



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

**AÊDO BRAGA SILVEIRA**

**MODELAGEM DIRETA E INVERSA DE AMPLIFICADORES DE FIBRAS DOPADAS**  
**COM ÉRBIO PARA ESTIMAR GANHO E FIGURA DE RUÍDO**

**FORTALEZA**

**2024**

AÊDO BRAGA SILVEIRA

MODELAGEM DIRETA E INVERSA DE AMPLIFICADORES DE FIBRAS DOPADAS  
COM ÉRBIO PARA ESTIMAR GANHO E FIGURA DE RUÍDO

Dissertação apresentada ao curso de Mestrado Acadêmico em Engenharia de Telecomunicações do Programa de Pós-Graduação em Engenharia de Telecomunicações do *Campus* Fortaleza do Instituto Federal de Educação, Ciência e Tecnologia do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia de Telecomunicações. Área de Concentração: Micro-ondas e Óptica Integrada.

Orientador: Prof. Dr. Glendo de Freitas Guimarães.

Coorientador: Prof. Dr. Auzuir Ripardo de Alexandria

FORTALEZA

2024

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)

---

S587m     Silveira, Aêdo Braga.  
              MODELAGEM DIRETA E INVERSA DE AMPLIFICADORES DE FIBRAS DOPADAS COM  
              ÉRBIO PARA ESTIMAR GANHO E FIGURA DE RUÍDO / Aêdo Braga Silveira. - 2024.  
              93 f. : il. color.

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

              Orientação: Prof. Dr. Glendo de Freitas Guimarães.

              Coorientação: Prof. Dr. Auzuir Ripardo de Alexandria.

              1. EDFA. 2. Aprendizagem de Máquina. 3. Ganho. 4. Figura de Ruído. I. Título.

CDD 621.382

---

**AÊDO BRAGA SILVEIRA**

**MODELAGEM DIRETA E INVERSA DE AMPLIFICADORES DE FIBRAS DOPADAS  
COM ÉRBIO PARA ESTIMAR GANHO E FIGURA DE RUÍDO**

**Dissertação apresentada ao curso de Mestrado Acadêmico em Engenharia de Telecomunicações do Programa de Pós-Graduação em Engenharia de Telecomunicações do *Campus* Fortaleza do Instituto Federal de Educação, Ciência e Tecnologia do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia de Telecomunicações. Área de Concentração: Micro-ondas e Óptica Integrada.**

**Aprovado em: \_\_\_\_/\_\_\_\_/\_\_\_\_.**

**BANCA EXAMINADORA**

---

Prof. Dr. Glendo de Freitas Guimarães (Orientador)  
Instituto Federal de Educação, Ciência e Tecnologia do Ceará

---

Prof. Dr. Auzuir Ripardo de Alexandria (Co-orientador)  
Instituto Federal de Educação, Ciência e Tecnologia do Ceará

---

Prof. Dr. Danilo Reis de Vasconcelos  
Instituto Federal de Educação, Ciência e Tecnologia do Ceará

---

Prof. Dr. André Lima Férrer de Almeida  
Universidade Federal do Ceará

A Deus.

Aos meus pais, Ana Vilma e Ricardo.

A minha namorada, Marília.

Aos meus irmãos, Vitor e Patricia.

Aos meus amigos.

Aos pesquisadores.

## **AGRADECIMENTOS**

A Deus, por iluminar o meu caminho até aqui. Por tudo que fez e continua fazendo na minha vida.

Ao Glendo, meu orientador, coordenador e amigo, que me socorreu diversas vezes durante a dissertação, sendo sempre um grande exemplo de profissionalismo e humanidade.

Ao Auzuir, meu coorientador, por todo o apoio, as valiosas dicas e a ajuda indispensável para a finalização deste projeto de pesquisa. Peço desculpas pelas dores de cabeça que causei ao longo do processo.

Aos membros da banca de qualificação, Joacir e Alexandre. E aos membros da banca avaliadora, Danilo e André. Pelas valiosas contribuições que em muito enriqueceram esse projeto de pesquisa.

Ao Isaac, que foi e continua sendo um verdadeiro mestre. Com ele, sempre aprendi muito e sigo aprendendo. Obrigado pela paciência, amizade e ensinamentos no decorrer desses anos.

Às minhas amigas Luana e Diana, que foram fundamentais para a conclusão deste projeto.

Aos meus amigos Tiago, Alan e Caio, companheiros de diversos projetos. Obrigado por todos esses anos de muitas risadas e de tantos aprendizados.

Aos grandes professores que tive no IFCE.

Aos amigos do laboratório de Fotônica, da nova e antiga geração.

A CAPES, pelo apoio financeiro.

A todos que me ajudaram, direta ou indiretamente, durante algum momento desta etapa da minha vida.

Aos meus grupos de amigos de longa data, "Rolezeiros" e "Alcateia", que estiveram presentes durante quase toda a minha vida. Obrigado por tudo, meus amigos.

À minha querida mãe, a primeira mestra da família, pelo amor incondicional e pelo incentivo constante a sempre continuar estudando.

À minha querida Marília, que mesmo sem entender tanto sobre o tema da minha pesquisa, sempre esteve ao meu lado, me apoiando em todos os momentos e me inspirando a dar o meu melhor. É a melhor companhia que eu poderia querer.

“Se eu vi mais longe, foi por estar de pé sobre ombros de gigantes.”

(Isaac Newton)

“Há uma diferença entre conhecer o caminho e percorrer o caminho.”

(Morpheus)

## RESUMO

O amplificador de fibra óptica dopada com érbio (*EDFA*) é reconhecido como um dos amplificadores mais importantes em sensores de fibras ópticas, os quais são amplamente utilizados para compensar a perda de potência óptica em enlaces ópticos, constituindo assim o principal recurso utilizado para contornar a atenuação. Esse amplificador opera no comprimento de onda ideal para telecomunicações, o qual obtém a menor atenuação por quilômetro de fibra óptica propagada. Além disso, os relativamente baixos níveis de ruído dos *EDFAs* os tornam uma escolha ideal para os sistemas *WDM*, necessários para a transmissão de altas taxas de velocidade. No entanto, sua modelagem é complexa, visto que são modelados através de métodos numéricos, os quais ganho e figura de ruído podem ser calculados através de análises numéricas. Contudo, esse método requer cálculos densos e conhecimentos referentes aos parâmetros de fabricação das fibras dopadas. Além disso, a complexidade matemática também exige um maior tempo de processamento requisitado pelo sistema. Para contornar essa adversidade, esse projeto propõe uma varredura multiparamétrica dos seguintes parâmetros: potência do sinal de entrada, potência de bombeamento, comprimento da fibra e nível de densidade de érbio, para dessa forma, estimar com precisão o ganho e a figura de ruído dos amplificadores, de maneira mais simples, rápida e precisa. Tanto o ganho quanto a figura de ruído foram treinados com o algoritmo *Extreme Gradient Boosting* com os valores de *holdout* de 90% para treinamento e 10% para testes. Para o modelo aplicado a figura de ruído, foi obtido um  $R^2$  de 0,9987, MAE de 0,0428, MSE de 0,0046, RSME de 0,0677, RMSLE de 0,0095 e MAPE de 0,0077, e para o ganho, foi obtido um  $R^2$  de 0,9996, MAE de 0,0565, MSE de 0,0150, RMSE de 0,1185, RMSLE de 0,0174 e MAPE de 0,0087. Além disso, também foi possível realizar a modelagem inversa dos amplificadores, em que com a variação do ganho e da figura de ruído, foi possível estimar com precisão a potência do sinal de entrada, a potência de bombeamento e o comprimento da fibra, os quais alcançaram um  $R^2$  de 0,9949, 0,9952 e 0,9475, respectivamente.

**Palavras-chave:** EDFA; Aprendizagem de Máquina; Ganho; Figura de Ruído.

## ABSTRACT

The erbium-doped fiber amplifier (*EDFA*) is recognized as one of the most important amplifiers in optical fiber sensors, which are extensively used to compensate for optical power loss in optical links, thus constituting the main resource used to overcome attenuation. This amplifier operates at the ideal wavelength for telecommunications, where the lowest attenuation per kilometer of propagated optical fiber is obtained. Additionally, the relatively low noise levels of *EDFAs* make them an ideal choice for *WDM* systems, necessary for high-speed transmission. However, their modeling is complex, as they are modeled using numerical methods, where gain and noise figure can be calculated through numerical analyses. However, this method requires dense calculations and knowledge of the parameters of doped fibers manufacturing. Moreover, the mathematical complexity also demands longer processing time required by the system. To overcome this adversity, this project proposes a multiparametric sweep of the following parameters: input signal power, pump power, fiber length, and erbium density level, in order to accurately estimate the gain and noise figure of the amplifiers in a simpler, faster, and more accurate way. Both gain and noise figure were trained using the Extreme Gradient Boosting algorithm with holdout values of 90% for training and 10% for testing. For the model applied to the noise figure, an  $R^2$  of 0.9987, MAE of 0.0428, MSE of 0.0046, RMSE of 0.0677, RMSLE of 0.0095, and MAPE of 0.0077 were obtained, and for gain, an  $R^2$  of 0.9996, MAE of 0.0565, MSE of 0.0150, RMSE of 0.1185, RMSLE of 0.0174, and MAPE of 0.0087 were obtained. Furthermore, it was also possible to perform the inverse modeling of the amplifiers, which with the gain and the noise figure variation, it was possible to accurately estimate the input signal power, pump power, and fiber length, achieving  $R^2$  values of 0.9949, 0.9952, and 0.9475, respectively.

**Keywords:** EDFA; Machine Learning; Gain; Noise Figure.

## LISTA DE FIGURAS

|                                                                                                                                                    |    |
|----------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 1 – Efeitos da dispersão e atenuação em uma fibra óptica . . . . .                                                                          | 23 |
| Figura 2 – Representação da propagação de raios ópticos em um guia de onda óptico de índice de degrau ideal . . . . .                              | 25 |
| Figura 3 – Diagrama em blocos do gerenciamento de perdas concentrada . . . . .                                                                     | 27 |
| Figura 4 – Diagrama em blocos do gerenciamento de perdas distribuída . . . . .                                                                     | 27 |
| Figura 5 – Amplificador de linha . . . . .                                                                                                         | 28 |
| Figura 6 – Amplificador óptico na topologia de pré-amplificador . . . . .                                                                          | 29 |
| Figura 7 – Amplificador de potência . . . . .                                                                                                      | 29 |
| Figura 8 – Os processos necessários para a ação do laser . . . . .                                                                                 | 31 |
| Figura 9 – Diagrama de níveis de energia para íons de $Er^{3+}$ em fibras ópticas (de sílica) . . . . .                                            | 32 |
| Figura 10 – Absorção e ganho espectral para íons de érbio em uma fibra de sílica dopada com germânio e alumínio . . . . .                          | 34 |
| Figura 11 – Os três tipos de configuração de um <i>EDFA</i> : a) codirecional, b) bombeamento reverso e c) bombeamento bidirecional . . . . .      | 35 |
| Figura 12 – Relação da dependência do ganho com o aumento do comprimento da fibra e da potência de bombeamento . . . . .                           | 38 |
| Figura 13 – Gráficos de figura de ruído e ganho dos amplificadores em função do comprimento de onda para diversos valores de bombeamento . . . . . | 40 |
| Figura 14 – Hierarquia da aprendizagem de máquina supervisionado e não supervisionado . . . . .                                                    | 42 |
| Figura 15 – Estrutura de árvore binária genérica . . . . .                                                                                         | 43 |
| Figura 16 – Exemplo de árvore de decisão . . . . .                                                                                                 | 44 |
| Figura 17 – Parâmetros Random Forest . . . . .                                                                                                     | 46 |
| Figura 18 – Fluxo de trabalho da floresta aleatória . . . . .                                                                                      | 47 |
| Figura 19 – Etapas de desenvolvimento da pesquisa . . . . .                                                                                        | 55 |
| Figura 20 – Setup experimental simulado no <i>OptiSystem</i> . . . . .                                                                             | 56 |
| Figura 21 – Arquitetura do <i>EDFA</i> utilizado no projeto . . . . .                                                                              | 59 |
| Figura 22 – Variação da figura de ruído em relação a diferentes potências de entrada . . . . .                                                     | 71 |
| Figura 23 – Variação do ganho em relação a diferentes potências de entrada . . . . .                                                               | 72 |
| Figura 24 – Variação da figura de ruído em relação a diferentes potências de bombeamento . . . . .                                                 | 73 |
| Figura 25 – Variação do ganho em relação a diferentes potências de bombeamento . . . . .                                                           | 74 |

|                                                                                                                                                       |    |
|-------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 26 – Variação da figura de ruído em relação a diferentes comprimentos de fibra dopada . . . . .                                                | 75 |
| Figura 27 – Variação da ganho em relação a diferentes comprimentos de fibra dopada . .                                                                | 76 |
| Figura 28 – Variação da figura de ruído em relação a diferentes níveis de densidade de érbio                                                          | 77 |
| Figura 29 – Variação do ganho em relação a diferentes níveis de densidade de érbio . . .                                                              | 78 |
| Figura 30 – Análise do modelo inverso para a potência óptica de entrada em função da variação da figura de ruído e do ganho respectivamente . . . . . | 80 |
| Figura 31 – Análise do modelo inverso para a potência óptica de entrada em função da variação da figura de ruído e do ganho respectivamente . . . . . | 81 |
| Figura 32 – Análise do modelo inverso para a potência óptica de entrada em função da variação da figura de ruído e do ganho respectivamente . . . . . | 83 |

## LISTA DE TABELAS

|                                                                                                                                          |    |
|------------------------------------------------------------------------------------------------------------------------------------------|----|
| Tabela 1 – Detalhamento dos parâmetros de entrada que serão utilizados . . . . .                                                         | 58 |
| Tabela 2 – Relação de algoritmos testados e seus respectivos valores estatísticos em<br>função da figura de ruído . . . . .              | 66 |
| Tabela 3 – Relação de algoritmos testados e seus respectivos valores estatísticos em<br>função do ganho . . . . .                        | 67 |
| Tabela 4 – Relevância dos parâmetros de entrada para a figura de ruído . . . . .                                                         | 69 |
| Tabela 5 – Relevância dos parâmetros de entrada para o ganho . . . . .                                                                   | 69 |
| Tabela 6 – Relação de algoritmos testados e seus respectivos valores estatísticos em<br>função da potência de sinal de entrada . . . . . | 79 |
| Tabela 7 – Relevância dos parâmetros de entrada para a figura de ruído . . . . .                                                         | 80 |
| Tabela 8 – Relação de algoritmos testados e seus respectivos valores estatísticos em<br>função da potência de bombeamento . . . . .      | 81 |
| Tabela 9 – Relevância dos parâmetros de entrada para a figura de ruído . . . . .                                                         | 82 |
| Tabela 10 – Relação de algoritmos testados e seus respectivos valores estatísticos em<br>função do comprimento da fibra . . . . .        | 83 |
| Tabela 11 – Relevância dos parâmetros de entrada para a figura de ruído . . . . .                                                        | 84 |
| Tabela 12 – Detalhamento dos parâmetros para o teste de <i>overfitting</i> . . . . .                                                     | 85 |
| Tabela 13 – Teste de <i>overfitting</i> aplicado a modelagem direta da figura de ruído . . . . .                                         | 85 |
| Tabela 14 – Teste de <i>overfitting</i> aplicado a modelagem direta do ganho . . . . .                                                   | 85 |

## LISTA DE ABREVIATURAS E SIGLAS

|          |                                                                    |
|----------|--------------------------------------------------------------------|
| EDFA     | do inglês, Erbium Doped Fiber Amplifier                            |
| ASE      | Emissão Espontânea Amplificada                                     |
| GBR      | do inglês, Gradient Boosting Regressor                             |
| XGboost  | do inglês, Extreme Gradient Boosting                               |
| LightGBM | do inglês, Light Gradient Boosting Machine                         |
| Laser    | do inglês, light amplification by stimulated emission of radiation |
| RF       | Algoritmo Floresta Aleatória                                       |
| GVD      | Dispersão de Velocidade de Grupo                                   |
| PCE      | Eficiência de Potência                                             |
| QCE      | Eficiência de Conversão Quântica                                   |
| QoT      | Qualidade da Transmissão                                           |
| FMF      | do inglês, Few-Mode Fiber                                          |
| ML       | do inglês, Machine Learning                                        |
| SQT      | Soma dos Quadrados Totais                                          |
| SQR      | Soma dos Quadrados de Regressão                                    |
| SQE      | Soma dos Quadrados dos Erros                                       |
| RSMLE    | ] do inglês, Root Mean Squared Logarithmic Error                   |
| RMSE     | do inglês, Root Mean Squared Error                                 |
| MSE      | do inglês, Mean Squared Error                                      |
| MAPE     | do inglês, Mean Absolute Percentual Error                          |
| MAE      | do inglês, Medium Absolute Error                                   |

## LISTA DE SÍMBOLOS

|                         |                                      |
|-------------------------|--------------------------------------|
| $\alpha_R$              | Coeficiente de Espalhamento Rayleigh |
| $C$                     | Velocidade da Luz                    |
| $\lambda$               | Comprimento de Onda                  |
| $n$                     | Índice de Refração                   |
| $P$                     | Potência Óptica Média                |
| $P_{in}$                | Potência de Entrada                  |
| $P_{out}$               | Potência de Saída                    |
| $L$                     | Comprimento da Fibra                 |
| $\alpha$                | Coeficiente de Atenuação             |
| $G$                     | Ganho de Amplificação                |
| $P_{s,saida}$           | Potência de Saída                    |
| $P_{s,entrada}$         | Potência de Entrada                  |
| $\lambda_{bombeamento}$ | Comprimento de Onda de Bombeamento   |
| $\lambda_s$             | Comprimento de Onda do Sinal         |
| $P_{bombeamento,ent}$   | Potência de Bombeamento              |
| $\lambda_s$             | Comprimento de Onda do Sinal         |
| $F_n$                   | Figura de Ruído                      |

## SUMÁRIO

|              |                                                              |           |
|--------------|--------------------------------------------------------------|-----------|
| <b>1</b>     | <b>INTRODUÇÃO</b>                                            | <b>16</b> |
| <b>1.1</b>   | <b>Objetivos</b>                                             | <b>17</b> |
| <b>1.1.1</b> | <b>Objetivo Geral</b>                                        | <b>17</b> |
| <b>1.1.2</b> | <b>Objetivos Específicos</b>                                 | <b>18</b> |
| <b>2</b>     | <b>FUNDAMENTAÇÃO TEÓRICA</b>                                 | <b>19</b> |
| <b>2.1</b>   | <b>Comunicações Ópticas</b>                                  | <b>19</b> |
| <b>2.2</b>   | <b>Efeitos de Propagação em Fibras Ópticas</b>               | <b>20</b> |
| <b>2.2.1</b> | <b>Atenuação</b>                                             | <b>20</b> |
| 2.2.1.1      | Absorção do Material                                         | 21        |
| 2.2.1.2      | Espalhamento Rayleigh                                        | 21        |
| 2.2.1.3      | Imperfeições no Guia de Onda                                 | 22        |
| 2.2.1.4      | Curvaturas                                                   | 22        |
| <b>2.2.2</b> | <b>Dispersão de Sinal em Fibras</b>                          | <b>23</b> |
| 2.2.2.1      | Dispersão Cromática                                          | 24        |
| 2.2.2.2      | Dispersão Modal                                              | 24        |
| <b>2.2.3</b> | <b>Efeitos não lineares</b>                                  | <b>25</b> |
| 2.2.3.1      | Espalhamento Estimulado de Luz                               | 25        |
| 2.2.3.2      | Modulação de Fase Não Linear                                 | 25        |
| 2.2.3.3      | Mistura de Quatro Ondas                                      | 26        |
| <b>2.3</b>   | <b>Amplificadores Ópticos</b>                                | <b>26</b> |
| <b>2.3.1</b> | <b>Topologias de Amplificadores Ópticos</b>                  | <b>28</b> |
| 2.3.1.1      | Amplificador em Linha                                        | 28        |
| 2.3.1.2      | Pré Amplificador                                             | 28        |
| 2.3.1.3      | Amplificador Óptico na Topologia de Amplificador de Potência | 28        |
| <b>2.3.2</b> | <b>Amplificadores a Fibra Dopada com Érbio</b>               | <b>29</b> |
| 2.3.2.1      | Emissão Espontânea e Emissão Estimulada                      | 30        |
| 2.3.2.2      | Princípio de Funcionamento                                   | 31        |
| 2.3.2.3      | Arquitetura do EDFA                                          | 34        |
| 2.3.2.4      | Ganho do Amplificador                                        | 36        |
| 2.3.2.5      | Figura de Ruído                                              | 38        |
| <b>2.4</b>   | <b>Aprendizagem de Máquina</b>                               | <b>40</b> |

|                |                                                                           |           |
|----------------|---------------------------------------------------------------------------|-----------|
| <b>2.5</b>     | <b>Aprendizagem de Máquina Supervisionado e Não-Supervisionado . . .</b>  | <b>41</b> |
| <b>2.5.1</b>   | <b>Algoritmos Utilizados . . . . .</b>                                    | <b>42</b> |
| <b>2.5.1.1</b> | <i>Árvore de Decisão . . . . .</i>                                        | <i>42</i> |
| <b>2.5.1.2</b> | <i>Algoritmo Floresta Aleatória . . . . .</i>                             | <i>45</i> |
| <b>2.5.1.3</b> | <i>Gradient Boosting Regressor (GBR) . . . . .</i>                        | <i>47</i> |
| <b>2.5.1.4</b> | <i>Light Gradient Boosting (LightGBM) . . . . .</i>                       | <i>48</i> |
| <b>2.5.1.5</b> | <i>Extra Trees Regressor (ET) . . . . .</i>                               | <i>48</i> |
| <b>2.5.1.6</b> | <i>Extreme Gradient Boosting (XGBoost) . . . . .</i>                      | <i>49</i> |
| <b>2.5.1.7</b> | <i>Light Gradient Boosting Versus Extreme Gradient Boosting . . . . .</i> | <i>49</i> |
| <b>3</b>       | <b>ESTADO DA ARTE . . . . .</b>                                           | <b>51</b> |
| <b>3.1</b>     | <b>Análise dos trabalhos encontrados . . . . .</b>                        | <b>52</b> |
| <b>4</b>       | <b>MATERIAIS E MÉTODOS . . . . .</b>                                      | <b>55</b> |
| <b>4.1</b>     | <b>Materiais Utilizados: . . . . .</b>                                    | <b>55</b> |
| <b>4.1.1</b>   | <i>OptiSystem 7 . . . . .</i>                                             | <i>56</i> |
| <b>4.1.2</b>   | <i>Python PyCaret . . . . .</i>                                           | <i>57</i> |
| <b>4.2</b>     | <b>Metodologia Experimental . . . . .</b>                                 | <b>57</b> |
| <b>4.2.1</b>   | <i>Simulação da Rede EDFA com Varredura Multiparamétrica . . . . .</i>    | <i>57</i> |
| <b>4.2.2</b>   | <i>Tratamento e organização dos dados . . . . .</i>                       | <i>60</i> |
| <b>4.2.3</b>   | <i>Distribuição dos Percentuais de Holdout . . . . .</i>                  | <i>60</i> |
| <b>4.2.4</b>   | <i>Aplicação dos Algoritmos de Aprendizagem de Máquina . . . . .</i>      | <i>60</i> |
| <b>4.2.5</b>   | <i>Modelagem Inversa . . . . .</i>                                        | <i>61</i> |
| <b>4.3</b>     | <b>Metodologia para Avaliação dos Resultados . . . . .</b>                | <b>61</b> |
| <b>4.3.1</b>   | <i>Coefficiente de Determinação . . . . .</i>                             | <i>61</i> |
| <b>4.3.2</b>   | <i>Erro Médio Absoluto . . . . .</i>                                      | <i>62</i> |
| <b>4.3.3</b>   | <i>Erro Percentual Absoluto Médio . . . . .</i>                           | <i>62</i> |
| <b>4.3.4</b>   | <i>Erro Quadrático Médio . . . . .</i>                                    | <i>63</i> |
| <b>4.3.5</b>   | <i>Raiz do Erro Quadrático Médio . . . . .</i>                            | <i>63</i> |
| <b>4.3.6</b>   | <i>Raiz do Erro Quadrático Logarítmico Médio . . . . .</i>                | <i>64</i> |
| <b>5</b>       | <b>RESULTADOS . . . . .</b>                                               | <b>65</b> |
| <b>5.1</b>     | <b>Comparação Entre os Algoritmos . . . . .</b>                           | <b>65</b> |
| <b>5.1.1</b>   | <i>Nível de Importância dos Parâmetros . . . . .</i>                      | <i>68</i> |
| <b>5.2</b>     | <b>Análise gráfica . . . . .</b>                                          | <b>69</b> |
| <b>5.2.1</b>   | <i>Modelagem Direta . . . . .</i>                                         | <i>69</i> |

|         |                                                                               |    |
|---------|-------------------------------------------------------------------------------|----|
| 5.2.1.1 | <i>Potência de Entrada</i> . . . . .                                          | 70 |
| 5.2.1.2 | <i>Potência de Bombeamento</i> . . . . .                                      | 72 |
| 5.2.1.3 | <i>Comprimento da Fibra</i> . . . . .                                         | 74 |
| 5.2.1.4 | <i>Densidade do Nível de Érbio</i> . . . . .                                  | 76 |
| 5.2.2   | <b>Modelagem Inversa</b> . . . . .                                            | 78 |
| 5.2.2.1 | <i>Modelagem Inversa para a Potência Óptica do Sinal de Entrada</i> . . . . . | 79 |
| 5.2.2.2 | <i>Modelagem Inversa Para a Potência de Bombeamento</i> . . . . .             | 80 |
| 5.2.2.3 | <i>Modelagem Inversa Para o Comprimento da Fibra</i> . . . . .                | 82 |
| 5.3     | <b>Diferença de tempo de processamento</b> . . . . .                          | 84 |
| 5.4     | <b>Teste de <i>overfitting</i></b> . . . . .                                  | 85 |
| 6       | <b>CONCLUSÃO</b> . . . . .                                                    | 87 |
| 7       | <b>PROJETOS FUTUROS</b> . . . . .                                             | 88 |
|         | <b>REFERÊNCIAS</b> . . . . .                                                  | 89 |

## 1 INTRODUÇÃO

Com o constante desenvolvimento da tecnologia, e o advento da *Big Data*, ou seja, dados com maiores variedades, chegando em maiores volumes e com maiores velocidades, faz-se necessária a utilização de tecnologias e de sistemas cada vez mais rápidos. Rahman, Afrin e Taip (2018) cita que a rede optoeletrônica é o estado da arte para tecnologias que necessitam de altas taxas de transferência.

Todavia existe um problema inerente as comunicações ópticas: a atenuação, que consiste na perda de potência óptica ao longo do enlace óptico. Segundo Malakzadeh, Pashaie e Mansoursamaei (2020), o amplificador de fibra óptica dopada com érbio (*EDFA - do inglês, Erbium Doped Fiber Amplifier*) é reconhecido como um dos amplificadores mais importantes em sensores de fibras ópticas, os quais são amplamente utilizados para compensar a perda de potência óptica em enlaces ópticos, constituindo assim o principal recurso utilizado para contornar a atenuação.

O *EDFA* foi escolhido para este projeto por operar no comprimento de onda ideal para telecomunicações, o qual obtém a menor atenuação por quilômetro. Além disso, os relativamente baixos níveis de ruído dos *EDFAs* os tornam uma escolha ideal para os sistemas que utilizam multiplexação por divisão de comprimento de onda (*WDM - do inglês, Wavelength Division Multiplexing*), necessários para a transmissão de altas taxas de velocidade. Apesar do baixo ruído, o desempenho de sistemas de comunicação que empregam múltiplos *EDFAs* é, em geral, limitado pelo ruído do amplificador (AGRAWAL, 2014).

Os *EDFAs* podem ser modelados através de métodos numéricos, os quais ganho e figura de ruído (parâmetros essenciais dos amplificadores dopados com érbio, e fundamentais para se analisar uma rede óptica) podem ser calculados através de análises numéricas. Contudo, esse método requer cálculos densos e conhecimentos referentes aos parâmetros de fabricação das fibras dopadas (SADIK, 2022). Além disso, a complexidade matemática também exige um maior tempo de processamento requisitado pelo sistema.

Ademais, o mercado de aprendizagem de máquina vêm crescendo com o decorrer dos anos e se encontra cada vez mais consolidado, visto que estão sendo cada vez mais utilizados para solucionar problemas da atualidade de forma mais veloz, e eficiente. As técnicas de inteligência artificial (*IA - do inglês, Artificial Intelligence*) podem ser utilizadas como importantes aliadas no estudo de comunicações ópticas

Sadik (2022) reforça que a utilização de algoritmos de aprendizagem de máquina promove

uma abordagem que pode oferecer grande precisão, além de possuírem menor complexidade do que quando comparados com modelos analíticos em alguns problemas envolvendo redes ópticas. Nos últimos anos, aplicações de aprendizagem de máquina em sistemas ópticos vem crescendo cada vez mais. Rahman, Afrin e Taip (2018) cita que, com o advento da ciência de dados, vários setores de comunicações ópticas estão tentando se adaptar à aprendizagem de máquina.

No entanto, alguns parâmetros em sistemas ópticos não possuem relação linear ou direta, dessa forma, quando aplica-se uma variação multiparamétrica na rede não é possível estimar com êxito como esta variação irá influenciar no sinal óptico transmitido.

Partindo do que foi explicitado anteriormente, este projeto visa realizar por meio de simulação, uma varredura multiparamétrica de *EDFA*, varrendo diferentes parâmetros em diferentes faixas de valores, para analisar o seu comportamento e construir um banco de dados, que posteriormente será aplicado a diferentes algoritmos de aprendizagem de máquina, para dessa forma, verificar qual deles fornece o melhor desempenho para estimar o ganho e a figura de ruído do sistema. Também será realizado para a proposta inversa, ou seja, a partir do que antes eram parâmetros de saída (ganho e figura de ruído) será possível estimar parâmetros de entrada, tais como potência do sinal de entrada, potência de bombeamento e comprimento da fibra. Este projeto tem como objetivo criar sistemas cada vez mais aprimorados, precisos e otimizados. Podendo ser utilizados em projetos para a modelagem de amplificadores ópticos dopados com érbio, mas também como uma ferramenta de auxílio educacional e acadêmica, pois com ela, é possível demonstrar de maneira prática e intuitiva, como a variação multiparamétrica pode influenciar o amplificador em análise.

## **1.1 Objetivos**

A partir da introdução citada acima, são apresentados os objetivos desejados em relação a pesquisa.

### ***1.1.1 Objetivo Geral***

Analisar o uso de algoritmos de regressão para realizar a modelagem direta e inversa de amplificadores de fibras dopadas com érbio.

### 1.1.2 *Objetivos Específicos*

- a) Modelar e analisar, através do software de simulação *OptiSystem*, amplificadores ópticos dopados com érbio para observar como a variação dos parâmetros de entrada: potência de entrada do sinal, potência de bombeamento, comprimento da fibra óptica e nível de dopagem de érbio podem ser correlacionados com os parâmetros de saída: ganho e figura de ruído;
- b) Analisar o algoritmo que melhor se ajusta a bases de dados utilizada no projeto, obtendo o maior coeficiente de regressão e os menores parâmetros de erros e, verificando através de análises gráficas o desempenho do modelo desenvolvido em comparação com a base de dados simulada;
- c) Realizar a modelagem inversa do *EDFA*; Correlacionando os parâmetros de saída anteriores para estimar a potência do sinal de entrada, a potência de bombeamento, e o comprimento da fibra óptica;
- d) Analisar as métricas e desempenho referentes à modelagem inversa.

## 2 FUNDAMENTAÇÃO TEÓRICA

Nesse capítulo é apresentada a fundamentação teórica necessária para um melhor entendimento do projeto. Iniciando pelas vantagens das comunicações ópticas, seguida por uma introdução a amplificadores ópticos, suas características, topologias, princípio de funcionamento e parâmetros fundamentais. Além disso, também são abordados os efeitos lineares e não lineares que são inerentes a utilização de sistemas que utilizam fibras ópticas, e por fim, é abordada a definição de aprendizagem de máquina, seus tipos, e alguns dos algoritmos que foram utilizados no projeto.

### 2.1 Comunicações Ópticas

A motivação para o desenvolvimento dos sistemas de comunicações utilizando fibras ópticas se iniciou com o início do laser, no começo dos anos 60. As características operacionais do sistema encorajaram os pesquisadores a examinarem o espectro óptico como uma extensão do espectro do rádio e micro-ondas com o intuito de fornecer enlaces de transmissão com grandes capacidades. Além disso, também foi notado que outras propriedades das fibras ópticas implicavam em vantagens operacionais em relação aos fios de cobre, tais como:

- i) Transmissão a longas distâncias: fibras ópticas têm pequenas perdas de transmissão em comparação aos fios de cobre, isso significa que os dados podem ser enviados a longas distâncias, deste modo reduzindo a necessidade de repetidores necessários no enlace, diminuindo assim a complexidade e custo do sistema;
- ii) Longa capacidade de informação: fibras ópticas possuem bandas maiores que a dos cabos de cobre, o que permite que mais informação possa ser enviada em uma única linha física. Essa propriedade resulta na diminuição do número de linhas necessárias para enviar determinada quantidade de informação;
- iii) Tamanho pequeno e peso leve: o peso leve e as pequenas dimensões das fibras oferecem uma vantagem em relação ao peso e volume de cabos em dutos e cidades. Devido essa maior portabilidade e flexibilidade, também são de grande importância em aeronaves, satélites, navios. Além disso, também são utilizados em aplicações militares, em que uma grande quantidade de cabos deve ser desenrolada e recuperada rapidamente;
- iv) Imunidade a interferências eletromagnéticas: uma importante característica da fibra óptica

está relacionada ao fato de que ela é um material dielétrico, ou seja, ela não conduz eletricidade, isso a torna imune a interferências eletromagnéticas, que são comumente observadas em fios de cobre;

- v) Aumento da segurança: fibras ópticas não sofrem problemas com *loops* de terra (*ground loops*), faíscas ou tensões potencialmente altas decorrentes das linhas de cobre. Contudo, precauções devem ser respeitadas com a utilização de lasers, como uma forma de prevenir possíveis danos oculares;
- vi) Aumento da confiabilidade do sinal: a fibra óptica oferece um alto nível de segurança de dados, partindo do princípio que o sinal óptico é bem confinado dentro da fibra e qualquer vazamento de sinal é absorvido pelo revestimento ao redor da fibra. Ao contrário dos fios de cobre, os quais os sinais elétricos podem ser desligados facilmente. Essa característica a torna de extrema importância em aplicações financeiras, governamentais, e em sistemas militares (KEISER, 2014).

## 2.2 Efeitos de Propagação em Fibras Ópticas

### 2.2.1 Atenuação

A atenuação é inerente as comunicações ópticas de longas distâncias e consiste na perda de potência incidente no decorrer do enlace óptico. Ela é um fator limitante nas comunicações ópticas, pois esta reduz a potência óptica que chega ao dispositivo receptor, que necessita de uma potência mínima para que o sinal possa ser recuperado de maneira precisa. Dessa forma, a distância da transmissão é limitada pelas perdas na fibra. Com o advento de amplificadores ópticos na década de 1990, as distâncias de transmissão puderam ultrapassar milhares de quilômetros, por compensação periódica das perdas acumuladas. Contudo, fibras de baixas perdas ainda são necessárias, pois o espaçamento entre amplificadores é determinado pelas perdas na fibra. As duas maiores contribuições de perda no enlace são a absorção material e o espalhamento Rayleigh (AGRAWAL, 2014).

Em condições genéricas, variações na potência óptica média  $P$  de uma sequência de bits que se propaga no interior de uma fibra óptica são regidas pela lei de Beer:

$$\frac{dP}{dz} = -\alpha P, \quad (2.1)$$

em que  $z$  corresponde a distância propagada na fibra óptica e  $\alpha$  o coeficiente de atenuação, este inclui a absorção material, como também outras fontes de absorção de potência. Considerando  $P_{in}$ , a potência de entrada de uma fibra de comprimento  $L$ , a potência de saída  $P_{out}$  é obtida por:

$$P_{out} = P_{in} \exp(-\alpha L). \quad (2.2)$$

Além disso, é comum expressar o coeficiente  $\alpha$  em dB/km, utilizando a relação da (2.3), que passa a ser referido como parâmetro de perda da fibra (AGRAWAL, 2014).

$$\alpha(dB/km) = -\frac{10}{L} \log_{10} \left( \frac{P_{in}}{P_{out}} \right) \approx 4,343\alpha. \quad (2.3)$$

#### 2.2.1.1 Absorção do Material

A absorção do material pode ser dividida em duas categorias: intrínseca e extrínseca. Perdas por absorção intrínseca correspondem à absorção pela sílica fundida (material usado na fabricação de fibras), enquanto absorção extrínseca está relacionada às perdas causadas por impurezas na sílica. Qualquer meio material absorve energia em certos comprimentos de onda que correspondem às ressonâncias eletrônicas e vibracionais associadas a moléculas específicas. Para moléculas de sílica ( $\text{SiO}_2$ ), ressonâncias eletrônicas ocorrem na região de ultravioleta ( $\lambda < 0.4 \mu\text{m}$ ), enquanto as ressonâncias vibracionais ocorrem na região de infravermelho ( $\lambda > 0.7 \mu\text{m}$ ). Devido à natureza amorfa da sílica fundida, essas ressonâncias ocorrem na forma de bandas de absorção, cujas caudas se estendem até a região visível (AGRAWAL, 2014).

#### 2.2.1.2 Espalhamento Rayleigh

O espalhamento Rayleigh consiste em um mecanismo básico de atenuação em fibras ópticas, com origem em flutuações de densidade microscópicas que acontecem na fibra. Isso se deve por conta de moléculas de sílica que se movem de modo aleatório no estado fundido e, no processo de fabricação da fibra, ficam imobilizadas onde estiverem. Flutuações de densidade levam a flutuações aleatórias no índice de refração, em uma escala menor do que o comprimento de onda óptico  $\lambda$ . O espalhamento de luz em um meio desse tipo é conhecido como espalhamento Rayleigh (AGRAWAL, 2014).

A seção reta de espalhamento varia com  $\lambda^{-4}$ . Em consequência, a perda intrínseca de fibras de sílica devido ao espalhamento *Rayleigh* pode ser escrita por:

$$\alpha_R = \frac{c}{\lambda^4}, \quad (2.4)$$

sendo  $c$ , a velocidade da luz no vácuo e  $\lambda$ , o comprimento de onda, que neste caso corresponde a  $1,55 \mu\text{m}$ .

#### 2.2.1.3 Imperfeições no Guia de Onda

Uma fibra monomodo ideal com perfeita geometria cilíndrica guia o modo óptico sem fuga de energia para a camada da casca. Na prática, imperfeições na interface núcleo-casca (por exemplo, variações aleatórias no raio do núcleo) podem levar a perdas adicionais, que contribuem para a perda total na fibra. O processo físico responsável por tais perdas é o espalhamento Mie, que ocorre devido a não homogeneidades do índice de refração em uma escala maior do que o comprimento de onda óptico. Em geral, é tomado cuidado para assegurar que o raio do núcleo não varie de modo significativo ao longo do comprimento da fibra durante a fabricação. Tais variações podem ser mantidas abaixo de 1%, e a resultante perda por espalhamento é, tipicamente, menor do que 0,03 dB/km para o comprimento de onda de  $1,55 \mu\text{m}$  (AGRAWAL, 2014).

#### 2.2.1.4 Curvaturas


Curvaturas na fibra constituem outra fonte de perda por espalhamento. A razão para isso pode ser entendida usando a imagem de raios. Normalmente, um raio guiado atinge a interface núcleo-casca em um ângulo maior do que o ângulo crítico, para que sofra reflexão interna total. Contudo, o ângulo diminui nas proximidades de uma curvatura e, para curvaturas de pequenos raios, pode se tornar menor do que o ângulo crítico, e assim, o raio pode escapar da fibra.

Uma importante fonte de perdas em fibras, em particular na forma de cabos, está relacionada a distorções axiais aleatórias que ocorrem invariavelmente durante a instalação de cabos, quando a fibra é pressionada contra uma superfície que não é perfeitamente lisa. Tais perdas são referidas como perdas por microcurvaturas. Estas, causam um aumento nas perdas de fibras, tanto monomodo como multimodo, e podem resultar em perda excessivamente grande ( $\approx 100$  dB/km), se não forem tomadas precauções para minimizá-las (AGRAWAL, 2014).

### 2.2.2 Dispersão de Sinal em Fibras

Um sinal óptico enfraquece decorrente dos mecanismos de atenuação e se alarga temporalmente à medida que o sinal viaja ao longo de uma fibra. Eventualmente esses dois fatores vão causar uma sobreposição entre pulsos vizinhos e, depois de uma certa quantidade de ocorrências, o receptor não consegue mais distinguir individualmente os pulsos adjacentes e podem surgir erros ao se interpretar o sinal recebido (KEISER, 2014). O efeito da dispersão no sinal óptico pode ser visto na Figura 1.

Figura 1 – Efeitos da dispersão e atenuação em uma fibra óptica



Fonte: Adaptado de Keiser (2014).

- (a) Sinais de entradas, distintos;
- (b) Os pulsos começam a se sobrepôr, mas ainda podem ser facilmente distinguidos;
- (c) Os pulsos já se sobrepuseram consideravelmente e torna-se mais difícil de distingui-los;
- (d) Eventualmente as sobreposições se intensificam e os pulsos adjacentes tornam-se indistinguíveis.

### 2.2.2.1 Dispersão Cromática

Dispersão cromática ou intramodal, também conhecida como dispersão de velocidade de grupo (*GVD* - do inglês, *group velocity dispersion*), ela pode ser dividida em dois tipos: dispersão material e dispersão por guia de onda. A dispersão intramodal é decorrente de uma fonte óptica de largura espectral finita, pois como as fontes ópticas não são ideais, ou seja, não são perfeitamente monocromáticas, elas não emitem em um único comprimento de onda, mas em uma certa faixa de comprimentos. Estes que por serem distintos, possuem diferentes índices de refração em determinados momentos da fibra, observando a (2.5), é possível inferir que essa variação afeta diretamente a velocidade de propagação da luz no meio. Dessa forma, os comprimentos de onda trafegam com diferentes velocidades dentro da fibra, ocasionando o alargamento do sinal na fibra monomodo (KEISER, 2014).

$$v = \frac{c}{n}, \quad (2.5)$$

em que  $v$  corresponde a velocidade da luz no meio;  $c$  a velocidade da luz no vácuo, ou seja,  $3 \cdot 10^8$  m/s e  $n$  corresponde ao índice de refração.


### 2.2.2.2 Dispersão Modal

Dispersão modal ou intermodal ocorre somente em fibras multimodo. Este mecanismo de distorção de sinal é o resultado de cada modo ter um valor diferente de velocidade em uma única frequência. É possível observar o surgimento do atraso na Figura 2, ilustrando uma fibra multimodo de índice degrau. Também é possível observar que quanto maior for o ângulo de propagação da congruência dos raios, maior será o número de modos, e consequentemente, mais lenta será a velocidade do grupo axial. Essa variação de velocidades de grupo dos diferentes modos resulta em um atraso, conhecida como dispersão modal. O alargamento máximo do pulso decorrente do atraso modal é a diferença entre o tempo de viagem  $T_{max}$  dos caminhos de congruência de raios mais longos (o modo de ordem mais alta) e o tempo de viagem  $T_{min}$  dos caminhos de congruência de raios mais curtos (modo fundamental ou de ordem mais baixa) (KEISER, 2014). Este alargamento é obtido a partir do traçado de raios e, para uma fibra de comprimento  $L$ , dada por:

$$\Delta T = T_{max} - T_{min} = \frac{n_1}{c} \left( \frac{L}{\sin \phi} - L \right) = \frac{Ln_1^2}{cn_2} \Delta, \quad (2.6)$$

em que  $\sin \varphi_c$  corresponde a  $\frac{n_2}{n_1}$ , representando a divisão entre os índices de refração apresentados; e  $\Delta$  é a diferença de índice;  $c$  a velocidade da luz no vácuo e  $L$  o comprimento da fibra óptica.

Figura 2 – Representação da propagação de raios ópticos em um guia de onda óptico de índice de degrau ideal



Fonte: Adaptado de Keiser (2014).

### 2.2.3 Efeitos não lineares

#### 2.2.3.1 Espalhamento Estimulado de Luz

O espalhamento Rayleigh, discutido na Seção 2.2.1.2, é um exemplo de espalhamento elástico em que a frequência da luz espalhada permanece inalterada. Em contraste, durante o espalhamento inelástico, a frequência da luz espalhada é deslocada para baixo. Dois exemplos de espalhamentos inelásticos são espalhamento Raman e espalhamento Brillouin. Estes podem ser compreendidos como o espalhamento de um fóton para um fóton de menor energia, de modo que a diferença de energia aparece na forma de um fônon. A principal diferença entre esses dois tipos de espalhamento é que fônons ópticos participam no espalhamento Raman, enquanto fônons acústicos participam no espalhamento Brillouin. Os dois processos de espalhamento resultam em uma perda de potência na frequência. Contudo, as correspondentes seções retas de espalhamento são suficientemente pequenas para que, em baixos níveis de potência, a perda seja desprezível (AGRAWAL, 2014).

#### 2.2.3.2 Modulação de Fase Não Linear

Em altas intensidades, todos os materiais possuem comportamento não linear e seus índices de refração aumentam de acordo com a intensidade. A origem física para esse efeito reside

na resposta inarmônica de elétrons a campos ópticos, resultando em uma susceptibilidade não linear. Isso implica em um fenômeno conhecido como auto modulação de fase, que consiste na mudança da fase óptica com o tempo, exatamente da mesma forma que o sinal óptico, entretanto essa mudança referente a fase não linear é auto induzida. Além disso, há outro efeito também conhecido como modulação de fase cruzada, esse fenômeno ocorre em redes que utilizam a técnica de *WDM*, quando dois ou mais canais ópticos são transmitidos simultaneamente no interior de uma fibra óptica (AGRAWAL, 2014).

### 2.2.3.3 *Mistura de Quatro Ondas*

O fenômeno não linear conhecido com mistura de quatro ondas (*FWM - do inglês, Four-Wave Mixing*) pode ser associado com a intermodulação, pois por exemplo, se três campos ópticos com frequências portadoras distintas se propagarem simultaneamente na fibra óptica, será gerado um quarto campo cuja frequência está diretamente relacionada às outras frequências. Dessa forma podem ser geradas diferentes combinações dos sinais. Em sistemas comuns não há tanto risco devido a exigência do casamento de fase, entretanto em sistemas multicanais elas podem vir a ser mais problemáticas, pois podem quase alcançar a condição de casamento em um dos canais distribuídos (AGRAWAL, 2014).

## 2.3 Amplificadores Ópticos

Cokrak e Altuncu (2004) citam que a perda de potência óptica é um dos principais limitadores de comunicações ponto a ponto de enlaces de longas distâncias. Resultantes de absorção e espalhamento Brillouin, dessa forma, faz-se necessária a resolução deste problema, os amplificadores ópticos foram desenvolvidos em 1980 e se tornaram comerciais em 1990, permitindo que o sinal óptico fosse diretamente amplificado.


Até 1990, a técnica conhecida pelos projetistas para contornar problemas de perda de potência, consistiam na utilização de um regenerador optoeletrônico (comumente conhecido como repetidor) em enlaces de fibras ópticas a cada cerca de 80 km. O regenerador consiste em um dispositivo que combina receptor-transmissor, ele capta o sinal óptico incidente, converte para o domínio elétrico, amplifica o sinal e em seguida o converte para o domínio óptico novamente e dessa forma, é transmitido para o restante do enlace (AGRAWAL, 2014).

Segundo Cokrak e Altuncu (2004), repetidores elétricos eram necessários para compensar a perda de potência derivada do aumento da distância. Contudo, a sua utilização implicava no

aumento da complexidade da rede e nos seus custos de instalação.


Essa técnica acaba por ser muito custosa e trabalhosa quando se trata de sistemas *WDM*, pois faz-se necessário a demultiplexação dos canais individuais em cada repetidor. Uma solução mais simples e eficiente seria a utilização de amplificadores ópticos, este que é capaz de amplificar diversos canais *WDM* simultaneamente. São ilustrados nas Figuras 3 e 4 os amplificadores conectados em cascata, de modo periódico, formando assim uma cadeia e permitindo a transmissão de uma sequência de pulsos ópticos por distâncias de até 10.000 km, mantendo o sinal em sua forma óptica original (AGRAWAL, 2014).

Figura 3 – Diagrama em blocos do gerenciamento de perdas concentrada



Fonte: Adaptado de Agrawal (2014).

Figura 4 – Diagrama em blocos do gerenciamento de perdas distribuída



Fonte: Adaptado de Agrawal (2014).


Nas imagens acima, “Tx” e “Rx” designam transmissores e receptores ópticos, respectivamente. Os tipos mais significativos de amplificadores ópticos são amplificadores de lasers semicondutores, Raman, Brillouin e o de fibra dopada com terras raras (COKRAK; ALTUNCU, 2004).

### 2.3.1 Topologias de Amplificadores Ópticos

#### 2.3.1.1 Amplificador em Linha

Em um enlace monomodo, os efeitos da dispersão podem/devem ser pequenos, então a principal limitação para o espaço de instalação do repetidor é a atenuação da fibra. Desde que o enlace não faça necessária regeneração completa do sinal, uma simples amplificação do sinal óptico é suficiente. Portanto, a amplificação em linha, demonstrada na Figura 5, pode ser utilizada para compensar a perda da transmissão e aumentar a distância entre os repetidores regenerativos.

Figura 5 – Amplificador de linha



Fonte: Adaptado de Agrawal (2014).


#### 2.3.1.2 Pré Amplificador

É demonstrado através da Figura 6 o amplificador na topologia de pré amplificador, sendo utilizado antes do receptor óptico. O sinal óptico enfraquecido é amplificado antes do circuito de detecção para que assim a degradação da relação sinal ruído causada pelo ruído térmico na eletrônica do receptor possa ser suprimida. Comparado com outros dispositivos *front-end*, como fotodiodos de avalanche ou detectores ópticos heteródinos, um pré-amplificador óptico fornece um fator de ganho maior e uma largura de banda mais ampla.

#### 2.3.1.3 Amplificador Óptico na Topologia de Amplificador de Potência


Aplicações de amplificador de potência ou *booster* incluem a colocação do dispositivo imediatamente após um transmissor óptico para aumentar a potência transmitida, como mostra a Figura 7. Isso serve para aumentar a distância de transmissão de 10 a 100 km dependendo do ganho do amplificador e da perda da fibra.

Figura 6 – Amplificador óptico na topologia de pré-amplificador



Fonte: Adaptado de Agrawal (2014).

Figura 7 – Amplificador de potência



Fonte: Adaptado de Agrawal (2014).

### 2.3.2 Amplificadores a Fibra Dopada com Érbio

Segundo Yankov *et al.* (2021), enlaces de fibra óptica são frequentemente amplificados utilizando *EDFAs*. Estes são peças fundamentais em sistemas que compreendem redes de telecomunicações.

O meio ativo de um amplificador óptico consiste normalmente em uma fibra óptica de 10 a 30 m de comprimento a qual foi levemente dopada com um elemento de terras-raras, como érbio (Er), itérbio (Yb), túlio (Tm) ou praseodímio (Pr). O material da fibra hospedeira pode ser sílica, um vidro a base de flúor ou um vidro de teluretos (KEISER, 2014).

A região de operação desses dispositivos depende do material hospedeiro e dos elementos de dopagem. Um material comumente utilizado para aplicações de telecomunicações de longas distâncias é a fibra de sílica dopada com érbio, a qual é conhecida como amplificador óptico dopada com érbio ou *EDFA*. Em alguns casos itérbio é adicionado para aumentar a eficiência de bombeamento e o ganho do amplificador. A operação padrão de um *EDFA* normalmente é limitada a região de 1530 a 1565 nm. Na verdade, o fato dos *EDFA* operarem nessa banda do espectro é a origem do termo banda C ou banda convencional. Contudo várias técnicas podem ser apresentadas e utilizadas para estender a operação para a banda S e a banda L.

Apesar dos amplificadores com fibras dopadas terem sido estudados em 1964, seu

uso se tornou prático somente 25 anos depois, quando a técnica de fabricação dos mesmos foi aperfeiçoada. Entre as terras raras, érbio é o elemento mais prático para a realização de amplificadores a fibra que operem na região próxima de  $1,5 \mu\text{m}$ , e dessa forma, *EDFAs* tem sido estudados exhaustivamente. A utilização desses amplificadores em sistemas *WDM* após 1995 revolucionou a comunicação óptica, resultando em sistemas com capacidades superiores a 1 Tb/s (AGRAWAL, 2014).


### 2.3.2.1 Emissão Espontânea e Emissão Estimulada

Nesta sub-sessão será apresentada uma breve introdução ao conceito de emissão espontânea e emissão estimulada, ambas utilizadas nos dispositivos ópticos para a emissão da luz, com o intuito de gerar uma melhor compreensão sobre o próximo tópico.

Independente do tipo do laser, o princípio de operação é o mesmo, a ação do laser é o resultado de três processos: absorção do fóton, emissão espontânea e a emissão estimulada. Esses processos são representados na Figura 8, em que  $E_1$  é a chamada energia do estado fundamental e  $E_2$  a energia do estado excitado. De acordo com a lei de Planck, a transição entre esses dois estados envolve a absorção ou a emissão de um fóton de energia  $h\nu_{12} = E_2 - E_1$ . Normalmente, o estado fundamental representa o sistema. Quando um fóton de energia  $h\nu_{12}$  interage com o sistema, o elétron no estado  $E_1$  pode absorver a energia do fóton e ser excitado ao estado  $E_2$ , ilustrado na Figura 8a. No entanto o estado  $E_2$  é um estado instável e o elétron, em um curto espaço de tempo, voltará ao estado fundamental, dessa forma, emitindo um fóton de energia  $h\nu_{12}$ . Isso ocorre sem qualquer estímulo externo e é conhecido como emissão espontânea, representado na Figura 8b. Essas emissões são isotrópicas e com fase aleatória.

O elétron também pode ser induzido a fazer a transição da banda de excitação para a fundamental através de uma estímulo externo, como ilustrado na Figura 8c, se o fóton de energia  $h\nu_{12}$  incide sobre o sistema, enquanto o elétron ainda está no estado excitado, o elétron é estimulado a cair para o estado fundamental e emite um fóton de energia  $h\nu_{12}$ . Esse fóton emitido está em fase com o fóton incidente, esse par de fótons são popularmente conhecidos como fótons gêmeos e a emissão resultante é conhecida como emissão estimulada.

Figura 8 – Os processos necessários para a ação do laser



Fonte: Adaptado de Keiser (2014).

Em equilíbrio térmico a densidade dos elétrons excitados é muito pequena. A maioria dos fótons incidentes no sistema serão absorvidos, então a emissão estimulada é essencialmente desprezível. A emissão estimulada vai exceder a absorção apenas se a população (número de elétrons) do estado de excitação for maior do que o estado fundamental. Essa condição é conhecida como inversão de população.

Esta, não se trata de uma condição de equilíbrio, a inversão de população é alcançada através de varias técnicas de bombeamento. Em um laser semicondutor, ela é alcançada através da injeção de elétrons dentro do material pelos contatos do dispositivo ou por meio de um método de absorção óptica por meio de fótons injetados externamente.


### 2.3.2.2 Princípio de Funcionamento

Assim como é utilizada uma corrente externa para excitar os elétrons a níveis mais altos de energia nos amplificadores ópticos semicondutores, faz-se necessário para os amplificadores de fibra óptica, a utilização do bombeamento óptico. Nesse processo, utilizam-se fótons para elevar os elétrons ao estado de excitação.

O processo de bombeamento óptico requer pelo menos três níveis de energia. O nível superior, o qual o elétron é elevado inicialmente, deve ser energeticamente acima do nível de emissão final desejado. Após alcançar o estado inicial de excitação, o elétron deve rapidamente liberar energia e cair para um nível de energia levemente inferior. O fóton de sinal pode servir de gatilho para então acionar o elétron estacionário neste nível mais baixo em emissão estimulada, em que o elétron libera sua energia restante na forma de um novo fóton com um comprimento de onda idêntico ao do fóton de sinal. Como o fóton de bombeamento deve ter uma energia maior do que o fóton de sinal, o comprimento de onda do bombeamento é menor do que o comprimento de onda do sinal.

Para entender o funcionamento de como um *EDFA* funciona, é necessário observar o nível

Figura 9 – Diagrama de níveis de energia para íons de  $Er^{3+}$  em fibras ópticas (de sílica)



Fonte: Keiser (2014).

de energia da estrutura do érbio. Os átomos de érbio na sílica são íons  $Er^{3+}$ , cujo são átomos que já perderam 3 de seus elétrons externos. Ao descrever as transições dos elétrons externos nesses íons para estados de energia, é comum referir-se ao processo como “aumentar os íons a níveis de energia mais altos”. A Figura 9 mostra um diagrama de níveis de energia e os vários processos de transição para o íon  $Er^{3+}$ . Os dois níveis principais para aplicações de telecomunicações são o nível metaestável (b) e o nível da bombeamento (a). O termo “metaestável” significa que os tempos de vida para transições deste estado para o estado fundamental são muito longas em comparação com os tempos de vida dos estados que levaram a esse nível.

Os níveis metaestável, do bombeamento e do estado fundamental são, na verdade, bandas de níveis de energia pouco espaçadas que formam uma distribuição decorrente de um efeito conhecido como Separação Stark. Além disso, cada nível Stark é ampliado por efeitos térmicos em uma faixa quase contínua. Para entender as várias transições de energia e faixas de emissão de fótons, considere as seguinte condições:

1 - A banda de bombeamento na parte esquerda da Figura 9 existe a 1,27-eV separado da parte fundamental, ou seja, da (c). Essa energia corresponde a um comprimento de onda de 980 nm.

2 - O topo da banda metaestável (b) é separado da parte inferior da banda do estado fundamental (nível c) em 0,841 eV. Esta energia corresponde a 1480 nm comprimento de onda.

3 - A parte inferior da banda metaestável (nível b) é separada da parte inferior da (c)

banda do estado fundamental em 0,814 eV. Esta energia corresponde ao comprimento de onda de 1530 nm.

4 - A parte inferior da banda metaestável (nível b) é separada da parte superior da banda do estado fundamental (nível c) em cerca de 0,775 eV. Esta energia corresponde ao comprimento de onda 1600 nm.

Isso significa que os comprimentos de onda possíveis para o bombeamento são 980 e 1480 nm. Os fótons emitidos durante as transições dos elétrons entre os níveis de energia da banda metaestável e da banda fundamental possuem uma faixa de 1530 a 1600 nm.

Em uma operação normal, o laser de bombeamento emitindo fotos de 980 nm, é utilizado para excitar os íons do estado fundamental para o nível de bombeamento, como mostrado no processo 1, na Figura 9. Esses íons excitados decaem/relaxam muito rapidamente (em torno de 1 microssegundo) e caem da zona de bombeamento para a metaestável, como mostrado no processo 2. Durante esse decaimento, o excesso de energia é liberado como fônons, que são vibrações mecânicas que acontecem na fibra óptica.

Outro bombeamento possível é o de 1480 nm. A energia desses fótons de bombeamento é muito similar a energia do sinal de fóton, porém levemente superior. A absorção do fóton de bombeamento de 1480 nm excita o elétron do estado de fundamental diretamente para a zona de metaestável, como mostra o processo 3 da Figura 9. Esses elétrons então, tendem a se mover para baixo para a extremidade inferior e mais populosa do nível metaestável (transição 4).


Alguns dos íons situados no nível metaestável podem decair de volta ao estado fundamental na ausência de um fluxo de fótons externamente estimulante, como mostrado pelo processo de transição 5. Esse fenômeno de decaimento é conhecido como emissão espontânea e é responsável por aumentar o ruído no amplificador.

Mais dois tipos de transições ocorrem quando um fluxo de fótons de sinal que têm energias correspondentes à energia de *bandgap* entre o estado fundamental e o nível metaestável passa pelo dispositivo. Primeiro, uma pequena porção dos fótons externos será absorvida por íons no estado fundamental, o que eleva esses íons para o nível metaestável, conforme mostrado pelo processo de transição 6.

Em segundo lugar, no processo da emissão estimulada (transição 7) um fóton de sinal aciona um íon excitado para cair para o estado fundamental, desse modo emitindo um novo fóton com a mesma energia, vetor de onda e polarização que o fóton de sinal recebido. As larguras dos níveis metaestáveis e do estado fundamental permitem a ocorrência de altos níveis de emissões estimuladas na faixa de 1530 a 1560 nm.

As respostas de absorção e emissão de um *EDFA* dependem da composição do vidro hospedeiro e dos tipos de dopantes, como germânio (Ge) e alumínio (Al), no vidro. É representado na Figura 10, um exemplo para uma sílica de vidro dopada com Ge que tem co-dopantes de Al adicionados. Os átomos de Al ajudam a absorver os íons Er no vidro e ampliam o espectro de ganho do amplificador. Observe que há uma resposta de pico de ganho em 1532 nm e uma região de 20 a 30 nm em comprimentos de onda mais longos em que o ganho é relativamente plano. Além de 1560 nm, o ganho diminui constantemente até atingir 0 dB (ganho unitário) por volta de 1616 nm.

Figura 10 – Absorção e ganho espectral para íons de érbio em uma fibra de sílica dopada com germânio e alumínio



Fonte: Keiser (2014).


### 2.3.2.3 Arquitetura do EDFA

Um amplificador óptico dopado com érbio consiste em uma fibra dopada, um ou mais lasers de bombeamento, um acoplador passivo de comprimento de onda, isoladores ópticos, e acopladores de derivação, como mostrado na Figura 11. Os isoladores ópticos previnem que o sinal amplificado reflita de volta ao dispositivo, o que poderia aumentar o ruído do amplificador, diminuir a eficiência do mesmo, e até mesmo danificar a fonte óptica.

O laser de bombeamento é geralmente injetado na mesma direção do fluxo do sinal. Esse

sistema, demonstrado pela Figura 11a, é conhecido como bombeamento codirecional. Também é possível injetar a potência de bombeamento na direção contrária ao fluxo, que é comumente conhecido como bombeamento reverso. Como mostrado na Figura 11, pode-se utilizar tanto uma única fonte de bombeamento quanto um esquema de bombeamento duplo, que como resultado tem ganhos típicos de +17 dB e +35dB respectivamente. Os amplificadores que operam na topologia reversa, ilustrados pela Figura 11b, permitem ganhos maiores, porém os codirecionais possuem melhores performances em relação ao ruído. Além disso, o bombeamento em 980 nm é preferível, pois produz menos ruído e alcança uma maior inversão de população que 1480 nm (KEISER, 2014).

Figura 11 – Os três tipos de configuração de um *EDFA*: a) codirecional, b) bombeamento reverso e c) bombeamento bidirecional



Fonte: Keiser (2014).

### 2.3.2.4 Ganho do Amplificador

Um dos parâmetros que caracteriza um amplificador óptico é o seu ganho de sinal ou ganho de amplificação ( $G$ ), definido por (2.7).

$$G = \frac{P_{s,saida}}{P_{s,entrada}}, \quad (2.7)$$

em que  $P_{s,entrada}$  e  $P_{s,saida}$  representam respectivamente a potência de entrada e de saída do amplificador óptico. Assim como qualquer tipo de amplificador, a magnitude do sinal de saída do *EDFA* eventualmente começa a saturar. A redução do ganho em um *EDFA* acontece quando há uma redução significativa na inversão de população devido a um sinal de grande largura.

As potências de entrada e saída de um amplificador *EDFA*, podem ser expressas em termos do princípio de conservação de energia:

$$P_{s,saida} \leq P_{s,entrada} + \frac{\lambda_{bombeamento}}{\lambda_s} P_{bombeamento,entrada}, \quad (2.8)$$

em que,  $P_{bombeamento,entrada}$  é a potência de bombeamento de entrada, e  $\lambda_{bombeamento}$  e  $\lambda_s$ , indicam os comprimentos de onda de bombeamento e o de sinal respectivamente. O princípio físico fundamental é que a quantidade de energia do sinal que pode ser extraído de um *EDFA*, não ultrapasse a energia de bombeamento armazenada no dispositivo. A desigualdade na (2.8) citada anteriormente indica a possibilidade de perda de fótons de bombeamento por diversas causas, tais como interação com impurezas ou perdas através da emissão espontânea (KEISER, 2014).

Através de (2.8), é possível inferir que a potência máxima do sinal de saída depende da relação  $\lambda_{bombeamento}/\lambda_s$ . Para o “esquema” de bombeamento funcionar, é preciso que o comprimento de onda de bombeamento seja menor que o comprimento de onda do sinal. Além disso, para que haja um ganho adequado, é necessário que a potência de entrada do sinal seja menor ou igual a potência de bombeamento. Dessa forma, a eficiência de potência (*PCE*), definida na (2.9) é menor que a unidade (KEISER, 2014).

$$PCE = \frac{P_{s,saida} - P_{s,entrada}}{P_{bombeamento,entrada}} = \frac{P_{s,saida}}{P_{bombeamento,entrada}} \leq \frac{\lambda_{bombeamento}}{\lambda_s} \leq 1. \quad (2.9)$$

O máximo valor teórico da *PCE* é  $\lambda_{bombeamento}/\lambda_s$ . Para referência absoluta, é útil utilizar a eficiência de conversão quântica (*QCE*), que é independente do comprimento de onda e definida por:

$$QCE = \frac{\lambda_{\text{signal}}}{\lambda_{\text{bombamento}}} PCE. \quad (2.10)$$

O valor máximo de  $QCE$  é a unidade, cujo esta indica que todos os fótons de bombeamento são convertidos em fótons de sinal. Também podemos reescrever a (2.8) em termos do ganho do amplificador. Assumindo que não há emissão espontânea, o ganho  $G$  é ilustrado por (2.11) abaixo:

$$G = \frac{P_{s,\text{saida}}}{P_{s,\text{entrada}}} \leq 1 + \frac{\lambda_{\text{bombamento}} P_{\text{bombamento,entrada}}}{\lambda_s P_{s,\text{entrada}}} \quad (2.11)$$

Isso mostra uma importante relação entre a potência do sinal de entrada e o ganho. Quando a potência do sinal de entrada é grande de modo que  $P_{s,\text{entrada}} \gg \left( \frac{\lambda_{\text{bombamento}}}{\lambda_s} \right) P_{\text{bombamento,ent}}$ . Dessa forma, o ganho máximo do amplificador é a unidade. Isso ilustra que o dispositivo é transparente ao sinal. Partindo da (2.11), com o objetivo de alcançar um ganho específico máximo  $G$ , a potência de sinal entrada não pode exceder o valor dado por

$$P_{s,\text{entrada}} \leq \frac{(\lambda_{\text{bombamento}}/\lambda_s) P_{\text{bombamento,entrada}}}{G - 1}. \quad (2.12)$$

Além da potência de bombeamento, o ganho também depende do comprimento da fibra. O ganho máximo em um laser de três níveis de comprimento  $L$ , como um *EDFA*, é dado por:

$$G = \exp(\rho \sigma_e L), \quad (2.13)$$


onde  $\sigma_e$  representa a secção transversal de emissão do sinal, e  $\rho$  é a concentração de dopagem de terras-raras, no caso deste projeto, o érbio. Para determinar o ganho máximo, deve-se considerar (2.11) e (2.12) em conjunto. Portanto, o ganho máximo de um *EDFA* é dado pelo mínimo das duas expressões de ganho:

$$G \leq \min \left\{ \exp(\rho \sigma_e L), 1 + \frac{\lambda_{\text{bombamento}}}{\lambda_s} \frac{P_{\text{bombamento,entrada}}}{P_{s,\text{entrada}}} \right\}. \quad (2.14)$$

Na Figura 12, é ilustrado o surgimento da saturação do ganho para vários comprimentos de fibras dopadas à medida que a potência de bombeamento aumenta. O ganho foi medido com um sinal de entrada óptica de 100 nW, no comprimento de onda de 1550 nm. Na medida em que

o comprimento da fibra aumenta para os baixos valores de potência de bombeamento, o ganho começa a diminuir após certo comprimento, isso acontece devido o bombeamento não possuir energia o suficiente para criar a inversão de população completa na parte do sentido de fluxo do amplificador. Nessa ocasião, a região não bombeada da fibra, absorve o sinal, o que resulta em perda de sinal nessa seção, em vez de ganho (KEISER, 2014).

Figura 12 – Relação da dependência do ganho com o aumento do comprimento da fibra e da potência de bombeamento



Fonte: Keiser (2014).

#### 2.3.2.5 Figura de Ruído

O ruído do amplificador é o principal fator de limitação para aplicações em sistemas. Todos os amplificadores degradam a relação sinal-ruído ( $SNR$ ) do sinal amplificado, devido à emissão espontânea que adiciona ruído ao sinal durante a amplificação. Em função dessa emissão espontânea amplificada ( $ASE$ ), a  $SNR$  é degradada, sendo a extensão da degradação quantificada por um parâmetro  $F_n$ , denominado figura de ruído do amplificador. Em analogia com amplificadores elétricos,  $F_n$  é definida por:

$$F_n = \frac{(SNR)_{in}}{(SNR)_{out}}. \quad (2.15)$$

No geral,  $F_n$  depende de vários fatores que envolvem o ruído térmico associado ao detector. Contudo, é possível chegar a uma simples função de  $F_n$  considerando um detector ideal, limitado apenas pelo ruído de disparo (shot noise).

Considerando o ganho do amplificador  $G$ , e que as potências de saída  $P_{out}$  e a potência de entrada  $P_{in}$  sejam relacionadas por  $P_{out} = GP_{in}$ . A  $SNR$  de entrada ou  $(SNR)_{in}$  é descrita por:

$$(SNR)_{in} = \frac{P_{in}}{2Gh\nu\Delta\nu}. \quad (2.16)$$

Para calcular a  $SNR$  do sinal amplificado, deve-se acrescentar a contribuição da  $ASE$  ao ruído do receptor. A densidade espectral de ruído  $ASE$  é praticamente constante (ruído branco) e é descrita por:

$$(S)_{ASE}(V) = n_{sp}h\nu(G - 1), \quad (2.17)$$

em que  $n_{sp}$ , consiste no fator de emissão espontânea (ou fator de inversão de população), e é dado por:

$$n_{sp} = \frac{n_2}{n_2 - n_1}, \quad (2.18)$$

em que  $n_1$  e  $n_2$  configuram as populações atômicas para os estados básico e excitado, respectivamente. O efeito de emissão espontânea adiciona flutuações ao sinal amplificado, aos quais durante a detecção, são convertidos em flutuações de corrente. A contribuição principal do ruído advém do batimento da emissão espontânea com o sinal.

$$(SNR)_{out} = \frac{GP_{in}}{(4S_{ASE} + 2h\nu)\Delta f}. \quad (2.19)$$

Portanto, a figura de ruído pode ser obtida substituindo (2.16) e (2.19) em (2.15), resultando na expressão:


$$F_n = 2n_{sp} \left( 1 - \frac{1}{G} \right) + \frac{1}{G} \approx 2n_{sp}. \quad (2.20)$$

A (2.20) é válida para  $G \gg 1$ , ou seja, ela demonstra que mesmo para um amplificador ideal com  $n_{sp}$  unitária, o sinal amplificado é degradado em 3 dB. Para a maioria dos amplificadores práticos, a figura de ruído será maior que 3 dB, podendo alcançar 6 a 8 dB.

Segundo Cokrak e Altuncu (2004), podemos concluir que a figura de ruído depende diretamente da potência e do ganho do ASE. A figura de ruído aumenta com o aumento da potência ASE, e diminui com o aumento do ganho.

Na Figura 13 é possível perceber que com o aumento da potência de bombeamento, há também, o aumento do ganho, e consequentemente, a redução da figura de ruído.

Figura 13 – Gráficos de figura de ruído e ganho dos amplificadores em função do comprimento de onda para diversos valores de bombeamento



Fonte: Agrawal (2014).

Keiser (2014) também cita que um bombeamento com o comprimento de onda de 980 nm produz uma inversão de população completa e por conta disso é possível obter menores figuras de ruídos para amplificadores de comprimento mais curto quando comparada ao de 1480 nm.

Os níveis relativamente baixos de ruído dos *EDFAs* os tornam uma escolha ideal para sistemas de comunicações ópticas *WDM*. Apesar do baixo ruído, o desempenho de sistemas de comunicação por fibra óptica de longa distância que empregam múltiplos *EDFAs* é, em geral, limitado pelo ruído do amplificador.

## 2.4 Aprendizagem de Máquina

Nas últimas décadas, com a crescente complexidade dos problemas a serem tratados computacionalmente e dos grandes volumes de dados gerados em diversos setores, tornou-se clara a necessidade de ferramentas computacionais mais sofisticadas, que fossem otimizadas, e consideravelmente mais autônomas, dessa forma reduzindo a intervenção humana e a dependência de especialistas. Para isso, essas técnicas deveriam ser capazes de criar por si próprias,

a partir da experiência passada, uma hipótese, ou função, capaz de resolver o problema que se deseja solucionar. Um exemplo simples é a descoberta de uma hipótese na forma de uma regra ou conjunto de regras para definir que clientes de um determinado supermercado devem receber propagandas de um produto específico, baseando-se no histórico de compras dos clientes cadastrados na base de dados do supermercado. A esse processo de formulação de uma hipótese ou função, a partir de um conjunto de experiências prévias, dá-se o nome Aprendizado de Máquina (*ML* - do inglês, *Machine Learning*) (HARRISON, 2019).

## 2.5 Aprendizagem de Máquina Supervisionado e Não-Supervisionado

Os algoritmos de *ML* são utilizados para solucionar diversas tarefas e que podem ser organizados seguindo diferentes critérios. Um deles diz respeito ao paradigma de aprendizado a ser adotado para lidar com a tarefa. De acordo com esse critério, as tarefas de aprendizado podem ser divididas em: preditivas e descritivas.

Em tarefas que envolvem previsão, a meta é encontrar uma função (também chamada de modelo ou hipótese) a partir dos dados de treinamento que possa ser utilizada para prever determinado resultado ou valor que caracterize um novo exemplo, com base nos valores de seus atributos de entrada. Para isso, cada objeto do conjunto de treinamento deve possuir atributos de entrada e de saída.

Os algoritmos ou métodos de *ML* utilizados nessa tarefa induzem modelos preditivos. Esses algoritmos seguem o paradigma de aprendizado supervisionado. O termo supervisionado vem da simulação da presença de um “supervisor externo”, que conhece a saída (rótulo) desejada para cada exemplo (conjunto de valores para os atributos de entrada). Com isso, o supervisor externo pode avaliar a capacidade da hipótese induzida de estimar o valor de saída para novos exemplos.

Em tarefas descritivas, a meta é explorar ou descrever um conjunto de dados. Os algoritmos de *ML* utilizados nessas tarefas não fazem uso do atributo de saída, por isso seguem o paradigma de aprendizado não supervisionado. Uma tarefa descritiva de agrupamento de dados, por exemplo, tem por meta encontrar grupos de objetos semelhantes no conjunto de dados. Outra tarefa descritiva é encontrar regras de associação que relacionam um grupo de atributos a outro grupo de atributos.

Na figura 14 é ilustrado uma hierarquia de aprendizado de acordo com os tipos de tarefas de aprendizado. No topo tem-se o aprendizado indutivo, processo pelo qual são realizadas as

Figura 14 – Hierarquia da aprendizagem de máquina supervisionado e não supervisionado



Fonte: Adaptado de Carvalho *et al.* (2011)

generalizações a partir dos dados. Tem-se em seguida os tipos de aprendizado supervisionado (preditivo) e não supervisionado (descritivo). As tarefas supervisionadas se distinguem pelo tipo dos rótulos dos dados: discreto, no caso de classificação; e contínuo, no caso de regressão. As tarefas descritivas são genericamente divididas em: agrupamento, em que os dados são agrupados de acordo com a sua similaridade; sumarização, cujo objetivo é encontrar uma descrição simples e compacta para um conjunto de dados; e associação, que consiste em encontrar padrões frequentes de associações entre os atributos de um conjunto de dados.

### 2.5.1 Algoritmos Utilizados


Nesse seção serão abordados os 5 algoritmos que obtiveram melhor desempenho na modelagem direta e inversa do amplificador proposto. Durante a análise dos algoritmos, foi possível observar que geralmente os modelos de melhor performance se repetiam, e as vezes alternavam entre o *gradient boosting* e a árvore de decisão (*Decision Tree*).

#### 2.5.1.1 Árvore de Decisão

A árvore é um tipo de grafo que consiste em uma estrutura de dados composta por uma coleção de nós e arestas organizadas hierarquicamente. Os nós são divididos em nós internos e nós folhas. É ilustrado na Figura 15 o exemplo de uma árvore binária, ou seja, onde cada nó possui apenas duas saídas.

Já a árvore de decisão, consiste em um conjunto de questionamentos organizados hierarquicamente e representados graficamente como uma árvore. Para um objeto inserido, a árvore de

Figura 15 – Estrutura de árvore binária genérica




Fonte: Adaptado de Criminisi *et al.* (2012).

decisão estima os parâmetros desconhecidos desse objeto através de sucessivas perguntas sobre suas propriedades conhecidas. As perguntas subsequentes dependem da resposta da pergunta anterior, e essa relação é representada graficamente como um caminho através da árvore. A decisão se baseia no nó terminal ou nó folha, situado no final do sistema.

Para exemplificar, utilizamos a Figura 16. Neste exemplo, existe uma fotografia e a partir dela, deseja-se desenvolver um algoritmo que automaticamente defina se a imagem está dentro de casa ou se a imagem está do lado de fora, ao ar livre. Nesse contexto, não se possui nenhuma informação além dos *pixels* da imagem. Dessa forma, pode ser iniciado observando a parte superior da imagem, e perguntando ao algoritmo se esta é ou não azul, a partir disso, pode-se cogitar que trata-se do céu no topo da imagem. Posteriormente, é realizada outra pergunta, também questionando sobre a cor azul, mas agora referente a parte inferior da imagem, se a resposta for não, a chance de ser o céu torna-se maior, porém se a resposta for sim, existe um alto risco de se estar analisando uma parede ou um muro azul (CRIMINISI *et al.*, 2012).

Figura 16 – Exemplo de árvore de decisão



Fonte: Adaptado de Criminisi *et al.* (2012).

Esse algoritmo consiste na utilização da estratégia de “dividir para conquistar” para resolver um problema de decisão. Um problema complexo é dividido em problemas mais simples, aos quais recursivamente são aplicadas as mesmas estratégias. As soluções dos subproblemas formados podem ser combinadas, no formato de uma árvore, para produzir uma solução do problema mais complexo. A força dessa proposta vem da capacidade de dividir o espaço de instâncias em subespaços e cada subespaço é ajustado usando diferentes modelos (CARVALHO *et al.*, 2011).

Todas essas perguntas/testes ajudam o objeto a percorrer até o espaço de decisão correto, além de aumentar a confiabilidade da resposta. Uma árvore de decisão é um grafo acíclico direcionado em que cada nó ou é um nó de divisão, com dois ou mais sucessores, ou um nó folha.

O nó folha é rotulado com uma função. Usualmente são considerados apenas os valores da variável alvo nos exemplos que chegam a um nó folha. No caso mais simples, a função é a constante que minimiza a função de custo. Em problemas de classificação, e assumindo a função

de custo 0-1, essa constante é a moda. Em problemas de regressão, a constante que minimiza a função de custo do erro médio quadrático é a média, enquanto para a função de custo do desvio absoluto é a mediana (CARVALHO *et al.*, 2011).

### 2.5.1.2 Algoritmo Floresta Aleatória


Floresta Aleatória é um algoritmo que combina a saída de vários grupos de árvores de decisão. No entanto, existem algumas diferenças entre os dois. Uma árvore de decisão tende a criar regras, que ela usa para tomar decisões. Uma floresta aleatória escolherá aleatoriamente os recursos e fará observações, construirá uma floresta de árvores de decisão e, em seguida, calculará a média dos resultados. A teoria é que um grande número de árvores não correlacionadas criará previsões mais precisas do que uma árvore de decisão individual. Isso ocorre porque o volume de árvores trabalha em conjunto para proteger cada uma de erros individuais e *overfitting*. Além disso, sua simplicidade e flexibilidade o faz ser amplamente utilizado em diversos problemas de regressão e classificação.

Eles possuem três parâmetros principais, os quais devem ser definidos antes do treinamento. Estes são: o tamanho do nó, o número de árvores e o número de recursos amostrados. Para aplicações de regressão no *Azure* (citado no Capítulo 4 na Seção 4.1) ainda são adicionados mais dois parâmetros: profundidade das árvores de decisão e número de divisões por nó, como ilustrados na Figura 17.

Os métodos de combinação (*ensemble*) de aprendizado são compostos por um conjunto de classificadores, como por exemplo, as árvores de decisão citadas anteriormente. Suas previsões são agregadas e analisadas para identificar o resultado mais popular. O método de combinação mais conhecido é o “*bagging*”. Neste método, uma amostra aleatória de dados em um conjunto de treinamento é selecionada com uma substituição, significando que os pontos de dados individuais podem ser escolhidos mais de uma vez. Após gerar várias amostras de dados, esses modelos são treinados de forma independente e, de acordo com o tipo de tarefa, como por exemplo, regressão ou classificação, a média ou a maioria dessas previsões geram uma estimativa mais precisa. Essa abordagem é geralmente utilizada para reduzir a variância dentro de um conjunto de dados ruidoso.

A floresta aleatória consiste em um conjunto de árvores de decisão treinadas em combinações aleatórias de recursos e amostras aleatórias de dados. A floresta aleatória obtém uma média destas árvores de decisão geradas aleatoriamente para criar a melhor árvore. Este conceito

Figura 17 – Parâmetros Random Forest



The image shows a configuration panel for 'Decision Forest Regression' in Azure Studio ML. It contains several settings, each with a label, a value field, and a menu icon (three horizontal lines) to its right. The settings are: 'Resampling method' set to 'Bagging'; 'Create trainer mode' set to 'Single Parameter'; 'Number of decision trees' set to '8'; 'Maximum depth of the decision trees' set to '32'; 'Number of random splits per node' set to '128'; and 'Minimum number of samples per leaf node' set to '1'.


| Parameter                               | Value            |
|-----------------------------------------|------------------|
| Resampling method                       | Bagging          |
| Create trainer mode                     | Single Parameter |
| Number of decision trees                | 8                |
| Maximum depth of the decision trees     | 32               |
| Number of random splits per node        | 128              |
| Minimum number of samples per leaf node | 1                |

Fonte: Retirado do *Azure Studio ML*

de treinar aprendizes fracos (*weak learners*) em paralelo e combiná-los usando um processo de média é chamado de *bagging*. Este consiste em um método “*ensemble*”, pois ele combina mais de um modelo (geralmente, chamados de *weak learners*) resultando em um modelo mais forte (*strong learners*). Além de *bagging*, existem outros dois métodos de combinação, conhecidos como “*boosting*” e “*stacking*” (MASÍS, 2023).

O algoritmo de floresta aleatória utiliza tanto o *bagging* quanto a aleatoriedade de recursos para criar uma floresta de árvores de decisão não correlacionadas. Aleatoriedade de recursos, também conhecido como *bagging* de recursos ou “o método de subespaço aleatório”, gera um subconjunto aleatório de recursos, que garante baixa correlação entre as árvores de decisão. Esta é uma principal diferença entre árvores de decisão e florestas aleatórias. Enquanto as árvores de decisão consideram todas as possíveis divisões de recursos, as florestas aleatórias selecionam apenas um subconjunto desses recursos.

Figura 18 – Fluxo de trabalho da floresta aleatória



Fonte: Viswanatha (2023)

### 2.5.1.3 Gradient Boosting Regressor (GBR)

Assim como a floresta aleatória, o *GBR* também utiliza o método ensemble, porém utiliza o *boosting*, invés do *bagging*. *Boosting* não funciona em paralelo, mas em sequência, treinando iterativamente aprendizes fracos (*weak learners*) e incorporando seus pontos fortes em um “aprendiz” mais forte, enquanto adapta outro aluno fraco para enfrentar suas “fraquezas”.

*Boosting* é um processo que combina diversos classificadores fracos para criar um classificador forte. Com base nas informações de um classificador, ele gera outro classificador, e assim sucessivamente. Por fim, o modelo final é criado combinando todos os classificadores (PATEL; CHOE; HALABI, 2020).

O *GBR* é um poderoso algoritmo quando se lida com dados em formato tabular. Isto garante maior precisão na previsão quando comparado com outros algoritmos de aprendizagem de máquina. No entanto, o *GBR* precisa de muito processamento, por isso é necessário projetar o algoritmo de forma eficiente. *LightGBM* e *XGBoost* são pacotes que projetam esses algoritmos de forma eficiente (PATEL; CHOE; HALABI, 2020).

#### 2.5.1.4 *Light Gradient Boosting (LightGBM)*

*LightGBM* é derivado do *GBR*, e consiste em um algoritmo relativamente novo, introduzido pela *Microsoft* em 2017. Devido o *GBR* convencional levar muito tempo para encontrar o melhor tempo de ponto dividido, várias abordagens foram consideradas para reduzir essa sobrecarga de desempenho (PATEL; CHOE; HALABI, 2020).

Reduzir o número de recursos pode ser um abordagem, mas pode afetar a precisão. Para superar essas dificuldades, *LightGBM* combina duas técnicas chamadas amostragem unilateral baseado em gradiente (*Sampling with Gradient-Based One-Side Sampling ou GOSS*), que reduz o tamanho dos dados, e Pacote de recursos exclusivos (*Exclusive Feature Bundling ou EFB*), que reduz o número de recursos usando algoritmos baseados em histograma em vez de encontrar o melhor ponto de divisão para resolver o problema do *GBR* (PATEL; CHOE; HALABI, 2020).

#### 2.5.1.5 *Extra Trees Regressor (ET)*

*ET* é um método de combinação utilizado para tarefas de regressão. Pertence à classe de algoritmos conhecidos como métodos *ensemble* baseados em árvore, os quais usam árvores de decisão como modelo base e combinam as previsões de múltiplas árvores para criar uma previsão geral mais precisa.

O processo de treinamento do algoritmo *ET* consiste na criação de árvores de decisão a partir de uma amostra inicializada do dados de treinamento e um subconjunto aleatório de recursos. Essa técnica visa reduzir a variância do modelo e melhorar seu desempenho de generalização. Este processo é repetido muitas vezes para criar um conjunto de árvores de decisão, e a previsão final é feita calculando a média das previsões de todas as árvores.

Uma vantagem do *ET* é que o seu treinamento é relativamente rápido e requer pouco ajuste do hiperparâmetros do modelo. No entanto, o modelo resultante pode ser menos interpretável do que uma única árvore de decisão e também podem ser propensas a *overfitting*, especialmente se os dados de treinamento não são suficientemente diversificados. *ET* é frequentemente utilizada em combinação com outros algoritmos ou como modelo de base para comparação. Pode ser uma ferramenta útil para tarefas de regressão onde o objetivo é alcançar alta precisão preditiva e eficiência computacional (KUMAR; JAISHARMA, 2023).

### 2.5.1.6 *Extreme Gradient Boosting (XGBoost)*

*Extreme Gradient Boosting* é outro algoritmo originado do *GBR*. Ele foi introduzido há pouco mais tempo que o *LightGBM*, desenvolvido em 2014 por Tianqi Chen. Em (CHEN; GUESTRIN, 2016) ele descreve o novo algoritmo, as lições que aprendeu e a proposta da nova invenção.

Esse algoritmo é amplamente utilizado em *ML* devido a sua precisão e velocidade relativamente rápida quando comparado com outros algoritmos convencionais de aprendizagem de máquina (PATEL; CHOE; HALABI, 2020).

Um dos maiores problemas em aprendizagem de árvores é encontrar a melhor divisão (*best split*), a maioria dos algoritmos de árvore única, como os do *scikit-learn*, utilizam algoritmos pré-classificados que visitam todos os dados após classificá-los de acordo com os recursos (*features*). Apesar desse método ser eficiente por conta de enumerar todas as possíveis possibilidades de divisão, é ineficiente em termos de velocidade. Por eficiência, *XGBoost* utiliza um algoritmo baseado em histograma (*Histogram-Based Algorithm*). O algoritmo baseado em histograma usa caixas que são divididas em formas discretas pelas características dos dados. Por isso, é mais eficiente que o método pré-classificado, mas também precisa enumerar todos os possíveis pontos de divisão (PATEL; CHOE; HALABI, 2020).

A aprendizagem em conjunto oferece uma solução sistemática para combinar o poder preditivo de vários aprendizes (*learners*). O resultado é um modelo único que fornece a saída agregada de vários modelos. Os modelos que formam o conjunto, também conhecidos como aprendizes básicos (*base learners*), podem ser do mesmo algoritmo de aprendizagem ou de diferentes algoritmos. *Bagging* e *boosting* são dois aprendizes amplamente utilizados. Apesar de essas duas técnicas poderem ser usadas com vários modelos estatísticos, o uso mais predominante tem sido com árvores de decisão (PATEL; CHOE; HALABI, 2020).

### 2.5.1.7 *Light Gradient Boosting Versus Extreme Gradient Boosting*

*LightGBM* e o *XGBoost* derivadas do *GBR*, são estruturas muito populares e de alto desempenho que aproveitam combinações de árvores impulsionadas (*boosted trees*) e a descoberta de divisão baseada em histograma. As principais diferenças residem na forma que os algoritmos realizam a divisão, que para *LightGBM* usa amostragem unilateral baseada em gradiente (*GOSS*) e agrupamento de recursos esparsos com *Exclusive Feature Bundling (EFB)*, enquanto o *XGBoost* utiliza o esboço de quantil ponderado (*Weighted Quantile Sketch*) e descoberta de divisão com

reconhecimento de esparsidade (*Sparsity-aware Split Finding*) (MASÍS, 2023).

Outra diferença entre *LightGBM* e *XGBoost* é que *LightGBM* utiliza um algoritmo de crescimento em folha (*leaf-wise*), enquanto o *XGBoost* usa um algoritmo de crescimento em nível (*level-wise*) (MASÍS, 2023) e (PATEL; CHOE; HALABI, 2020).

O algoritmo *LightGBM* é propenso a *overfitting* durante a sua implementação devido o seu método de divisão, que emprega estratégia *leaf-wise*. No entanto, o algoritmo *XGBoost* usa uma estratégia chamada de *level-wise* que leva mais tempo para realizar os cálculos, resultando em maior tempo de computação. Porém, o *XGBoost* possui um parâmetro de regularização, além de implementar a amostragem de colunas e redução de peso em novas árvores, ambas as técnicas são utilizadas no combate ao *overfitting* (SIBINDI; MWANGI; WAITITU, 2023).

### 3 ESTADO DA ARTE

Nessa sessão é demonstrado como foi feita a busca pelo estado da arte utilizada nesse projeto.

Primeiramente, foi realizada uma pesquisa nas seguintes bases teóricas: *Web of Science*, *IEEE* e *Science Direct*, o objetivo foi encontrar artigos relacionados a amplificadores ópticos dopados com érbio, algoritmos de regressão, principalmente os modelos com *gradient boosting* e derivados e, finalmente, os parâmetros de saída desejados, no caso, o ganho e figura de ruído. Para cada acervo foi utilizado uma metodologia diferente que será descrita a seguir:

Ao se utilizar algoritmos de regressão ou *gradient boosting*, tornávamos a pesquisa muito seletiva, resultando em poucas bibliografias, e ao usar amplificadores ópticos invés do *EDFA*, foram encontrados muitos artigos destoantes com a proposta desse projeto. Partindo disso, as palavras chaves selecionadas foram “EDFA”, “Artificial Intelligence”, “Machine Learning”, “Deep Learning”, “Noise Figure” e “Optical Gain”. Dos artigos encontrados oriundos dessa expressão, foram aplicados os critérios de exclusão: como período de publicação entre 2020 e 2024 (com exceção do acervo *Web of Science*), e após esse primeiro critério, foram lidos os resumos e a conclusão dos mesmos, eles deveriam ter utilizado amplificadores ópticos, principalmente o *EDFA*, além disso deveriam utilizar algoritmos de regressão ou redes neurais e, por fim, deveriam ser utilizados para estimar algum parâmetro do sistema, de preferência, os mesmos que estamos utilizando.

#### 1. Base de dados utilizada: *Web of Science*

- **Expressão Lógica:** “EDFA” AND (“Artificial Intelligence OR Machine Learning OR Deep Learning”) AND (“Noise Figure” OR “Optical Gain”)
- **Total de artigos encontrados** = 20.
- **Critérios de exclusão:**
- **Ano de publicação:** Como só haviam somente 20 artigos nesse acervo, e o artigo mais antigo era de 2017, para esse acervo especificamente, não foi utilizado filtro por ano de publicação. Total de artigos encontrados = 20.
- **Título e objetivos condizentes com o escopo da pesquisa:** 7 artigos.

#### 2. Base de dados utilizada: *IEE Xplore*

- **Expressão Lógica:** “EDFA” AND (“Artificial Intelligence OR Machine Learning OR Deep Learning”) AND (“Noise Figure” OR “Optical Gain”)
- **Total de artigos encontrados** = 111
- **Critérios de exclusão:**
- **Ano de publicação:** 2020 à 2024. Total de artigos encontrados = 88.
- **Título e objetivos condizentes com o escopo da pesquisa:** 19 artigos. Após remover os artigos repetidos em relação a base de dados anterior, restaram 12 artigos da plataforma IEEE.

### 3. Base de dados utilizada: *Science Direct (Elsivier)*

- (Modeling EDFA) AND (REGRESSION ALGORITHM OR NEURAL NETWORK) AND (PREDICT AND (OPTICAL GAIN OR NOISE FIGURE))
- **Total de artigos encontrados** = 87
- **Critérios de exclusão:**
- **Ano de publicação:** 2020 à 2024. Total de artigos encontrados = 61.
- **Título e objetivos condizentes com o escopo da pesquisa:** 1 artigo

Vale ressaltar que também foram pesquisados artigos dentro das referências bibliográficas dos artigos encontrados acima, por isso é possível observar referências mais antigas nesse projeto de pesquisa.

#### 3.1 Análise dos trabalhos encontrados

Após a pesquisa em alguns acervos bibliográficos relevantes como *web of science*, *IEEE*, *Science Direct*, etc. O artigo de (SADIK, 2022) foi o que mais se aproximou da metodologia desse projeto, servindo como principal referência. Ele utilizou parâmetros semelhantes, no entanto, não usou densidade do érbio, e adicionou comprimento de onda e ganho como parâmetros de entrada para estimar a figura de ruído. Esse foi o único projeto dentro os pesquisados pelas palavras chave que também utilizou algoritmo *gradient boosting*, a grande maioria utilizou redes neurais. Sadik (2022) obteve  $R^2$  de 0,9742, *MAE* de 0,3428 e *RMSE* de 0,4429. Apesar de ter obtido resultados muito bons, o modelo apresentado nesse projeto de pesquisa foi capaz de alcançar um coeficiente de regressão maior, erros menores, além de utilizar mais métricas de

erro para avaliar o modelo, como *MAPE*, *MSE* e *RSMLE*, além de fazer o mesmo para o ganho. O coeficiente de regressão e os parâmetros de erro são discutidos no Capítulo 4, na Seção 4.3.

(BASTOS-FILHO; BARBOZA; MARTINS-FILHO, 2017) cita que a maioria das abordagens utiliza a máscara do amplificador *Amplifier Mask* como banco de dados para armazenar alguns dos pontos operacionais do amplificador; então é possível estimar como o amplificador distorcerá o sinal e o quanto de ruído será adicionado ao sinal se um desses pontos for selecionado. A máscara do amplificador é o resultado de um processo de caracterização, que altera potência de entrada e o ganho do amplificador caracterizado seguindo uma etapa predefinida (por exemplo, 1 dB). Como consequência, a saída da caracterização é um conjunto discreto de pontos. Em 2017, propôs a utilização de redes neurais para estimar ganho e figura de ruído em amplificadores ópticos dopados com érbio, destacou sua importância para reduzir o número de dados e o aumento de sua velocidade de predição, além de destacar um problema atual na modelagem de amplificadores que é o controle adaptativo de operação, que futuramente pode ser otimizado através da aprendizagem de máquina em conjunto com sistemas como microcontroladores. Este inclusive, é uma perspectiva futura para esse projeto de pesquisa. Projetos sequenciais dos mesmos membros ((BASTOS-FILHO; BARBOZA; MARTINS-FILHO, 2017) e (FREITAS *et al.*, 2021)) destacam a importância dos algoritmos de regressão para substituir os métodos convencionais de controle de ganho e a diminuição de tempo resposta.

É possível ver através dos artigos que muitos deles utilizam redes neurais como uma forma de estimar os valores, inclusive Sutili *et al.* (2022) destaca a importância da utilização das redes neurais para o aprimoramento de amplificadores ópticos.

Em Zhu *et al.* (2018), a modelagem baseada em aprendizado de máquina de amplificadores de fibra dopada com érbio é utilizada para determinar o ganho dependente do comprimento de onda, através de redes neurais, para uso em sistemas de transmissão óptica, em que foi possível atingir *RMSE* de 0,08, 0,18 e 0,27 dB em faixas de entrada de +/- 3, 6, 9 dB, respectivamente.

Na pesquisa de Wang, Kilper e Chen (2023) foram utilizadas redes neurais profundas (*DNN* - do inglês, *Deep Neural Network*) para estimar o ganho. O banco de dados foi coletado a partir de *EDFAs* comerciais e foi possível obter erros inferiores a 0,18/0,24 dB para *MAE*.

Yu *et al.* (2021) realizou uma comparação entre redes neurais e uma rede neural que utilizava como parâmetro de entrada o ganho espectral calculado analiticamente para estimar o ganho contornando o problema da dependência do comprimento de onda. Utilizando essa técnica, foram obtidas melhoras significativas na precisão, velocidade de treinamento e quantidade de dados necessário, com *RSME* de 0,144 dB e *MAE* de 0,16 dB. Zhu *et al.* (2020) também utilizou

redes neurais e redes neurais híbridas.

Marcon *et al.* (2020) utilizou *ML* para aprender a relação inversa entre os parâmetros de bombeamento Raman e o ganho resultante, utilizando centenas de redes neurais em paralelo. A mesma equipe também realizou a mesma proposta de modelagem inversa com a partir de amplificação Raman, porém com fibras *few-mode fibers (FMF)* (CHEN *et al.*, 2020). Além disso, Huang *et al.* (2021) também utilizou redes neurais em conjunto com amplificadores Raman distribuídos para realizar a modelagem inversa do perfil do bombeamento, e dessa forma variar o ganho do sistema, foi obtido um *RSME* de 0,0910 dB.

Kamel *et al.* (2021) utilizou arquiteturas neurais para prever *OSNR* a partir de previsões incertas de potência, com base sobre a relação analítica entre *OSNR* e as figuras de ruído aprendidas.


Ainda é possível ver outros parâmetros avaliados em outras modelagens de amplificadores, como por exemplo: Matera (2020), que utilizou algoritmos de regressão e redes neurais para melhorar a qualidade do sistema *Quality of Transmission - QoT* em amplificadores ópticos semicondutores e Kaur, Manna e Marimuthu (2021) utiliza a modelagem híbrida de amplificadores *TDFA-EDFA* para minimizar a taxa de erro de bit. Além disso, Tay *et al.* (2022) destacou a utilização de redes neurais em amplificadores paramétricos de fibra óptica (*FOPA*). O modelo desenvolvido nesse projeto pode ser utilizado para realizar a predição dos comprimentos de onda e das potências de bombeamento necessários para o sistema, caso o ganho desejado seja fornecido.

Lin, Lin e Jiang (2023) utiliza redes neurais para realizar a predição do ganho, no entanto quando o modelo treinado é utilizado em outros dispositivos, para o novo dispositivo, sua precisão é reduzida. Dessa forma, eles propõem a utilização de uma rede neural auxiliar para adaptar o modelo utilizado para os novos valores de referência ou aplicar *transfer learning* para a rede neural principal, como resultado o *RSME* convencional da rede de 0,04 dB foi reduzido para 0,02 dB com a utilização da rede neural auxiliar. Ros, Moura e Yankov (2020) também usa redes neurais e generaliza o seu modelo para outros dispositivos físicos. Além disso, Lin, Lin e Jiang (2023) cita You, Jiang e Janz (2018) como um projeto pioneiro na área de aprendizagem de máquina aplicada a modelagem de *EDFAs*, nele também foram utilizadas redes neurais para estimar o ganho e obteve um *RSME* inferior a 0,2 dB.

## 4 MATERIAIS E MÉTODOS

As etapas necessárias para a realização desse projeto são ilustradas na Figura 19.

Figura 19 – Etapas de desenvolvimento da pesquisa



Fonte: Autor.

### 4.1 Materiais Utilizados:

Para a realização das simulações dos amplificadores ópticos, foi utilizado o *software* de simulação *OptiSystem 7* para a aquisição dos dados, posteriormente, foi realizada a limpeza e o tratamento necessário para a construção do banco de dados. Em seguida, após o banco de dados estar finalizado, foram aplicados os algoritmos de *ML*. Inicialmente, estes, foram aplicados na base de dados utilizando o *software Microsoft Machine Learning Studio*, porém apesar de se ter obtido bons resultados, no decorrer dessa pesquisa, a aplicação também foi realizada em *python*, o qual foi selecionado para seguir e continuar o projeto, pois a partir dele seria possível testar mais algoritmos de regressão, verificar todas as métricas estatísticas desejadas, citadas na


subseção 4.1.2, além de ter a oportunidade de se programar o próprio algoritmo, permitindo uma maior individualidade ao projeto e ainda, posteriormente, seria possível realizar o registro do *software*.

O *software Microsoft Machine Learning Studio* consiste em uma ferramenta de programação visual, baseada em fluxogramas ou *Graphical User Interface (GUI)* e apesar de não ter sido utilizada até o final do projeto, com ela foi possível obter bons resultados, funcionando de forma bem eficiente. Ela é ideal para usuários que não possuem tanta familiaridade com *ML* ou desejam iniciar exploração nessa área de atuação.

#### 4.1.1 OptiSystem 7

O OptiSystem, ilustrado na Figura 20, consiste em um *software* da empresa Optiwave, desenvolvido para simular, projetar e testar sistemas e dispositivos ópticos. Por meio dele, foi possível alterar simultaneamente diversos parâmetros de um *EDFA* em uma larga faixa de valores, e a partir disso, analisar como isso afeta o sinal transmitido no enlace.

Figura 20 – Setup experimental simulado no OptiSystem



Fonte: Autor

#### 4.1.2 Python PyCaret

*PyCaret* é uma biblioteca *low-code* em *Python*, que visa reduzir o tempo necessário para aplicar diferentes modelos de *ML*. Ela permite que os usuários possam realizar seus experimentos ponta a ponta de maneira rápida e eficiente. Além disso, suporta tarefas de *ML* supervisionada (classificação e regressão), agrupamento (*clustering*), detecção de anomalias, além de diversas funções para realizar o tratamento dos dados e ajuste de hiper parâmetros (NANFACK; FUTE; ELE, 2022). Para problemas de classificação e regressão, são utilizados as seguintes métricas de avaliação:

Para classificação: Acurácia, AUC, Revocação (Recall), Precisão, F1, Kappa.

Para regressão: MAE, MSE, RMSE,  $R^2$ , RMSLE, MAPE.

## 4.2 Metodologia Experimental

Nesta sessão, foi demonstrado o passo a passo para a execução do projeto.

### 4.2.1 Simulação da Rede EDFA com Varredura Multiparamétrica

O *setup* do amplificador dopado com érbio codirecional utilizado nesse projeto consiste nos seguintes dispositivos ilustrados na Figura 21: o laser de onda contínua operando no comprimento de onda de 1550 nm, que será nossa fonte de luz principal, por onde a informação é transmitida; O laser de bombeamento operando em 980 nm, fundamental para elevar o íon de érbio para o estado excitado e permitir a amplificação do sinal através da emissão estimulada, e por fim o comprimento da fibra óptica dopada utilizada pelo amplificador e o nível de dopagem de íons de érbio inseridos na mesma.

Também estão presentes os isoladores ópticos, amplamente utilizados em sistemas de comunicações ópticas como uma forma de solucionar o problema do retorno de luz refletida ou espalhada, decorrente da reflexão de Fresnel. Esta, que acontece nos conectores, em emendas, espalhamento Rayleigh, entre outros, além de degradar o desempenho do amplificador, também é capaz de danificar componentes, como o laser. Além disso, em amplificadores a fibra dopada, a emissão ASE implica na diminuição da inversão de população no início da fibra, aumentando o ruído no sistema. Isoladores ópticos são eficientes no tratamento desse problema, pois permitem a passagem de luz somente em uma direção, dessa forma, impedindo que a reflexão deteriore o sistema (GUIMARÃES, 2006).

Com o auxílio do *OptiSystem*, foi possível realizar varredura de diversos parâmetros do *EDFA* em faixas distintas. Para esse projeto, foram definidos os seguintes parâmetros de entrada: potência óptica incidente, potência do laser de bombeamento, comprimento da fibra e o nível de densidade do érbio na fibra. Estes parâmetros foram utilizados para estimar os parâmetros de saída: Ganho do amplificador e figura de ruído, ambos em decibéis (dB). Shukla e Kaur (2013) e Cokrak e Altuncu (2004) destacam a importância desses quatro parâmetros de entrada na avaliação de amplificadores ópticos dopados com érbio e sua relevância para estimar os parâmetros de saída.

Qualquer implementação requer o conhecimento dos parâmetros físicos do *EDFA*, como comprimento, raio e perda da fibra dopada, nível de concentração de érbio e configuração de bombeamento. Esses parâmetros normalmente não são fornecidos com o *datasheet* do dispositivo e são difíceis de se medir experimentalmente (YANKOV *et al.*, 2021). O único parâmetro que é fornecido no manual é a faixa da potência do sinal de entrada. Partindo disso, os valores definidos foram escolhidos da seguinte forma: para a potência do sinal de entrada, foi levado em consideração os *EDFAs* comerciais que funcionam de -10dBm a 10dBm, foi preferível trabalhar com os valores em miliwatts (0,1 a 10 mW) pela sua escala linear invés da logarítmica, pois dessa forma o algoritmo de *ML* possui uma maior facilidade em ajustar o modelo para essa escala de dados, obtendo assim melhores resultados. Para a potência de bombeamento foi escolhido um intervalo que compreendesse o range utilizado nas revisões da literatura, que ficavam entre 20 e 100 mW, o comprimento da fibra foi definido a partir de um amplificador óptico real com 5 metros de fibra dopada com érbio, então resolvemos explorar a partir desse comprimento, e finalmente, para o nível de densidade do íon  $\text{Er}^{3+}$  foi escolhido a partir da literatura e do *OptiSystem*, o qual fornece como valor padrão 1000 ppm, que foi definido como o valor final. Para a varredura do valor da potência incidente foram utilizadas duas formas diferentes, a primeira de 0,1 a 1 mW com o passo de 0,1 mW e a segunda de 1 mW a 10 mW com o passo de 1 mW, ambas ilustradas na Tabela 1 junto com os demais parâmetros, a faixa escolhida para cada parâmetro e o passo utilizado por cada um deles.

Tabela 1 – Detalhamento dos parâmetros de entrada que serão utilizados

| Parâmetros de Entrada     | Valor Inicial | Valor Final | Passo   | Nível de Varredura |
|---------------------------|---------------|-------------|---------|--------------------|
| Potência Óptica Incidente | 0,1 mW        | 1 mW        | 0,1 mW  | 1                  |
| Potência Óptica Incidente | 1 mW          | 10 mW       | 1 mW    | 1                  |
| Potência de Bombeamento   | 20 mW         | 120 mW      | 20 mW   | 2                  |
| Comprimento da Fibra      | 5 m           | 15 m        | 2 m     | 3                  |
| Concentração de Érbio     | 500 ppm       | 1000 ppm    | 100 ppm | 4                  |


Além disso, no início deste projeto foram testados diferentes faixas para os parâmetros de entrada, inclusive valores menores, todavia haviam algumas combinações em que a figura de ruído resultante era menor que o seu limite teórico inferior, segundo Desurvire (2002) o valor mínimo para a figura de ruído é de 3 dB. Dessa forma, os valores definidos foram escolhidos também com o intuito de respeitar o limite teórico estabelecido na literatura. A partir disso, foram testadas 3 soluções distintas:

1. Arredondar as que eram inferiores a 3 para 3, pois se tratavam de valores bem próximos;
2. Remover na base de dados os pontos em que a figura de ruído era inferior a 3;
3. Ajustar os parâmetros de entrada para que os valores obtidos para a figura de ruído sempre fossem iguais ou superiores ao limite teórico estabelecido.

Todas as opções foram testadas, e a que apresentou o melhor resultado foi a terceira, cuja foi a escolhida para a continuação do projeto.

Além dos valores mínimos, máximos e o passo referente a cada parâmetro, também são apresentados os níveis de cada um. A varredura no *OptiSystem* funciona da seguinte forma: o nível mais alto é o primeiro a ser varrido, e o mais baixo, o último, formando assim o banco de dados utilizado neste projeto, totalizando 4104 pontos.

Figura 21 – Arquitetura do EDFA utilizado no projeto



Fonte: Autor

#### 4.2.2 *Tratamento e organização dos dados*

Após a finalização das simulações, os dados são extraídos do *OptiSystem* no formato *xls*, este arquivo, no entanto, apresenta bem mais parâmetros do que os que estamos analisando no projeto, pois contempla todos os parâmetros dos dispositivos utilizados na simulação, além de alguns erros de formatação, tais como: linhas em branco e problemas na casa decimal. Portanto, foi realizada uma "limpeza" nos dados para remover essas linhas e colunas indesejadas, como também realizar os demais ajustes necessários para que o banco de dados pudesse ser utilizado.

No final desse processo, são encontrados os 4104 pontos. Destes 4104, 102 pontos, distribuídos entre a base, o centro e o topo do banco de dados, são removidos do mesmo, resultando em 4002 pontos que darão continuidade a aplicação dos algoritmos de *ML*. Os dados foram removidos para posteriormente, serem utilizados para formar gráficos comparativos entre os valores coletados diretamente do *software* e os valores resultantes da predição do modelo de *ML* utilizado nesse projeto.

#### 4.2.3 *Distribuição dos Percentuais de Holdout*

Após a finalização do banco de dados, deve-se estimar os valores de *holdout*, ou seja, uma porcentagem dos dados para realizar o treinamento dos dados, aplicando o algoritmo de regressão determinado e o restante deve ser utilizado para testar o sistema. Foi realizado uma varredura percorrendo diferentes percentuais de treinamento/teste, com o intuito de encontrar o algoritmo e a combinação de valores de *holdout* em que fossem apresentados os melhores resultados.

#### 4.2.4 *Aplicação dos Algoritmos de Aprendizagem de Máquina*

Posteriormente, são aplicados os algoritmos de regressão, neste projeto foram testados 19, estes foram: *Extreme Gradient Boosting*, *Extra Trees Regressor*, *Light Gradient Boosting Machine*, *Random Forest Regressor*, *Decision Tree Regressor*, *Gradient Boosting Regressor*, *AdaBoost Regressor*, *K Neighbors Regressor*, *Least Angle Regression*, *Bayesian Ridge*, *Ridge Regression*, *Linear Regression*, *Huber Regressor*, *Lasso Regression*, *Lasso Least Angle Regression*, *Elastic Net*, *Passive Aggressive Regressor*, *Orthogonal Matching Pursuit*, *Dummy Regressor*.

#### 4.2.5 Modelagem Inversa

A modelagem inversa consiste em utilizar o que previamente eram os parâmetros de saída, ou seja, ganho e figura de ruído, para estimar um dos parâmetros de entrada, dentre eles: potência do sinal de entrada, potência de bombeamento e comprimento da fibra.

Para realizar a modelagem inversa, diferentemente da modelagem direta, não foi removido nenhum dado da base de dados inicial, ou seja, foram utilizados todos os 4104 pontos para realizar o treinamento do modelo, e para a realização dos gráficos comparativos, foram geradas novas amostras no *OptiSystem*, com valores que pertenciam a faixa da nossa base de dados, estavam dentro do intervalo, porém não foram trabalhadas diretamente durante o treinamento.

### 4.3 Metodologia para Avaliação dos Resultados

Nesta sessão, é realizada a comparação dos resultados a partir dos algoritmos aplicados a base de dados em relação as métricas estatísticas definidas, estas são: MAE, MSE, RMSE,  $R^2$ , RMSLE, MAPE.

#### 4.3.1 Coeficiente de Determinação

Para realizar a verificação da eficiência dos algoritmos aplicados ao banco de dados, foi utilizado o coeficiente de determinação ( $R^2$ ), que consiste em uma medida estatística utilizada para avaliar a qualidade do ajuste de um modelo de regressão. A sua métrica varia de -1 a 1, sendo 0 e valores menores representando um modelo linear pouco adequado e 1, um modelo linear muito adequado. Uma maneira de calcular o ( $R^2$ ) é utilizando a seguinte expressão com a soma dos quadrados totais ( $SQT$ ), a soma dos de regressão ( $SQR$ ) e a dos erros ( $SQE$ ):

$$SQT = \sum_{i=1}^n (Y_i - \bar{Y})^2, \quad (4.1)$$

$$SQR = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2, \quad (4.2)$$

$$SQE = \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2, \quad (4.3)$$

$$R^2 = \frac{SQE}{SQT} = 1 - \frac{SQR}{SQT}, \quad (4.4)$$

em que  $Y_i$  corresponde ao valor real;  $\hat{Y}_i$  ao valor estimado e  $\bar{Y}_i$  define o Valor médio.

#### 4.3.2 Erro Médio Absoluto

O erro médio absoluto (*MAE* — do inglês, *Medium Absolute Error*), esta é uma métrica ilustrada em (4.5), que consiste na diferença entre o valor real pelo valor estimado, mas por existirem valores tanto positivos como negativos, deve-se empregar o módulo na diferença entre os valores. Além disso, essa métrica não é afetada por valores discrepantes (*outliers*) (HARRISON, 2019).

$$MAE(Y, \hat{Y}_i) = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i|. \quad (4.5)$$

O valor resultante de (4.5), tem a mesma unidade/escala utilizada pelos dados de entrada, facilitando assim a interpretação. Por exemplo, se o resultado contiver algum erro, o modelo pode estar errando para mais ou para menos em relação ao valor correto.

#### 4.3.3 Erro Percentual Absoluto Médio

O erro percentual absoluto médio (*MAPE* — do inglês, *Mean Absolute Percentual Error*) é uma métrica que mostra a porcentagem em relação aos valores reais, ela é basicamente a (4.5), porém dividida pelo módulo do valor real, ilustrada por (4.6) a seguir.

$$MAPE(Y, \hat{Y}_i) = \frac{1}{n} \sum_{i=1}^n \frac{|Y_i - \hat{Y}_i|}{\max(\epsilon, Y_i)}. \quad (4.6)$$

A variável  $\epsilon$  consiste em um valor extremamente pequeno (2,220446049250313e-16), utilizado pela biblioteca *scikit-learn* para que os casos em que  $Y_i$  seja igual a zero, para que dessa forma, não haja a ocorrência de erros (CONTRIBUTORS, 2024). Essa métrica é amplamente utilizada para reportar a performance do modelo, trazendo uma compreensão mais abrangente do resultado de *MAE*.

#### 4.3.4 Erro Quadrático Médio

O erro quadrático médio (*MSE* — do inglês, *Mean Squared Error*) é uma métrica que calcula a diferença entre o valor real e o valor estimado, no entanto, diferentemente do *MAE*, ao invés de ser usado módulo na diferença dos valores, no *MSE*, a diferença é elevada ao quadrado. Dessa forma, o algoritmo penaliza os algoritmos que tiverem maior *MSE*, identificando que eles não performaram de maneira precisa em relação as previsões (HARRISON, 2019).

$$MSE(Y, \hat{Y}_i) = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2. \quad (4.7)$$

Entretanto, essa métrica pode causar um problema na interpretação, podendo haver a distorção de sua unidade. Por exemplo, caso o resultado seja em metros (m), quando elevado ao quadrado, o resultado será em m<sup>2</sup>. Por conta disso, há uma adaptação em que se é tirada a raiz quadrada, descrita na próxima subseção.

#### 4.3.5 Raiz do Erro Quadrático Médio

A raiz do erro quadrático médio (*RMSE* — do inglês, *Root Mean Squared Error*), possui a mesma ideia do *MSE* de penalizar os algoritmos que tiverem maior discrepância entre o valor real e o valor estimado, porém é aplicado a raiz quadrada a fórmula anterior, para sanar o problema de distorção da unidade

Apesar do valor ter a mesma unidade, ele difere da métrica *MAE*, pois os valores (outliers) podem impactar na previsão do modelo. Mas a sua interpretabilidade pode seguir a mesma lógica, em que o seu resultado pode estar errando tanto para mais quanto para menos. Por essa razão, esta métrica pode ser uma boa opção quando é preciso ter uma avaliação mais criteriosa sobre as previsões do modelo.

$$RMSE(Y, \hat{Y}_i) = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2}. \quad (4.8)$$

Segundo Bruce e Bruce (2019), a métrica de desempenho mais importante da perspectiva da ciência de dados é a raiz do erro quadrático médio. Além disso, artigos científicos como o de Huang *et al.* (2021) destacam a importância em utilizar a métrica *RMSE* para verificar a precisão do algoritmo treinado. É uma métrica amplamente utilizada e reconhecida na comunidade de *ML* para aferir o desempenho de modelos de regressão.

#### 4.3.6 Raiz do Erro Quadrático Logarítmico Médio

A Raiz do Erro Quadrático logaritmo Médio (*RSMLE* — do inglês, *Root Mean Squared Logarithmic Error*) calcula uma métrica de risco correspondente ao valor esperado do erro ou perda logarítmica quadrada. É semelhante a métrica da Subseção 4.8 anterior, mas utiliza o logaritmo natural, também utiliza a raiz quadrada para o ajuste da unidade.

$$RMSLE(Y, \hat{Y}_i) = \sqrt{\frac{1}{n} \sum_{i=1}^n (\ln(1 + Y_i) - \ln(1 + \hat{Y}_i))^2}. \quad (4.9)$$

Essa métrica é mais eficiente quando utilizada em bancos de dados que possuem crescimento exponencial, como contagem populacional, vendas médias de uma mercadoria ao longo de um período de anos, etc. Uma característica importante também é que esta métrica penaliza uma predição menor que o valor real mais do que penaliza uma estimativa para valores maiores.

## 5 RESULTADOS

Neste capítulo, são apresentados os resultados obtidos com base na metodologia destacada no Capítulo 4. Inicialmente, são demonstrados os resultados da aplicação dos algoritmos de ML na base de dados, evidenciando as diferenças de desempenho entre eles. Em seguida, é realizada uma análise gráfica multiparamétrica, utilizando diferentes intervalos dos parâmetros de entrada, comparando os resultados obtidos pela IA com os dados simulados no software.

Além disso, foi possível realizar a modelagem inversa para determinar a potência óptica incidente, a potência de bombeamento e o comprimento da fibra em função do ganho e da figura de ruído.

As duas últimas seções deste capítulo exploram aspectos distintos: uma aborda a comparação entre o tempo de processamento do modelo de *ML* desenvolvido neste projeto e o tempo requerido para a simulação no *OptiSystem*, enquanto a outra apresenta um teste final utilizando uma nova base de dados. Este teste foi conduzido para avaliar o desempenho do modelo e assegurar que não houve *overfitting*.

### 5.1 Comparação Entre os Algoritmos

Inicialmente foi realizado uma varredura dos diferentes valores possíveis de *holdout* entre todos os algoritmos disponíveis no *framework Pycaret*: *Extreme Gradient Boosting*, *Extra Trees Regressor*, *Light Gradient Boosting Machine*, *Random Forest Regressor*, *Decision Tree Regressor*, *Gradient Boosting Regressor*, *AdaBoost Regressor*, *K Neighbors Regressor*, *Least Angle Regression*, *Bayesian Ridge*, *Ridge Regression*, *Linear Regression*, *Huber Regressor*, *Lasso Regression*, *Lasso Least Angle Regression*, *Elastic Net*, *Passive Aggressive Regressor*, *Orthogonal Matching Pursuit*, *Dummy Regressor*.

Todos os modelos foram varridos em diferentes porcentagens de divisões entre treinamento e teste. Iniciando de 10% para treinamento e 90% para teste, em seguida 20% de treinamento e 80% para teste, aumentando em 10% para treinamento e diminuindo 10% para os testes, e assim sucessivamente até o valor final de 90/10. O objetivo era identificar o modelo que apresentasse o maior coeficiente de regressão e os menores erros possíveis, estes são parâmetros fundamentais para avaliar o quão próximo o modelo proposto está da base de dados simulada utilizada neste projeto. Após a varredura completa, o algoritmo que alcançou esse propósito foi o *Extreme Gradient Boosting* para valores *holdout* de 90% para treinamento e 10% para teste, tanto para a figura de ruído, quanto para o ganho. O resultado da varredura dos algoritmos para

ambos os parâmetros de saída são ilustrados nas Tabelas abaixo para o "melhor" valor de *holdout*:

Tabela 2 – Relação de algoritmos testados e seus respectivos valores estatísticos em função da figura de ruído

| Modelo                          | MAE    | MSE    | RMSE   | $R^2$   | RMSLE  | MAPE   |
|---------------------------------|--------|--------|--------|---------|--------|--------|
| Extreme Gradient Boosting       | 0,0428 | 0,0046 | 0,0677 | 0,9987  | 0,0095 | 0,0077 |
| Light Gradient Boosting Machine | 0,0472 | 0,0058 | 0,0757 | 0,9984  | 0,0107 | 0,0085 |
| Extra Trees Regressor           | 0,0619 | 0,0092 | 0,0959 | 0,9974  | 0,0133 | 0,0110 |
| Random Forest Regressor         | 0,0778 | 0,0152 | 0,1230 | 0,9957  | 0,0163 | 0,0133 |
| Gradient Boosting Regressor     | 0,1024 | 0,0227 | 0,1500 | 0,9937  | 0,0223 | 0,0198 |
| Decision Tree Regressor         | 0,1681 | 0,0501 | 0,2236 | 0,9860  | 0,0304 | 0,0292 |
| K Neighbors Regressor           | 0,2037 | 0,0999 | 0,3158 | 0,9720  | 0,0504 | 0,0404 |
| AdaBoost Regressor              | 0,6633 | 0,5423 | 0,7360 | 0,8482  | 0,1303 | 0,1538 |
| lar Least Angle Regression      | 0,5772 | 0,6188 | 0,7859 | 0,8274  | 0,1293 | 0,1198 |
| Bayesian Ridge                  | 0,5771 | 0,6188 | 0,7859 | 0,8274  | 0,1293 | 0,1198 |
| Ridge Regression                | 0,5772 | 0,6188 | 0,7859 | 0,8274  | 0,1293 | 0,1198 |
| Linear Regression               | 0,5772 | 0,6188 | 0,7859 | 0,8274  | 0,1293 | 0,1198 |
| Huber Regressor                 | 0,5573 | 0,6680 | 0,8156 | 0,8141  | 0,1169 | 0,1068 |
| Elastic Net                     | 0,6034 | 0,6897 | 0,8297 | 0,8076  | 0,1243 | 0,1216 |
| Lasso Regression                | 0,6557 | 0,8031 | 0,8955 | 0,7759  | 0,1295 | 0,1295 |
| Lasso Least Angle Regression    | 0,6557 | 0,8031 | 0,8955 | 0,7759  | 0,1295 | 0,1295 |
| Passive Aggressive Regressor    | 1,0220 | 1,7005 | 1,2514 | 0,5258  | 0,2380 | 0,2168 |
| Orthogonal Matching Pursuit     | 1,4912 | 3,4896 | 1,8675 | 0,0250  | 0,2788 | 0,3017 |
| Dummy Regressor                 | 1,5108 | 3,5910 | 1,8942 | -0,0027 | 0,2824 | 0,3054 |

Tabela 3 – Relação de algoritmos testados e seus respectivos valores estatísticos em função do ganho

| Modelo                          | MAE    | MSE     | RMSE   | $R^2$   | RMSLE  | MAPE   |
|---------------------------------|--------|---------|--------|---------|--------|--------|
| Extreme Gradient Boosting       | 0,0565 | 0,0150  | 0,1185 | 0,9996  | 0,0174 | 0,0087 |
| Light Gradient Boosting Machine | 0,0826 | 0,0392  | 0,1788 | 0,9990  | 0,0277 | 0,0141 |
| Extra Trees Regressor           | 0,1001 | 0,0389  | 0,1952 | 0,9990  | 0,0190 | 0,0120 |
| Random Forest Regressor         | 0,1484 | 0,0665  | 0,2556 | 0,9983  | 0,0290 | 0,0188 |
| Decision Tree Regressor         | 0,2094 | 0,1030  | 0,3202 | 0,9973  | 0,0354 | 0,0248 |
| Gradient Boosting Regressor     | 0,2110 | 0,1631  | 0,3942 | 0,9957  | 0,0614 | 0,0429 |
| AdaBoost Regressor              | 1,1478 | 1,9707  | 1,4017 | 0,9484  | 0,1581 | 0,1517 |
| K Neighbors Regressor           | 1,1224 | 3,2463  | 1,7969 | 0,9151  | 0,1062 | 0,0835 |
| Least Angle Regression          | 2,1247 | 7,4586  | 2,7302 | 0,8050  | 0,2928 | 0,2693 |
| Bayesian Ridge                  | 2,1245 | 7,4586  | 2,7302 | 0,8050  | 0,2926 | 0,2693 |
| Ridge Regression                | 2,1247 | 7,4586  | 2,7302 | 0,8050  | 0,2928 | 0,2693 |
| Linear Regression               | 2,1247 | 7,4586  | 2,7302 | 0,8050  | 0,2928 | 0,2693 |
| Huber Regressor                 | 2,0997 | 7,5666  | 2,7498 | 0,8022  | 0,2788 | 0,2623 |
| Elastic Net                     | 2,1178 | 7,6100  | 2,7576 | 0,8010  | 0,2701 | 0,2612 |
| Lasso Regression                | 2,1209 | 7,6420  | 2,7635 | 0,8002  | 0,2736 | 0,2651 |
| Lasso Least Angle Regression    | 2,1209 | 7,6420  | 2,7635 | 0,8002  | 0,2736 | 0,2651 |
| Passive Aggressive Regressor    | 3,1706 | 16,3032 | 4,0159 | 0,5750  | 0,3743 | 0,4108 |
| Orthogonal Matching Pursuit     | 4,7304 | 28,8312 | 5,3680 | 0,2460  | 0,4548 | 0,5988 |
| Dummy Regressor                 | 5,2911 | 38,4406 | 6,1990 | -0,0045 | 0,5402 | 0,7840 |

Levando em consideração os 5 algoritmos que obtiveram os melhores resultados, estes foram: *"Extreme Gradient Boosting, Light Gradient Boosting Machine, Extra Trees Regressor, Random Forest Regressor e Gradient Boosting Regressor"* dentre os modelos, é possível analisar o algoritmo *"Gradient Boosting"* em quinto lugar. É importante ressaltar que os dois algoritmos que obtiveram os melhores resultados são derivados dele. Além disso, todos os 5 algoritmos são construídos a partir de árvores de decisão.

Segundo Patel, Choe e Halabi (2020) alguns algoritmos de aprendizagem de máquina, tais como floresta aleatória, árvores de decisão, e regressão logística possuem uma predição fraca em ambientes de computação em nuvem, visto que são mais eficientes em banco de dados de pequeno porte. Além disso, o modelo *"Gradient Boosting Decision Tree"*, utilizado para predições, é capaz de produzir resultados precisos de forma eficiente ao se utilizar um grande conjunto de dados. Consiste em uma combinação de algoritmos fracos, como árvores de decisão, floresta aleatória, classificação binária e regressão logística, para dessa forma criar algoritmos mais fortes, como por exemplo o *Light Gradient Boosting Machine (LightGBM)* e o *Extreme Gradient Boosting (XGBoost)*.

### 5.1.1 Nível de Importância dos Parâmetros

Os parâmetros de entrada escolhidos possuem relação direta com a figura de ruído e o ganho do amplificador, ilustrados por (2.20) e (2.14), citadas no Capítulo 2, respectivamente.

A seleção de recursos é uma etapa muito importante, pois afeta diretamente o desempenho da previsão. Existem muitos atributos nos dados, alguns dos atributos podem ser irrelevantes ou parcialmente relevantes para com a previsão. Se estes forem selecionados, isso causará um impacto negativo no modelo de previsão.

Geralmente, a importância fornece uma pontuação que indica quão útil ou valioso cada recurso foi na construção das árvores de decisão impulsionadas dentro do modelo. Quanto mais um atributo é usado para tomar decisões importantes com árvores de decisão, maior é sua importância relativa. Essa importância é calculada explicitamente para cada atributo no conjunto de dados, permitindo que os atributos sejam classificados e comparados entre si. A importância é calculada para uma única árvore de decisão pela quantidade que cada atributo "ponto de divisão" melhora a medida de desempenho, ponderada pelo número de observações pelas quais o nó é responsável. A medida de desempenho pode ser a pureza usada para selecionar a divisão pontos ou outra função de erro mais específica (PATEL; CHOE; HALABI, 2020).

A seguir ilustrados nas Tabelas 4 e 5, podemos ver a importância de cada parâmetro utilizado na predição da figura de ruído e do ganho, respectivamente.

Tabela 4 – Relevância dos parâmetros de entrada para a figura de ruído

|   | Parâmetros de Entrada             | Porcentagens |
|---|-----------------------------------|--------------|
| 1 | Potência do Sinal de Entrada [mW] | 0,500778     |
| 2 | Potência de Bombeamento [mW]      | 0,321083     |
| 3 | Comprimento da Fibra [m]          | 0,120024     |
| 4 | Densidade do Nível de Érbio [ppm] | 0,058115     |

Tabela 5 – Relevância dos parâmetros de entrada para o ganho

|   | Parâmetros de Entrada             | Porcentagens |
|---|-----------------------------------|--------------|
| 1 | Potência do Sinal de Entrada [mW] | 0,653054     |
| 2 | Potência de Bombeamento [mW]      | 0,324489     |
| 3 | Comprimento da Fibra [m]          | 0,012400     |
| 4 | Densidade do Nível de Érbio [ppm] | 0,010057     |

É possível analisar individualmente a influência que cada parâmetro teve na predição, sendo o mais relevante a potência do sinal de entrada, e o de menor relevância, a densidade de nível de érbio, para ambos os parâmetros de saída. Além disso, é possível observar que a potência de entrada e potência de bombeamento já constituem mais de 80% na relevância da predição para a figura de ruído, e quase 100% para o ganho do amplificador.

## 5.2 Análise gráfica

### 5.2.1 Modelagem Direta

A seguir nessa sessão, são ilustrados alguns gráficos que foram montados a partir dos 102 pontos removidos do banco de dados citados em 4.2.2, em que é possível analisar os diferentes parâmetros, em diversos pontos do banco de dados e observando a correlação entre eles juntamente com a performance do modelo. Os gráficos a seguir são divididos da seguinte forma: de acordo com a subseção especificada, o parâmetro de análise vai ser varrido e os demais valores permanecerão fixos, para que dessa forma, seja possível analisar graficamente como esse parâmetro afeta a figura de ruído e o ganho do sistema, e como o modelo responde a esse conjunto de dados.

As figuras a seguir são divididas em um conjunto de três gráficos, o a) corresponde aos valores da base do banco de dados, ou seja, os valores mais baixos do nosso banco, os gráficos b)

correspondem a valores intermediários, no centro do banco e, por fim, o c) referencia os valores do topo do banco, ou seja, os valores máximos dos parâmetros.


#### 5.2.1.1 *Potência de Entrada*

Segundo a fórmula 2.14, é possível notar que ao aumentar a potência de entrada, há uma diminuição direta no ganho, isso porquê, para que haja a amplificação do sinal, deve-se realizar o bombeamento de íons de érbio do estado fundamental para o estado excitado, e para que isso aconteça, a potência de bombeamento deve ser consideravelmente maior que a do sinal de entrada, dessa forma, ao manter a potência de bombeamento constante e aumentar somente a potência de entrada, tem-se a diminuição contínua do ganho (KEISER, 2014). Isto, é uma consequência da dificuldade em se realizar uma inversão de população completa.


Dessa forma, durante o processo de amplificação, os íons ficam mais susceptíveis a ASE, discutida no capítulo 2, e assim resultando na redução do ganho e no aumento do ruído. O comportamento discutido é ilustrado no Figura abaixo 22, onde é possível ver o aumento da figura de ruído em função do aumento da potência de entrada, ao mesmo tempo em que é destacado no gráfico 23 a diminuição do ganho em função deste mesmo aumento.

O modelo adotado não teve dificuldades em realizar a predição em função da potência de entrada, obtendo uma resposta consideravelmente precisa para esse parâmetro em todos os gráficos das Figuras. Foram obtidos coeficientes de regressão muito próximos de 1 e erros próximos de zero, tornando muitos próximos os gráficos referentes aos dados simulados e os preditos, isso provavelmente é proveniente do seu alto valor de relevância desse parâmetro de entrada para ambos os parâmetros de saída.


Figura 22 – Variação da figura de ruído em relação a diferentes potências de entrada



(a)




(b)




(c)


Figura 23 – Variação do ganho em relação a diferentes potências de entrada



(a)



(b)



(c)

#### 5.2.1.2 Potência de Bombeamento


A potência de bombeamento, foi o segundo parâmetro de maior relevância na predição dos modelos estudados nesse projeto. Ele constitui mais de 30% de influência no valor de predição para ambos os parâmetros de saída.

Como visto na subseção anterior, é necessário que a potência de bombeamento seja maior que a do sinal de entrada, e além disso, o comprimento de onda de bombeamento deve ser menor que o comprimento de onda do sinal de entrada. Dessa forma, é possível estabelecer uma amplificação com níveis bem definidos aumentando a emissão de fótons gêmeos e reduzindo a emissão espontânea no amplificador. O comportamento esperado é ilustrado nas Figuras 24 e 25, em que com o aumento da potência de bombeamento há um aumento crescente do ganho e uma constante diminuição da figura de ruído.


Para este parâmetro, os modelos também apresentaram resultados bem precisos. É possível observar que os gráficos 24a e 25a são os que apresentam uma distância levemente maior que os outros em relação a base de dados e o modelo, no entanto, ainda são bem precisos. Os demais

gráficos ilustrados em 24b, 24c, 25b e 25c apresentaram uma maior correlação. Para a potência de bombeamento, o modelo proposto também conseguiu uma correlação consideravelmente alta, com baixos valores de erro e altos coeficientes de regressão.


Figura 24 – Variação da figura de ruído em relação a diferentes potências de bombeamento



(a)




(b)



(c)

Figura 25 – Variação do ganho em relação a diferentes potências de bombeamento



### 5.2.1.3 Comprimento da Fibra


Para o comprimento da fibra, os gráficos apresentaram o resultado esperado, para baixos valores de potências de bombeamento, o ganho começa a diminuir com o aumento do comprimento da fibra, pois o bombeamento não tem energia suficiente para criar uma inversão de população completa no sentido de fluxo do amplificador. Nesse caso, a região não bombeada da fibra absorve o sinal, resultando no aumento da figura de ruído e na diminuição do ganho, ambos ilustrados nos gráficos das Figuras 26 e 27 respectivamente.

É possível observar o crescente aumento da figura de ruído em decorrência do aumento do comprimento da fibra, para os 3 gráficos do conjunto da Figura 26. Em comparação aos parâmetros referentes a potência do sinal de entrada e a potência de bombeamento, podemos ver uma maior separação entre os pontos, no entanto, levando em consideração o eixo referente a


figura de ruído, é possível observar que a distância entre a base de dados e o modelo é de menos de 0,1 dB.

Para o ganho, o gráfico 27a, o qual utiliza valores menores de potência de sinal de entrada, potência de bombeamento e nível de dopagem de érbio, ilustra o momento em que o amplificador alcança o seu pico de ganho e logo em seguida, ocorre o seu decremento em função do aumento da fibra, isso ilustra a região em que a fibra absorve o sinal. Ao observar esse gráfico, é possível ver que o ponto referente a 15 metros, ilustra a maior distância entre os pontos analisados nesse projeto até agora, cerca de quase 1 dB de diferença. Provavelmente, isso acontece, pois a relevância desse parâmetro na predição do valor do ganho é quase nula, além disso, os parâmetros principais para a predição estão com os valores mais baixos da base de dados, influenciando em uma maior desconexão, pois observando os gráficos 27b e 27c que utilizam valores maiores para os seus parâmetros, é possível verificar uma maior correlação.


Figura 26 – Variação da figura de ruído em relação a diferentes comprimentos de fibra dopada



(a)




(b)



(c)

Figura 27 – Variação da ganho em relação a diferentes comprimentos de fibra dopada



#### 5.2.1.4 Densidade do Nível de Érbio


Com o aumento do érbio, é possível perceber o aumento da figura de ruído a medida em que se aumenta a dopagem de érbio na fibra. Para o ganho, o gráfico lembra o do comprimento da fibra, cujo para baixos níveis de potência de bombeamento, ele cresce com o aumento da dopagem, alcança um determinado pico de ganho, e em seguida começa a diminuir, ao mesmo tempo em que há um crescente aumento da figura de ruído.

O nível de dopagem em érbio foi o parâmetro que obteve a menor porcentagem nas tabelas de relevância, ilustradas nas tabelas 4 e 5. Ao analisar as Figuras 28 e 29


Levando em consideração o eixo da figura de ruído 28a, ao analisar o ponto de 500 ppm, que é o mais distante entre a base de dados e a predição, é possível verificar que consiste em um erro menor que 0,1 dB. No gráfico 29a, o ultimo ponto, referente ao 1000 ppm, dentre todos os gráficos apresentados nesse projeto, foi o ponto que apresentou a maior distância entre a base

de dados e o modelo, com cerca de 1 dB de diferença. Para o ganho, tanto para a densidade de érbio quanto para o comprimento da fibra, o gráfico referente aos menores valores apresentou a maior desconexão, isso acontece, pois assim como citado na subseção anterior, além da sua relevância na predição do parâmetro ser quase nula, os parâmetros de maior relevância estão na sua faixa mais baixa, implicando em um maior erro, mas que ainda pode ser considerado um erro pequeno. Com o aumento dos valores, os demais gráficos apresentaram uma maior correlação.


Figura 28 – Variação da figura de ruído em relação a diferentes níveis de densidade de érbio



(a)




(b)




(c)


Figura 29 – Variação do ganho em relação a diferentes níveis de densidade de érbio



(a)



(b)



(c)

### 5.2.2 Modelagem Inversa

Após a modelagem satisfatória dos *EDFAs*, o passo subsequente foi a modelagem inversa, ou seja, permitir que o modelo, a partir da figura de ruído e do ganho desejados, possa estimar os parâmetros de entrada especificados. A modelagem inversa foi realizada para a potência do sinal de entrada, para a potência de bombeamento e para o comprimento da fibra, utilizando a base de dados desse projeto (4104 pontos, pois para esse modelo, não foram necessários remover pontos para realizar a análise gráfica, novos pontos foram gerados isoladamente no *OptSystem*) gerando uma nova base de dados apenas para testes. Esta, com diferentes valores de entrada diferente dos utilizados para o treinamento do modelo, porém dentro da faixa destacada no banco de dados. Dessa forma, os parâmetros de saída também se tornaram parâmetros de entrada, aumentando a complexidade do sistema.

Os valores de *holdout* foram testados entre três combinações que se mostravam mais

eficientes: 70/30, 80/20 e 90/10. Para a potência do sinal de entrada a combinação que apresentou o melhor resultado foi a de 90/10, e para a potência bombeamento e comprimento da fibra foi a de 80/20.

#### 5.2.2.1 Modelagem Inversa para a Potência Óptica do Sinal de Entrada

Na tabela a seguir são ilustradas as métricas de desempenho encontradas após a aplicação dos algoritmos de aprendizagem de máquina propostos nesse projeto:


Tabela 6 – Relação de algoritmos testados e seus respectivos valores estatísticos em função da potência de sinal de entrada

| Modelo                          | MAE    | MSE     | RMSE   | $R^2$   | RMSLE  | MAPE   |
|---------------------------------|--------|---------|--------|---------|--------|--------|
| Extra Trees Regressor           | 0,0704 | 0,0399  | 0,1953 | 0,9963  | 0,0344 | 0,0356 |
| Extreme Gradient Boosting       | 0,0915 | 0,0537  | 0,2280 | 0,9949  | 0,0384 | 0,0447 |
| Light Gradient Boosting Machine | 0,1101 | 0,0713  | 0,2640 | 0,9932  | 0,0440 | 0,0630 |
| Random Forest Regressor         | 0,0942 | 0,0794  | 0,2785 | 0,9925  | 0,0522 | 0,0490 |
| Decision Tree Regressor         | 0,1017 | 0,1361  | 0,3611 | 0,9873  | 0,0639 | 0,0498 |
| Gradient Boosting Regressor     | 0,2878 | 0,2393  | 0,4864 | 0,9775  | 0,1075 | 0,1967 |
| K Neighbors Regressor           | 0,4361 | 0,5152  | 0,7154 | 0,9516  | 0,1073 | 0,1867 |
| AdaBoost Regressor              | 0,9299 | 1,5140  | 1,2282 | 0,8574  | 0,3318 | 1,2170 |
| Least Angle Regression          | 1,1085 | 2,0552  | 1,4318 | 0,8054  | 0,3950 | 1,8164 |
| Bayesian Ridge                  | 1,1087 | 2,0553  | 1,4318 | 0,8054  | 0,3950 | 1,8173 |
| Ridge Regression                | 1,1085 | 2,0552  | 1,4318 | 0,8054  | 0,3950 | 1,8165 |
| Linear Regression               | 1,1085 | 2,0552  | 1,4318 | 0,8054  | 0,3950 | 1,8164 |
| Huber Regressor                 | 1,0800 | 2,1272  | 1,4565 | 0,7987  | 0,3702 | 1,6105 |
| Elastic Net                     | 1,2651 | 2,4963  | 1,5783 | 0,7641  | 0,4333 | 2,0850 |
| Lasso Regression                | 1,3504 | 2,7972  | 1,6708 | 0,7356  | 0,4572 | 2,2345 |
| Lasso Least Angle Regression    | 1,3504 | 2,7971  | 1,6708 | 0,7356  | 0,4572 | 2,2346 |
| Orthogonal Matching Pursuit     | 1,6613 | 4,6995  | 2,1662 | 0,5555  | 0,5496 | 2,4542 |
| Passive Aggressive Regressor    | 2,3077 | 9,0533  | 2,7333 | 0,1495  | 0,6660 | 3,6559 |
| Dummy Regressor                 | 2,8532 | 10,6558 | 3,2622 | -0,0060 | 0,8500 | 4,5767 |

É possível ver que o algoritmo que obteve a melhor métrica foi o *Extra Trees Regressor*, no entanto, durante a análise das predições, a diferença entre os valores preditos e os da base de dados eram muito "estáticos". Dessa forma, foi preferível prosseguir com o *Extreme Gradient Boosting*, que como citado anteriormente já possui técnicas que combatem o *overfitting*.

Como analisado anteriormente, o aumento da potência de entrada implica no aumento da figura de ruído e na diminuição do ganho, a Figura 30 ilustra esse comportamento, visto que a medida em que a figura de ruído aumenta a potência óptica incidente também aumenta, e a medida que o ganho aumenta, ela diminui. É possível analisar que o modelo respondeu com precisão para o modelo inverso.

Figura 30 – Análise do modelo inverso para a potência óptica de entrada em função da variação da figura de ruído e do ganho respectivamente



A seguir na Tabela 7, é ilustrada a comparação da relevância entre os parâmetros de entradas.

Tabela 7 – Relevância dos parâmetros de entrada para a figura de ruído

|   | Parâmetros de Entrada             | Porcentagens |
|---|-----------------------------------|--------------|
| 1 | Ganho [dB]                        | 0,631532     |
| 2 | Potência de Bombeamento [mW]      | 0,306698     |
| 3 | Comprimento da Fibra [m]          | 0,027931     |
| 4 | Densidade do Nível de Érbio [ppm] | 0,019883     |
| 5 | Figura de Ruído [dB]              | 0,013957     |

É possível analisar que os parâmetros mais relevantes para a modelagem inversa da potência do sinal incidente são o ganho e a potência de bombeamento, os demais parâmetros apresentam uma relevância bem menor, somados, representam cerca de pouco mais de 6%.

#### 5.2.2.2 Modelagem Inversa Para a Potência de Bombeamento


Para a modelagem da potência de bombeamento, os passos anteriores foram seguidos. Foi utilizado a base de dados anterior, mas dessa vez o modelo iria treinar em função da predição da potência de bombeamento. Sabendo disso, é ilustrada na tabela abaixo a performance dos algoritmos utilizados para esse propósito

Tabela 8 – Relação de algoritmos testados e seus respectivos valores estatísticos em função da potência de bombeamento


| Modelo                          | MAE     | MSE       | RMSE    | $R^2$   | RMSLE  | MAPE   |
|---------------------------------|---------|-----------|---------|---------|--------|--------|
| Extra Trees Regressor           | 0,7382  | 4,0448    | 1,9356  | 0,9966  | 0,0236 | 0,0106 |
| Extreme Gradient Boosting       | 1,3017  | 5,5613    | 2,3448  | 0,9952  | 0,0366 | 0,0206 |
| Light Gradient Boosting Machine | 1,6120  | 6,4614    | 2,5218  | 0,9945  | 0,0382 | 0,0255 |
| Random Forest Regressor         | 1,1889  | 9,0755    | 2,9633  | 0,9923  | 0,0422 | 0,0170 |
| Decision Tree Regressor         | 0,9870  | 20,4711   | 4,4849  | 0,9825  | 0,0712 | 0,0140 |
| Gradient Boosting Regressor     | 4,9744  | 41,9287   | 6,4583  | 0,9642  | 0,1267 | 0,0888 |
| AdaBoost Regressor              | 13,9978 | 263,3240  | 16,2196 | 0,7746  | 0,3072 | 0,2954 |
| K Neighbors Regressor           | 13,3157 | 353,9242  | 18,7992 | 0,6972  | 0,2794 | 0,2262 |
| Least Angle Regression          | 17,0324 | 443,0578  | 21,0332 | 0,6206  | 0,4144 | 0,3488 |
| Bayesian Ridge                  | 17,0334 | 443,0594  | 21,0333 | 0,6206  | 0,4148 | 0,3487 |
| Ridge Regression                | 17,0325 | 443,0574  | 21,0332 | 0,6206  | 0,4144 | 0,3488 |
| Linear Regression               | 17,0324 | 443,0578  | 21,0332 | 0,6206  | 0,4144 | 0,3488 |
| Huber Regressor                 | 16,9430 | 445,0933  | 21,0793 | 0,6189  | 0,4189 | 0,3446 |
| Lasso Regression                | 17,1262 | 445,4989  | 21,0933 | 0,6184  | 0,4010 | 0,3472 |
| Lasso Least Angle Regression    | 17,1262 | 445,4985  | 21,0933 | 0,6184  | 0,4010 | 0,3472 |
| Elastic Net                     | 17,7526 | 472,2327  | 21,7204 | 0,5954  | 0,3928 | 0,3539 |
| Orthogonal Matching Pursuit     | 25,3429 | 897,6119  | 29,9566 | 0,2305  | 0,5228 | 0,5564 |
| Dummy Regressor                 | 30,1639 | 1174,2245 | 34,2594 | -0,0048 | 0,6127 | 0,7157 |
| Passive Aggressive Regressor    | 36,1478 | 1991,7227 | 41,3866 | -0,6953 | 0,7186 | 0,8119 |

Apesar do *Extra Trees Regressor* ter obtido o maior coeficiente de regressão e as menores métricas de erro, optou-se por não utilizá-lo, visto que apresentou o mesmo problema descrito na subseção anterior, nesse caso, foi dada continuidade utilizando o *Extreme Gradient Boosting*. Na Figura 31 é ilustrada a comparação entre a base de dados e a predição do modelo em função da variação da figura de ruído e do ganho.

Figura 31 – Análise do modelo inverso para a potência óptica de entrada em função da variação da figura de ruído e do ganho respectivamente



(a)



(b)

A medida em que se aumenta a figura de ruído, tem-se a redução da potência de bombeamento, assim como com aumento do ganho tem-se um aumento correspondente ao parâmetro de análise. A modelagem também conseguiu realizar uma boa aproximação entre os valores estimados e o banco de dados. E por fim, a seguir, é ilustrada a tabela de importância dos parâmetros na predição da potência de bombeamento.

Tabela 9 – Relevância dos parâmetros de entrada para a figura de ruído

|   | Parâmetros de Entrada             | Porcentagens |
|---|-----------------------------------|--------------|
| 1 | Ganho [dB]                        | 0,471589     |
| 2 | Potência do Sinal de Entrada [mW] | 0,438602     |
| 3 | Figura de Ruído [dB]              | 0,071354     |
| 4 | Comprimento da Fibra [m]          | 0,011768     |
| 5 | Densidade do Nível de Érbio [ppm] | 0,006687     |

Para finalizar, é possível observar que os parâmetros mais importantes para a predição desse parâmetro são o ganho e a potência óptica incidente, os demais parâmetros somados compõem cerca de quase 9% do valor total.

#### 5.2.2.3 Modelagem Inversa Para o Comprimento da Fibra


Sequencialmente foi realizado a modelagem para o comprimento da fibra também os passos anteriores foram seguidos. O modelo também foi treinado utilizando a mesma base de dados, porém com o comprimento da fibra como alvo de predição. Sabendo disso, é ilustrada na tabela abaixo a performance dos algoritmos utilizados para esse propósito

Tabela 10 – Relação de algoritmos testados e seus respectivos valores estatísticos em função do comprimento da fibra


| Modelo                          | MAE    | MSE     | RMSE   | $R^2$   | RMSLE  | MAPE   |
|---------------------------------|--------|---------|--------|---------|--------|--------|
| Extreme Gradient Boosting       | 0,6017 | 0,6144  | 0,7829 | 0,9475  | 0,0704 | 0,0622 |
| Extra Trees Regressor           | 0,7205 | 0,8716  | 0,9319 | 0,9255  | 0,0833 | 0,0755 |
| Light Gradient Boosting Machine | 0,7051 | 0,8863  | 0,9403 | 0,9243  | 0,0824 | 0,0715 |
| Random Forest Regressor         | 0,8599 | 1,1848  | 1,0871 | 0,8987  | 0,0987 | 0,0904 |
| Decision Tree Regressor         | 1,2031 | 2,8717  | 1,6935 | 0,7540  | 0,1562 | 0,1225 |
| Gradient Boosting Regressor     | 1,5662 | 3,5461  | 1,8819 | 0,6969  | 0,1833 | 0,1797 |
| Linear Regression               | 2,3771 | 8,1584  | 2,8559 | 0,3016  | 0,2759 | 0,2781 |
| Ridge Regression                | 2,3772 | 8,1584  | 2,8559 | 0,3016  | 0,2759 | 0,2781 |
| Bayesian Ridge                  | 2,3780 | 8,1585  | 2,8559 | 0,3016  | 0,2760 | 0,2783 |
| Huber Regressor                 | 2,3665 | 8,2740  | 2,8759 | 0,2915  | 0,2772 | 0,2767 |
| K Neighbors Regressor           | 2,5256 | 9,7810  | 3,1260 | 0,1634  | 0,3064 | 0,3027 |
| Elastic Net                     | 2,7256 | 9,8228  | 3,1335 | 0,1598  | 0,3115 | 0,3308 |
| AdaBoost Regressor              | 2,7482 | 10,0440 | 3,1677 | 0,1414  | 0,3146 | 0,3345 |
| Lasso Regression                | 2,8849 | 10,9208 | 3,3038 | 0,0660  | 0,3270 | 0,3508 |
| Lasso Least Angle Regression    | 2,8849 | 10,9205 | 3,3038 | 0,0660  | 0,3270 | 0,3508 |
| Dummy Regressor                 | 3,0084 | 11,7217 | 3,4231 | -0,0027 | 0,3377 | 0,3661 |
| Orthogonal Matching Pursuit     | 3,0090 | 11,7261 | 3,4238 | -0,0031 | 0,3378 | 0,3661 |
| Least Angle Regression          | 3,1324 | 18,5588 | 4,0340 | -0,6069 | 0,3859 | 0,3600 |
| Passive Aggressive Regressor    | 3,8095 | 21,9474 | 4,6210 | -0,8743 | 0,4408 | 0,4618 |

Para o comprimento da fibra, o algoritmo que mais se destacou foi o *Extreme Gradient Boosting*. Dessa forma, todos os modelos para as modelagens inversas utilizaram o o mesmo algoritmo de *ML*.

Figura 32 – Análise do modelo inverso para a potência óptica de entrada em função da variação da figura de ruído e do ganho respectivamente



(a)



(b)

É possível analisar na 32a que na medida em que se aumenta a figura de ruído, aumenta-se o comprimento da fibra. Para o ganho há um "gráfico de parábola", pois na medida em que se vai

aumentando o comprimento da fibra, há um momento em que o ganho do amplificador começa a cair. É possível analisar na Figura 32b que existem momentos em que existem valores de ganho praticamente iguais, mas para comprimentos divergentes, como é o caso dos pontos de 4 e 14 m.

Vale ressaltar que para esse parâmetro também foi utilizado uma base de dados extra simulada no *OptiSystem* para ser utilizada na comparação gráfica. No entanto, ao contrário da potência de sinal incidente e da potência de bombeamento, que utilizavam dados para testes que estavam dentro do intervalo utilizado na base de dados, para esse parâmetro em específico, foram utilizados nos testes valores que também estavam fora do intervalo utilizado para treinamento.

O modelo desenvolvido foi capaz de estimar com precisão o comprimento da fibra, mesmo para momentos em que o ganho era praticamente igual, ilustrando a correlação do comprimento da fibra com a figura de ruído correspondente. E por fim, a seguir, é ilustrada a tabela de importância dos parâmetros na predição do comprimento da fibra.

Tabela 11 – Relevância dos parâmetros de entrada para a figura de ruído

|   | Parâmetros de Entrada             | Porcentagens |
|---|-----------------------------------|--------------|
| 1 | Figura de Ruído [dB]              | 0,306443     |
| 2 | Ganho [dB] [dB]                   | 0,266159     |
| 3 | Densidade do Nível de Érbio [ppm] | 0,145437     |
| 4 | Potência de Bombeamento [mW]      | 0,144267     |
| 5 | Potência do Sinal de Entrada [mW] | 0,137693     |

Para finalizar, é possível observar que os parâmetros mais importantes para a predição do comprimento da fibra são o ganho e a figura de ruído, seguido pela densidade do nível de érbio. Um comportamento atípico quando comparado aos parâmetros anteriores, que tinham como parâmetros mais relevantes as potências do sinal de entrada e a potência de bombeamento. Para o modelo inverso do comprimento da fibra, estes parâmetros são os menos relevantes, porém é possível perceber que comparado aos outros modelos inversos, este é o que a relevância dos parâmetros utilizados como entrada são bem mais distribuídos ou balanceados, visto que para os anteriores, a maior porcentagem de relevância era concentrada em dois parâmetros e neste todos possuem uma porcentagem aproximada.

### 5.3 Diferença de tempo de processamento

O tempo necessário para simular os 4.104 pontos no *OptiSystem* foi de 12 minutos e 48 segundos, enquanto o desenvolvimento dos modelos de aprendizado de máquina, tanto para a modelagem direta quanto para a inversa, ocorreu de forma praticamente instantânea. O

treinamento do algoritmo levou apenas 0,15 segundos, e a simulação dos 1250 pontos abordada na próxima seção, foi praticamente imediata, com o *Google Colab* indicando um tempo de 0 segundos.

É importante destacar que o tempo de processamento no *OptiSystem* depende diretamente do número de pontos analisados, bem como das especificações do dispositivo utilizado para realizar a simulação.

#### 5.4 Teste de *overfitting*

Por fim, para verificar se os modelos de *ML* não estavam suscetíveis ao *overfitting*, foi realizado um último teste utilizando uma nova base de dados para avaliar os modelos desenvolvidos na modelagem direta.

Esse teste consistiu em gerar uma nova base de dados com valores diferentes daqueles utilizados previamente para o treinamento dos modelos, mas ainda dentro do intervalo estabelecido.

Para essa nova base de teste, os parâmetros de entrada foram explorados conforme a Tabela 12, totalizando 1250 pontos.

Tabela 12 – Detalhamento dos parâmetros para o teste de *overfitting*

| Parâmetros de Entrada     | Valor Inicial | Valor Final | Passo   | Nível de Varredura |
|---------------------------|---------------|-------------|---------|--------------------|
| Potência Óptica Incidente | 0,15 mW       | 0,95 mW     | 0,2 mW  | 1                  |
| Potência Óptica Incidente | 1,5 mW        | 9,5 mW      | 2 mW    | 1                  |
| Potência de Bombeamento   | 30 mW         | 110 mW      | 20 mW   | 2                  |
| Comprimento da Fibra      | 6 m           | 14 m        | 2 m     | 3                  |
| Concentração de Érbio     | 550 ppm       | 950 ppm     | 100 ppm | 4                  |

Ao submeter a base de teste aos modelos desenvolvidos neste projeto, foram obtidas as seguintes métricas, apresentadas nas tabelas abaixo.

Tabela 13 – Teste de *overfitting* aplicado a modelagem direta da figura de ruído

| Modelo                    | MAE    | MSEM   | RMSE   | $R^2$  | RMSLE  | MAPE   |
|---------------------------|--------|--------|--------|--------|--------|--------|
| Extreme Gradient Boosting | 0,1558 | 0,0466 | 0,2159 | 0,9828 | 0,0337 | 0,0297 |

Tabela 14 – Teste de *overfitting* aplicado a modelagem direta do ganho

| Modelo                    | MAE    | MSE    | RMSE   | $R^2$  | RMSLE  | MAPE   |
|---------------------------|--------|--------|--------|--------|--------|--------|
| Extreme Gradient Boosting | 0,6880 | 0,8759 | 0,9359 | 0,9727 | 0,1012 | 0,0671 |

Demonstrando que, mesmo quando submetido a combinações diferentes de valores de entrada, o modelo mantém um alto coeficiente de regressão e baixos valores de erro, indicando a ausência de *overfitting*.

## 6 CONCLUSÃO

Tanto o ganho quanto a figura de ruído foram modelados utilizando o algoritmo *Extreme Gradient Boosting*, com uma divisão dos dados de *holdout* de 90% para treinamento e 10% para testes. Para o modelo aplicado à figura de ruído, os resultados obtidos foram:  $R^2$  de 0,9987, MAE de 0,0428, MSE de 0,0046, RMSE de 0,0677, RMSLE de 0,0095 e MAPE de 0,0077. Já para o modelo aplicado ao ganho, os valores alcançados foram  $R^2$  de 0,9996, MAE de 0,0565, MSE de 0,0150, RMSE de 0,1185, RMSLE de 0,0174 e MAPE de 0,0087.

Ambos os modelos demonstraram coeficientes de determinação ( $R^2$ ) próximos da unidade e baixos valores nos indicadores de erro, evidenciando sua elevada precisão. O modelo do ganho apresentou ligeira superioridade nos parâmetros estatísticos de validação em comparação ao modelo da figura de ruído, o que pode ser atribuído à linearidade intrínseca do ganho, enquanto a figura de ruído possui características não lineares. Ademais, observou-se uma relação inversamente proporcional entre ganho e figura de ruído, conforme previamente demonstrado em (2.20), em que aumentos no ganho resultam em diminuições na figura de ruído e vice-versa.

Os resultados indicam que o modelo foi capaz de estimar, com elevada eficiência, esses parâmetros fundamentais para a modelagem de amplificadores ópticos dopados com érbio. Em comparação com métodos tradicionais, o modelo proposto apresenta vantagens significativas, como alta precisão, menor complexidade, redução no tempo de resposta e menor demanda de processamento.

Adicionalmente, foi realizada a modelagem inversa dos amplificadores, possibilitando estimar, a partir das variações no ganho e na figura de ruído, os seguintes parâmetros: potência do sinal de entrada, potência de bombeamento e comprimento da fibra. Os coeficientes de determinação obtidos para esses parâmetros foram  $R^2$  de 0,9949, 0,9952 e 0,9475, respectivamente, confirmando a robustez e a aplicabilidade do modelo proposto.

## 7 PROJETOS FUTUROS

- Testar diferentes arquiteturas de *EDFA*;
- Testar comprimento de bombeamento de 1480 nm;
- Testar com *Support Vector Machine (SVM)*;
- Testar com redes neurais.
- Realizar a modelagem inversa para a densidade de érbio;
- Testar em sistemas *WDM*;
- Servir como base para o desenvolvimento de *EDFAs* com controle adaptativo.

## REFERÊNCIAS

- AGRAWAL, G. **Sistemas de comunicação por fibra óptica**. [S.l.]: Elsevier Brasil, 2014. v. 4.
- BASTOS-FILHO, C. J.; BARBOZA, E. d. A.; MARTINS-FILHO, J. F. Estimating the spectral gain and the noise figure of edfa using artificial neural networks. In: **2017 19th International Conference on Transparent Optical Networks (ICTON)**. [S.l.: s.n.], 2017. p. 1–4.
- BRUCE, A.; BRUCE, P. **Estatística prática para cientistas de dados**. [S.l.]: Alta Books, 2019.
- CARVALHO, A.; FACELI, K.; LORENA, A.; GAMA, J. Inteligência artificial—uma abordagem de aprendizado de máquina. **Rio de Janeiro: LTC**, v. 2, p. 45, 2011.
- CHEN, T.; GUESTRIN, C. Xgboost: A scalable tree boosting system. In: **Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining**. [S.l.: s.n.], 2016. p. 785–794.
- CHEN, Y.; DU, J.; HUANG, Y.; XU, K.; HE, Z. Intelligent gain flattening in wavelength and space domain for fmf raman amplification by machine learning based inverse design. **Optics Express**, Optica Publishing Group, v. 28, n. 8, p. 11911–11920, 2020.
- COKRAK, A. C.; ALTUNCU, A. Gain and noise figure performance of erbium doped fiber amplifiers (edfa). **IU-Journal of Electrical & Electronics Engineering**, İstanbul University-Cerrahpasa, v. 4, n. 2, p. 1111–1122, 2004.
- CONTRIBUTORS scikit-learn. **scikit-learn: Regression Metrics**. 2024. <[https://scikit-learn.org/stable/modules/model\\_evaluation.html#regression-metrics](https://scikit-learn.org/stable/modules/model_evaluation.html#regression-metrics)>. Accessed: January 15, 2024.
- CRIMINISI, A.; SHOTTON, J.; KONUKOGLU, E. *et al.* Decision forests: A unified framework for classification, regression, density estimation, manifold learning and semi-supervised learning. **Foundations and trends® in computer graphics and vision**, Now Publishers, Inc., v. 7, n. 2–3, p. 81–227, 2012.
- DESURVIRE, E. **Erbium-Doped Fiber Amplifiers: Device and System Developments**. Wiley, 2002. (A John Wiley & Sons, Inc., publication). ISBN 9780471419037. Disponível em: <<https://books.google.com.br/books?id=WfxSAAAAMAAJ>>.
- FREITAS, L. M. de; BARBOZA, E. d. A.; BASTOS-FILHO, C. J.; MARTINS-FILHO, J. F. Surrogate model for adaptive control of optical amplifier operating point based on machine learning. In: IEEE. **2021 IEEE Latin-American Conference on Communications (LATINCOM)**. [S.l.], 2021. p. 1–6.
- GUIMARÃES, G. de F. **Amplificador e conversor de comprimento de onda híbrido TD-FA/FOPA para comunicações ópticas**. Dissertação (Mestrado) — Universidade Federal de Pernambuco, 2006.
- HARRISON, M. **Machine Learning—Guia de referência rápida: trabalhando com dados estruturados em Python**. [S.l.]: Novatec Editora, 2019.
- HUANG, Y.; DU, J.; CHEN, Y.; XU, K.; HE, Z. Machine learning assisted inverse design for ultrafine, dynamic and arbitrary gain spectrum shaping of raman amplification. In: MDPI. **Photonics**. [S.l.], 2021. v. 8, n. 7, p. 260.

KAMEL, S.; HAUFERMANN, H.; GAC, D. L.; SANTOS, L. D.; KÉGL, B.; FRIGNAC, Y.; CHARLET, G. Osnr prediction for optical links via learned noise figures. In: IEEE. **2021 European Conference on Optical Communication (ECOC)**. [S.l.], 2021. p. 1–4.

KAUR, I.; MANNA, M. S.; MARIMUTHU, R. Implementing hybrid amplifiers for dwdm system using artificial intelligence methods. In: IEEE. **2021 IEEE International Conference on Service Operations and Logistics, and Informatics (SOLI)**. [S.l.], 2021. p. 1–5.

KEISER, G. **Comunicações por Fibras Ópticas-4**. [S.l.]: AMGH Editora, 2014.

KUMAR, G. S.; JAISHARMA, K. Improve the accuracy for flight ticket prediction using xgbregressor optimizer in comparison with extra treeregressor performance. In: IEEE. **2023 6th International Conference on Contemporary Computing and Informatics (IC3I)**. [S.l.], 2023. v. 6, p. 2558–2562.

LIN, J.; LIN, X.; JIANG, Z. Auxiliary neural network assisted machine learning edfa gain model. In: OPTICA PUBLISHING GROUP. **Optical Fiber Communication Conference**. [S.l.], 2023. p. M2E–2.

MALAKZADEH, A.; PASHAIE, R.; MANSOURSAMAEI, M. Gain and noise figure performance of an edfa pumped at 980 nm or 1480 nm for dofss. **Optical and Quantum Electronics**, Springer, v. 52, p. 1–16, 2020.

MARCON, G.; GALTAROSSA, A.; PALMIERI, L.; SANTAGIUSTINA, M. C+ l band gain design in few-mode fibers using raman amplification and machine learning. In: IEEE. **2020 Italian Conference on Optics and Photonics (ICOP)**. [S.l.], 2020. p. 1–4.

MASÍS, S. **Interpretable Machine Learning with Python: Learn to build interpretable high-performance models with hands-on real-world examples**. [S.l.]: Packt Publishing Ltd, 2023. v. 2.

MATERA, F. Machine learning in soa optical communication systems. In: IEEE. **2020 Italian Conference on Optics and Photonics (ICOP)**. [S.l.], 2020. p. 1–4.

NANFACK, P. F. T.; FUTE, E. T.; ELE, P. A. Pycaret for the evaluation of classification methods in order to set up a decision making system for the early diagnosis of schizophrenia by eeg. In: IEEE. **2022 16th International Conference on Signal-Image Technology & Internet-Based Systems (SITIS)**. [S.l.], 2022. p. 335–340.

PATEL, V.; CHOE, S.; HALABI, T. Predicting future malware attacks on cloud systems using machine learning. In: IEEE. **2020 IEEE 6th Intl Conference on Big Data Security on Cloud (Big-DataSecurity), IEEE Intl Conference on High Performance and Smart Computing,(HPSC) and IEEE Intl Conference on Intelligent Data and Security (IDS)**. [S.l.], 2020. p. 151–156.

RAHMAN, K. F.; AFRIN, F.; TAIP, F. S. bin. Optical network performance analysis through prediction of q factor on simulated and validated dataset. In: IEEE. **2018 IEEE International Conference on Artificial Intelligence in Engineering and Technology (IICAIET)**. [S.l.], 2018. p. 1–4.

ROS, F. D.; MOURA, U. C. D.; YANKOV, M. P. Machine learning-based edfa gain model generalizable to multiple physical devices. In: IEEE. **2020 European Conference on Optical Communications (ECOC)**. [S.l.], 2020. p. 1–4.

SADIK, S. A. Noise figure estimation of edfa based on gradient boosting regression approach for thz applications. In: IEEE. **2022 Workshop on Microwave Theory and Techniques in Wireless Communications (MTTW)**. [S.l.], 2022. p. 86–89.

SHUKLA, P.; KAUR, K. P. Performance analysis of edfa for different pumping configurations at high data rate. **International Journal of Engineering and Advanced Technology (IJEAT)**, Citeseer, v. 2, n. 5, p. 487–490, 2013.

SIBINDI, R.; MWANGI, R. W.; WAITITU, A. G. A boosting ensemble learning based hybrid light gradient boosting machine and extreme gradient boosting model for predicting house prices. **Engineering Reports**, Wiley Online Library, v. 5, n. 4, p. e12599, 2023.

SUTILI, T.; MINETO, C.; RIVEROS, L. G. M.; SILVA, M. J. D.; SIMÕES, F. D.; FIGUEIREDO, R. C. Wideband amplification for the next generation of optical transport networks. In: IEEE. **2022 SBFoton International Optics and Photonics Conference (SBFoton IOPC)**. [S.l.], 2022. p. 1–6.

TAY, K.; PAKARZADEH, H.; HUONG, A.; OTHMAN, N.; CHOLAN, N. Gain prediction of dual-pump fiber optic parametric amplifier based on artificial neural network. **Optik**, Elsevier, v. 253, p. 168579, 2022.

VISWANATHA, V. Thyroid disease detection using machine learning approach. OSF Preprints, 2023.

WANG, Z.; KILPER, D.; CHEN, T. An open edfa gain spectrum dataset and its applications in data-driven edfa gain modeling. *Optica Open*, 2023.

YANKOV, M. P.; KAMINSKI, P. M.; HANSEN, H. E.; ROS, F. D. Snr optimization of multi-span fiber optic communication systems employing edfas with non-flat gain and noise figure. **Journal of Lightwave Technology**, IEEE, v. 39, n. 21, p. 6824–6832, 2021.

YOU, Y.; JIANG, Z.; JANZ, C. Machine learning-based edfa gain model. In: IEEE. **2018 European Conference on Optical Communication (ECOC)**. [S.l.], 2018. p. 1–3.

YU, J.; ZHU, S.; GUTTERMAN, C. L.; ZUSSMAN, G.; KILPER, D. C. Machine-learning-based edfa gain estimation. **Journal of Optical Communications and Networking**, Optica Publishing Group, v. 13, n. 4, p. B83–B91, 2021.

ZHU, S.; GUTTERMAN, C.; MONTIEL, A. D.; YU, J.; RUFFINI, M.; ZUSSMAN, G.; KILPER, D. Hybrid machine learning edfa model. In: OPTICA PUBLISHING GROUP. **Optical Fiber Communication Conference**. [S.l.], 2020. p. T4B–4.

ZHU, S.; GUTTERMAN, C. L.; MO, W.; LI, Y.; ZUSSMAN, G.; KILPER, D. C. Machine learning based prediction of erbium-doped fiber wdm line amplifier gain spectra. In: IEEE. **2018 European Conference on Optical Communication (ECOC)**. [S.l.], 2018. p. 1–3.