (Figura 30). Depreende-se que as correlações, que a potência do WDM possui correlação muito fraca e todas as potências dos bombeamentos dos EDFAs, possuem uma correlação fraca.

Figura 30 - Heatmap correlacionando a variável mínimo BER com as variáveis de entrada.




4.3 TREINAMENTO DOS MODELOS

Os gráficos a seguir serão apresentados em termos da porcentagem do banco de dados que foi utilizada para treinamento do modelo e o coeficiente de determinação (R^2) encontrado. São mostrados em formato de subseções a fim de focar em um alvo específico por vez.

4.3.1 Ganho Total


É possível observar na Figura 31 que entre os três algoritmos aplicados foi obtido melhor coeficiente de determinação (R^2) para o método BDTR, entretanto, para os demais métodos, também foram atingidos valores de R^2 superiores a 70%. Mostrou-se ainda (Figura 32) uma verificação relacionando as porcentagens 10, 50 e 80% da base de dados utilizada para treinamento em comparação com os diferentes modelos de IA que irá confirmar o método com melhor desempenho.

Figura 31 - Gráfico dos treinamentos realizados sobre o conjunto de dados utilizando os algoritmos de IA: BDTR, DFR e HGBR tendo como alvo o ganho total.



Fonte: Autora

Figura 32 - Gráficos de barras dos valores obtidos para o parâmetro R^2 relacionados aos diferentes algoritmos de treinamento usados variando algumas porcentagens da base de dados utilizada no estudo tendo como alvo o ganho total .




Fonte: Autora

4.3.2 Potência Total


Já para o alvo potência total, conforme Figura 33, obteve-se coeficientes de determinação mais similares, a partir de uma base de treinamento de 30%. O mesmo método BDTR, obteve os melhores resultados em quase todas as bases de treinamento. Entretanto para a base utilizada no estudo houve uma variação menor entre o BDTR e o HGBR que pode ser melhor visualizada na Figura 34.

Figura 33 - Gráfico dos treinamentos realizados sobre o conjunto de dados utilizando os algoritmos de IA: BDTR, DFR e HGBR tendo como alvo a potência total.



Fonte: Autora

Figura 34 - Gráficos de barras dos valores obtidos para o parâmetro R^2 relacionados aos diferentes algoritmos de treinamento usados variando algumas porcentagens da base de dados utilizada no estudo tendo como alvo a potência total.




Fonte: Autora

4.3.3 Máximo Qfator

De maneira geral, os resultados obtidos não foram satisfatórios, ficando o indicador R^2 próximo de 0.6. Seria preciso uma base de dados maior para a busca por melhores resultados e ainda inserir na avaliação das entradas outros parâmetros melhor


correlacionados com os fatores de qualidade. Entretanto o foco desse trabalho foi a análise de parâmetros relacionados ao gerenciamento de perdas; na Figura 35 há o comparativo dos três métodos de IA utilizados na aprendizagem. Para essa saída foram obtidos melhores resultados utilizando o algoritmo HGBR, pode-se visualizar ainda na Figura 36 que houve variação de qual seria o algoritmo que teria melhor resultado para o R^2 de acordo com a variação da porcentagem de dados utilizada para aprendizagem.

Figura 35 - Gráfico dos treinamentos realizados sobre o conjunto de dados utilizando os algoritmos de IA: BDTR, DFR e HGBR tendo como alvo o Qfator.



Fonte: Autora

Figura 36 - Gráficos de barras dos valores obtidos para o parâmetro R^2 relacionado aos diferentes algoritmos de treinamento usados variando algumas porcentagens da base de dados utilizada no estudo tendo como alvo o máximo Qfator.



Fonte: Autora

4.3.4 Mínimo BER

Observa-se na Figura 37, que para esse alvo a grande maioria dos algoritmos testados disponibilizaram o indicador R^2 negativo. As justificativas de tê-lo de forma negativa serão discutidas na sequência.

O primeiro pressuposto para este revés pode ser atribuído ao fato de que o modelo não se adequa ao problema em questão. Neste caso, o ideal seria utilizar um outro algoritmo a fim de que os parâmetros se adaptem mesmo que minimamente aos dados, como opção de testes, poderia ser utilizado o deep learning (DL), que é um ramo do *machine learning* (ML) que pode aprender com mais refinamento e é apropriado para tarefas complexas.


Outra justificativa possível advém da existência de poucos dados para o problema em questão, onde seria necessário gerar uma maior quantidade de dados para que dessa forma o algoritmo se adequar melhor ao modelo.

Outro fator relevante é o fato de as entradas que foram estudadas nesse trabalho não serem correlacionadas de maneira mais direta com esse parâmetro de análise de qualidade do sistema, tal qual já mencionado para a análise do fator de qualidade máximo Q_{fator} .

Observa-se portanto que, à medida que se vai incrementando a quantidade de dados utilizada para treinamento do modelo, apesar de certa inconsistência, tem-se uma melhora no resultado de R^2 . Outro fator a ser destacado é baseado no fato de que o R^2 , mesmo com 90% da base toda sendo utilizada para treinamento, mantém-se extremamente baixo, inferior a 0.2.


Há uma melhora mesmo que não seja significativa quando foi utilizado o método HGBR, conforme demonstrado na Figura 38 relacionando as porcentagens 10, 60 e 90% da base de dados utilizada para treinamento em comparação com os diferentes modelos de IA.

Figura 37 - Gráfico dos treinamentos realizados sobre o conjunto de dados utilizando os algoritmos de IA: BDTR, DFR e HGBR tendo como alvo o Mín. BER.



Fonte: Autora

Figura 38 - Gráficos de barras dos valores obtidos para o parâmetro R^2 relacionado aos diferentes algoritmos de treinamento usados variando algumas porcentagens da base de dados utilizada no estudo tendo como alvo o mínimo BER



Fonte: Autora

4.4 COMPARAÇÃO ENTRE OS VALORES SIMULADOS E TREINADOS


Neste descritivo foi realizada a comparação das diferenças gráficas entre o valor simulado (real) e o valor treinado (predição) pelos algoritmos para os bombeamentos extremos (20,20,20) e (35,35,35) e os médios (25,25,25) e (30,30,30), além dos melhores valores obtidos para os diferentes alvos.

Trabalha-se de maneira geral aqui com o modelo que foi treinado sobre a metodologia *lock on*, ou seja, quando é utilizado 80% dos dados para treinamento do modelo e os 20% restantes para avaliação, com exceção para a saída que houve pior desempenho (mínimo BER) onde foi utilizada uma situação de *underfitting*, que é quando há erro elevado tanto nos dados de treino quanto nos dados de teste, portanto, para a saída mínimo BER será utilizada 90% da base de dados para treinamento. Busca-se dessa forma verificar o que foi obtido com o valores preditos a fim de expor as comparações necessárias. Dito isso, serão demonstrados para cada saída (alvo) os gráficos do algoritmo que apresentou o melhor valor de coeficiente de determinação (R^2).

4.4.1 Ganho total dos bombeamentos extremos e médios

O algoritmo *Boosted Decision Tree Regression* (BDTR) foi o método que alcançou o melhor desempenho com o maior coeficiente de determinação para a saída ganho total. Foi relacionado o ganho total em função do parâmetro de entrada, potência do WDM. É possível visualizar graficamente, conforme Figura 39, que não há variações significativas entre os os valores reais (simulados) e preditos (treinados) pelo algoritmo, confirmando, dessa forma, que há correlação direta entre as entradas estudadas e a referida saída.

Figura 39 - (a) Comparação real x predição para a saída ganho total dos bombeamentos extremos inferiores (20;20;20); (b) Comparação real x predição para a saída ganho total dos bombeamentos extremos superiores (35;35;35); (c) Comparação real x predição para a saída ganho total dos bombeamentos médios (25;25;25); (d) Comparação real x predição para a saída ganho total dos bombeamentos médios (30;30;30).




Fonte: Autora

4.4.2 Curvas consolidadas do ganho total dos bombeamentos extremos e médios

A Figura 40 valida que as curvas dos dados simulados e treinados não têm erros significativos, ratifica, portanto, a correlação direta entre as entradas e a saída ganho total.

Figura 40 - (a) Gráfico das curvas dos dados simulados referente aos bombeamentos dos EDFAs dos pontos extremos e médios para a saída ganho total; (b) Gráfico das curvas dos dados treinados referente aos bombeamentos dos EDFAs dos pontos extremos e médios para a saída ganho total.



Fonte: Autora


4.4.3 Potência total dos bombeamentos extremos e médios

A demonstração dos gráficos do algoritmo *Boosted Decision Tree Regression* (BDTR) também foi disponibilizada (Figura 42) devido a esse ser o método que apresentou o maior coeficiente de determinação para a saída potência total. Percebe-se também graficamente que não existem variações significativas entre os valores reais (simulados) e preditos (treinados), apesar da correlação da maioria das entradas ser fraca em contraponto ao bombeamento do terceiro EDFA ser muito forte.

4.4.4 Curvas consolidadas do potência total dos bombeamentos extremos e médios


As curvas são inseridas no mesmo gráfico com valores simulados e treinados de forma a visualizar (Figura 41) a correlação entre as entradas e a saída potência total.


Figura 41 - (a) Gráfico das curvas dos dados simulados referente aos bombeamentos dos EDFAs dos pontos extremos e médios para a saída potência total; (b) Gráfico das curvas dos dados treinados referente aos bombeamentos dos EDFAs dos pontos extremos e médios para a saída potência total.



Fonte: Autora

Figura 42 - (a) Comparação real x predição para a saída potência total dos bombeamentos extremos inferiores (20;20;20); (b) Comparação real x predição para a saída potência total dos bombeamentos extremos superiores (35;35;35); (c) Comparação real x predição para para a saída potência total dos bombeamentos médios (25;25;25); (d) Comparação real x predição para a saída potência total dos bombeamentos médios (30;30;30).






Fonte: Autora

4.4.5 Máximo Qfator dos bombeamentos extremos e médios

Já para o máximo Qfator foram demonstrados os gráficos do algoritmo *Histogram Gradient Boosting Regression* (HGBR), conforme Figura 43, o método obteve o melhor coeficiente de R^2 , aproximadamente 0.605644. É possível visualizar graficamente que, como era de se esperar, houveram variações mais perceptíveis entre os valores reais (simulados) e preditos (treinados), visto que a análise de parâmetros relacionados ao gerenciamento de perdas foi tomada como cerne deste estudo, e não aos relacionados ao gerenciamento de dispersão.

Figura 43 - (a) Comparação real x predição para a saída máximo Qfator dos bombeamentos extremos inferiores (20;20;20); (b) Comparação real x predição para a saída máximo Qfator dos bombeamentos extremos superiores (35;35;35); (c) Comparação real x predição para a saída máximo Qfator dos bombeamentos médios (25;25;25); (d) Comparação real x predição para a saída máximo Qfator dos bombeamentos médios (30;30;30).




Fonte: Autora

4.4.6 Curvas consolidadas do máximo Qfator dos bombeamentos extremos e médios

Os gráficos anexados contêm as 4 curvas dos bombeamentos extremos e médios com os dados simulados e treinados, respectivamente, Figura 44. Para esta saída foi observada menor correlação com as entradas potência do WDM e bombeamento dos amplificadores dopados por érbio. Desta forma, valida-se o menor desempenho da estatística R^2 . Confirmado novamente que a correlação indireta das entradas com a saída é fator determinante para a predição analisada pelos métodos de aprendizado de máquina.

Figura 44 - (a) Gráfico das curvas dos dados simulados referente aos bombeamentos dos EDFAs dos pontos extremos e médios para a saída máximo Qfator; (b) Gráfico das curvas dos dados treinados referente aos bombeamentos dos EDFAs dos pontos extremos e médios para a saída máximo Qfator.



Fonte: Autora


4.4.7 Mínimo BER dos bombeamentos extremos e médios

Apesar de termos uma situação de *underfitting*, busca-se verificar o que foi obtido com os valores treinados, a fim de expor as explicações necessárias. Trabalha-se com o modelo treinado utilizando 90% do banco de dados sobre o algoritmo *Histogram Gradient Boosting Regression* (HGBR), pois foi o melhor resultado dentre todos, este alcançou um valor de indicador de performance R^2 de 0.192455. Em uma primeira análise, percebe-se que os resultados foram razoáveis para esse determinado R^2 que foi encontrado, porém pode-se supor que é devido ao modelo já possuir um aprendizado de como funciona praticamente todo o banco de dados disponibilizado, pois foi treinado com 90% dele. Este parâmetro de saída tem uma correlação baixa com os parâmetros de entrada, ratificando as distorções acentuadas entre valores reais e preditos. Os gráficos dos bombeamentos extremos e médios podem ser analisados na Figura 45.

4.4.8 Curvas consolidadas do mínimo BER dos bombeamentos extremos e médios


Por fim, a Figura 46 abrange os conjunto de dados simulados e treinados para a saída mínimo BER, este possui a menor correlação com as entradas potência do WDM e bombeamento dos amplificadores dopados por érbio, corroborando para o menor desempenho de todas as saídas estudadas.

Figura 45 - (a) Comparação real x predição para a saída mínimo BER dos bombeamentos extremos inferiores (20;20;20); (b) Comparação real x predição para a saída mínimo BER dos bombeamentos extremos superiores (35;35;35); (c) Comparação real x predição para a saída mínimo BER dos bombeamentos médios (25;25;25); (d) Comparação real x predição para a saída mínimo BER dos bombeamentos médios (30;30;30),



Fonte: Autora

Figura 46 - (a) Gráfico das curvas dos dados simulados referente aos bombeamentos dos EDFAs dos pontos extremos e médios para a saída mínimo BER; (b) Gráfico das curvas dos dados treinados referente aos bombeamentos dos EDFAs dos pontos extremos e médios para a saída mínimo BER.



Fonte: Autora

4.4.9 Comparação simulado x treinado para os melhores parâmetros de saída

De acordo com os dados simulados, selecionou-se os melhores valores de saída referente a cada alvo posteriormente comparados com os valores preditos para as mesmas combinações de entrada, mostrados graficamente na Figura 47 e detalhados na Tabela 4. Foi utilizado o indicador de acuracidade de desempenho estatístico, que é o erro absoluto percentual médio (MAPE - *Mean Absolute Percentage Error*), medida que expressa a porcentagem média dos erros em valor absoluto e define que, quanto menor esta medida, melhor a precisão dos dados obtidos.


Reafirmando as análises anteriores, para a diferença entre os valores reais e preditos das saídas ganho total e potência total, que são mais correlacionadas com as entradas, foram obtidos os menores percentuais de erro, 0,24 e 0,18, respectivamente. Já para o mínimo BER obteve-se erro acima do esperado, não sendo possível estabelecer acuracidade de desempenho. Por outro lado, percebeu-se um erro de 3,91 por cento para o alvo máximo Qfator.

Tabela 4 - Melhores parâmetros de saída (Simulado e Treinado).

WDM	EDFA 1	EDFA 2	EDFA 3	Parâmetros de saída	Simulado	Treinado
Potência entrada	Potência Bombeamento	Potência Bombeamento	Potência Bombeamento			
2	23	23	30	Ganho Total	-19,7277906164077	-19,7318992614746
12	28	28	35	Potência Total	-34,2008636394358	-34,1853981018066
6	26	26	25	Min. BER	0,0000000117176	0,0060453637601
2	27	30	27	Máx. Qfator	5,5224088914798	5,5224143761497

Fonte: Autora

Figura 47 - Gráficos de barra para a comparação simulado x treinado para os melhores valores de saída referente aos parâmetros ganho total, potência total, máximo Qfator e mínimo BER.



Fonte: Autora

5 CONCLUSÕES

Neste trabalho de mestrado, uma base de dados foi simulada no *OptiSystem* para uma rede óptica WDM onde foram setados parâmetros de entrada e obtidos parâmetros de saída. Demonstrou-se que as predições para os parâmetros de saída mais correlacionados com os parâmetros de entrada são o ganho total e potência total, estes tiveram melhores resultados em comparação aos menos correlacionados, que são o máximo Qfator e mínimo BER. Os resultados apresentados eram esperados devido ao fato de que o objetivo inicial do projeto visava o gerenciamento de perdas.

Foi observado que, para a base de dados simulada, o algoritmo *Boosted Decision Tree Regression* (BDTR) apresentou melhor desempenho na análise do ganho total e potência total. Já para os alvos máximo Qfator e mínimo BER o *Histogram Gradient Boosting Regression* (HGBR) foi superior.

Desta forma, constata-se que o aprendizado de máquina é um campo promissor para o estudo de melhorias de redes ópticas, visto que o uso de algoritmos nos fornecem soluções viáveis sem a necessidade de estudo de todos os cenários possíveis e irão direcionar o planejamento de sistemas de comunicações ópticas, com o objetivo de minimizar as altas margens inseridas nos projetos reais, que elevam os custos e subutilizam os recursos da rede.

Sugere-se que para trabalhos futuros a base de dados seja ampliada para investigação pelo aprendizado de máquina, além da análise dos parâmetros de gerenciamento de dispersão que são mais correlacionados com a análise de QoT.

A inserção de outras linguagens de máquina com mais robustez é incentivada a fim de que possam ser realizadas novas verificações para uma base de dados mais complexa.

REFERÊNCIAS

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

AGRAWAL, G. P. **Fiber-optic Communication Systems**. [S.l.]: New York: [s.n.] p. 29 – 92. ISBN 0-471-22114-7, 2002.

AMICO, A. D et. al. **Enhancing Lightpath QoT Computation With Machine Learning in Partially Disaggregated Optical Networks**. IEEE Open Journal of the Communications Society, vol. 2, pp. 564-574, 2021.

BISHOP, C. M. Pattern. **Recognition and Machine Learning: Information Science and Statistics**. Nova Iorque: Springer-Verlag, 2006.

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.

DUTTA, M.; STROSCIOS, M. A. **Advances in Semiconductor Lasers and Application to Optoelectronics**. Singapore: Word Scientific, 2000.

GONÇALVES, A. M. **Análise da Propagação de Impulsos em Fibras Óticas**. Tese (Doutorado) - Instituto Superior Técnico - Universidade Técnica de Lisboa, Lisboa, 2012.

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-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.

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

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>.

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>>.

MANSO, C. et. al. **Scalability analysis of machine learning QoT estimators for a cloud-native SDN controller on a WDM over SDM network**. Journal of Optical Communications and Networking, vol. 14, no. 4, pp. 257-266, 2022.

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

PADTEC. **Introdução a Sistemas Ópticos**. [S.l.], 2019.

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.

SENIOR, J. M. **Chapter 3 - transmission characteristics of optical fibers**. [S.l.]: Optical Fiber Communications: Principles and Practice. England: [s.n.], 2009.

TRONCO, T. R.; ÁVILA, L. F. **Fundamentos de Comunicações ópticas**. 1. ed. [S.l.: s.n.], 2007.

ZHANG, L. et al. **A survey on QoT prediction using machine learning in optical networks**. Optical Fiber Technology, 2022.

APÊNDICE A – Mínimo BER para os bombeamentos extremos e médios

WDM Potência de Entrada	EDFA 1 Potência de Bombeamento	EDFA 2 Potência de Bombeamento	EDFA 3 Potência de Bombeamento	Mínimo BER
2	20	20	20	0,0226481322625
4	20	20	20	0,4826400013725
6	20	20	20	0,0011976667775
8	20	20	20	0,0000107506236
10	20	20	20	0,0000021416675
12	20	20	20	0,0188875117473
2	25	25	25	0,0000419926840
4	25	25	25	0,0398565034432
6	25	25	25	0,0001003174701
8	25	25	25	0,0036147923894
10	25	25	25	0,0041604997066
12	25	25	25	0,0005248671774
2	30	30	30	0,0009782503907
4	30	30	30	1,0000000000000
6	30	30	30	0,0017236209517
8	30	30	30	1,0000000000000
10	30	30	30	0,0037491927136
12	30	30	30	0,0040590195182
2	35	35	35	0,0002630887822
4	35	35	35	0,0011218511103
6	35	35	35	1,0000000000000
8	35	35	35	0,0005147060525
10	35	35	35	1,0000000000000
12	35	35	35	0,0005038106631

APÊNDICE B - Máximo Qfator para os bombeamentos extremos e médios

WDM Potência de Entrada	EDFA 1 Potência de Bombeamento	EDFA 2 Potência de Bombeamento	EDFA 3 Potência de Bombeamento	MAX. Qfator
2	20	20	20	4,0812414368073
4	20	20	20	4,2204279570892
6	20	20	20	4,5073590082849
8	20	20	20	4,8676688678696
10	20	20	20	4,8067000610771
12	20	20	20	4,0080210640886
2	25	25	25	4,4015783488597
4	25	25	25	4,6410826720252
6	25	25	25	4,9398705248815
8	25	25	25	5,0214517711771
10	25	25	25	4,4961997844218
12	25	25	25	3,1135808097858
2	30	30	30	3,0382938630822
4	30	30	30	0,0000000000000
6	30	30	30	2,9019132479405
8	30	30	30	0,0000000000000
10	30	30	30	2,6696348072569
12	30	30	30	2,6388597369779
2	35	35	35	3,4634710409154
4	35	35	35	3,9490801259816
6	35	35	35	0,0000000000000
8	35	35	35	3,2680853955819
10	35	35	35	0,0000000000000
12	35	35	35	3,0670082364153