

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ**

**VINICIUS DE CARVALHO**

**SISTEMA DE MAPEAMENTO DE FORÇA COM SENSORES DE  
MACROCURVATURA EM FIBRA ÓTICA MULTIPLEXADOS**

**CURITIBA**

**2022**

**VINICIUS DE CARVALHO**

**SISTEMA DE MAPEAMENTO DE FORÇA COM SENSORES DE  
MACROCURVATURA EM FIBRA ÓTICA MULTIPLEXADOS**

**Force mapping system based on optical fiber macrobend sensors**

Dissertação de mestrado apresentada ao Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do grau de Mestre em Ciências - Área de Concentração: Fotônica em Engenharia.

Orientador: Profa. Dra. Marcia Muller

Coorientador: Prof. Dr. José Luis Fabris

**CURITIBA**

**2022**



[4.0 Internacional](https://creativecommons.org/licenses/by/4.0/)

Esta licença permite compartilhamento, remixe, adaptação e criação a partir do trabalho, mesmo para fins comerciais, desde que sejam atribuídos créditos ao(s) autor(es). Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.



VINICIUS DE CARVALHO

**SISTEMA DE MAPEAMENTO DE FORÇA COM SENSORES DE MACROCURVATURA EM FIBRA ÓTICA  
MULTIPLEXADOS**

Trabalho de pesquisa de mestrado apresentado como requisito para obtenção do título de Mestre Em Ciências da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Fotônica Em Engenharia.

Data de aprovação: 28 de Julho de 2022

Dra. Marcia Muller, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Andre Eugenio Lazzaretti, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Hypolito Jose Kalinowski, Doutorado - Universidade Federal Fluminense (Uff)

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 28/07/2022.

## **AGRADECIMENTOS**

Aos meus orientadores, Professora Marcia Muller e Professor José Luís Fabris, pela confiança, oportunidade de trabalho e orientações. À Universidade Tecnológica Federal do Paraná e em especial aos Professores do Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial.

Aos colegas do Laboratório de Laser pelas discussões decorrentes da pesquisa e pelos trabalhos desenvolvidos em conjunto.

Aos meus pais e a todos que me apoiaram e estiveram ao meu lado em anos tão atípicos.

À CAPES, CNPq, Fundação Araucaria e Finep. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

## RESUMO

O trabalho apresenta sistemas de sensoriamento aplicados na monitoração *quasi*-distribuída de força sobre estruturas rígidas. O sensoriamento é baseado na resposta de uma rede de sensores de macrocurvatura multiplexados em série em fibras óticas. Os dois sistemas construídos e avaliados contêm três e cinco elementos sensores multiplexados em um único enlace de fibra, esses dispositivos estão acoplados a estruturas de tipo placa com objetivo de monitorar a posição e a magnitude de uma força individual empregada nas estruturas. As magnitudes das forças utilizadas nos ensaios experimentais correspondem a faixa entre 100 gf e 2000 gf em passos de 100 gf. Uma matriz de sensoriamento unidimensional é formada por estrutura de PMMA, com 30 cm de comprimento e 5 cm de largura, instrumentada com três elementos sensores, a região monitorada apresenta seis áreas colineares de aplicação de força. Também é elaborada uma matriz de sensoriamento bidimensional, formada por estrutura metálica quadrada com lados de 20 cm instrumentada com cinco elementos sensores, tal estrutura apresenta nove áreas de aplicação de força. Para viabilizar a operação dos sistemas de sensoriamento, são avaliados modelos de regressão voltados a processamento do sinal ótico transmitido pela fibra. Foram implementados modelos de regressão lineares e não lineares, baseados em Rede Elástica e Vetores Suportes com dimensionalidade reduzida por Análise de Componentes Principais (PCA). Os modelos preditivos treinados que apresentam melhores resultados são aplicados em uma etapa de teste que simula a operação real dos sistemas sensores. Os desempenhos médios detectados variaram de acordo com a estrutura monitorada, com a complexidade do modelo e com o número de variáveis características utilizadas. Os menores erros médios de predição na etapa de teste são de 2,41 cm e 177 gf, já os maiores são de 4,01 cm e 397 gf para estimativa da posição e da magnitude da força, respectivamente. Os resultados apresentados evidenciam capacidade de operação dos modelos de regressão com dimensionalidade reduzida tanto por penalização  $L_1$  do modelo de Rede Elástica como por PCA. A partir dos modelos baseados em Rede Elástica foi realizada uma avaliação de faixas espectrais relevantes para operação dos sistemas.

**Palavras-chave:** sensores óticos; macrocurvatura em fibra ótica; sensor multiplexado; estrutura rígida; modelos de regressão.

## ABSTRACT

The work presents sensing systems applied in the *quasi*-distributed force monitoring on rigid structures. The sensing is based on the response of an array of macrocurvature sensors serially multiplexed. Systems were developed with three and five sensor elements multiplexed in a single fiber link. These devices were coupled to plate-like structures to monitor the position and magnitude of an individual force applied to these structures. The magnitudes of the forces used in the experimental tests correspond to the range between 100 gf and 2000 gf in steps of 100 gf. A one-dimensional sensing matrix was formed by a PMMA structure, 30 cm long and 5 cm wide, instrumented with three sensing elements. The monitored region had six collinear force application areas. A two-dimensional sensing matrix was also elaborated, formed by a square metallic structure with sides of 20 cm instrumented with five sensing elements. This structure had nine force application areas. Regression models aimed at processing the optical signal transmitted by the fiber to make the sensing systems operation viable. Linear and nonlinear regression models were implemented based on Elastic Net and Support Vectors with reduced dimensionality by Principal Component Analysis (PCA). The trained predictive models that presented better results were applied in a test step that simulated the actual operation of the sensor systems. The average performances detected varied according to the monitored structure, the model complexity, and the number of characteristic variables used. The minor prediction errors in the test stage were 2.41 cm and 177 gf, while the largest were 4.01 cm and 397 gf for estimating the position and magnitude of the force, respectively. The results presented show the operating capacity of the regression models with reduced dimensionality both by  $L_1$  penalty of the Elastic Net model and by PCA. From the models based on Elastic Net, an evaluation of relevant spectral bands to the operation of the systems was carried out.

**Keywords:** optical sensors; optical fiber macrobending; multiplexed sensors; rigid structure; regression models.

## LISTA DE FIGURAS

|                                                                                                                                                                                                                                                                                                             |           |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------|
| <b>Figura 1 – Corte de seção transversal de uma fibra ótica padrão. . . . .</b>                                                                                                                                                                                                                             | <b>28</b> |
| <b>Figura 2 – Configuração de componentes padrão em um sistema sensor em fibra<br/>ótica baseado em sinal transmitido. . . . .</b>                                                                                                                                                                          | <b>29</b> |
| <b>Figura 3 – Perdas óticas associadas às regiões de uma curvatura de fibra ótica. . .</b>                                                                                                                                                                                                                  | <b>31</b> |
| <b>Figura 4 – Representação de regressão linear por vetor suporte com observações X<br/>e margens. . . . .</b>                                                                                                                                                                                              | <b>36</b> |
| <b>Figura 5 – Função de penalização linear. . . . .</b>                                                                                                                                                                                                                                                     | <b>37</b> |
| <b>Figura 6 – Validação cruzada 10-fold. . . . .</b>                                                                                                                                                                                                                                                        | <b>42</b> |
| <b>Figura 7 – Anel de fibra ótica fixado com um laço simples utilizado para fabricação<br/>de transdutor baseado em macrocurvatura. . . . .</b>                                                                                                                                                             | <b>43</b> |
| <b>Figura 8 – Representações dos elementos sensores utilizados no sistema ótico. (a)<br/>Elemento sensor formado por estrutura de fibra curvada em anel e<br/>encapsulação. (b) Corte transversal do elemento sensor mostrando posi-<br/>cionamento do anel de fibra interno ao encapsulamento. . . . .</b> | <b>44</b> |
| <b>Figura 9 – (a) Sistema em fibra ótica com três elementos sensores multiplexados.<br/>(b) Matriz de sensoriamento unidimensional para monitoração de força<br/>individual aplicada em diferentes áreas colineares. Linha realçada sobre<br/>a fibra ótica para visualização. . . . .</b>                  | <b>45</b> |
| <b>Figura 10 – Em preto as áreas e coordenadas centrais de aplicação de força na matriz<br/>de sensoriamento unidimensional. Em cinza, posições dos elementos<br/>sensores acoplados à estrutura. . . . .</b>                                                                                               | <b>45</b> |
| <b>Figura 11 – (a) Sistema em fibra ótica com cinco elementos sensores multiplexados.<br/>(b) Matriz de sensoriamento bidimensional para monitoração de força<br/>individual aplicada sobre a estrutura. Linha realçada sobre a fibra ótica<br/>para visualização. . . . .</b>                              | <b>46</b> |
| <b>Figura 12 – Em preto as áreas e coordenadas centrais de aplicação de força na ma-<br/>triz de sensoriamento bidimensional. Em cinza, posições dos elementos<br/>sensores acoplados à estrutura. . . . .</b>                                                                                              | <b>47</b> |
| <b>Figura 13 – Esquema de montagem experimental conectando em série fonte ótica,<br/>estrutura rígida sensora, espectrômetro e computador. . . . .</b>                                                                                                                                                      | <b>48</b> |

|                                                                                                                                                                                                                                                                                                                                                                             |           |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------|
| <b>Figura 14 – Mecanismo aplicador de forças. . . . .</b>                                                                                                                                                                                                                                                                                                                   | <b>48</b> |
| <b>Figura 15 – Métrica das matrizes de entrada para implementação dos modelos. . .</b>                                                                                                                                                                                                                                                                                      | <b>52</b> |
| <b>Figura 16 – Fluxograma de tratamento de dados, implementação e avaliação dos<br/>modelos de Regressão por Rede Elástica a partir dos conjuntos de dados.</b>                                                                                                                                                                                                             | <b>54</b> |
| <b>Figura 17 – Fluxograma de tratamento de dados, implementação e avaliação dos<br/>modelos de Regressão por Vetores Suporte a partir dos conjuntos de<br/>dados. . . . .</b>                                                                                                                                                                                               | <b>55</b> |
| <b>Figura 18 – Espectros de transmissão com intensidades relativas detectadas no sis-<br/>tema contendo três sensores conectados em série quando aplicadas<br/>forças individuais diretamente sobre cada um dos elementos sensores.<br/>(a) Elemento sensor 1. (b) Elemento sensor 2. (c) Elemento sensor 3. . .</b>                                                        | <b>57</b> |
| <b>Figura 19 – Espectros de transmissão com intensidades relativas detectadas no sis-<br/>tema contendo cinco sensores conectados em série quando aplicadas<br/>forças individuais diretamente sobre cada um dos elementos sensores.<br/>(a) Elemento sensor 1. (b) Elemento sensor 2. (c) Elemento sensor 3. (d)<br/>Elemento sensor 4. (e) Elemento sensor 5. . . . .</b> | <b>58</b> |
| <b>Figura 20 – Repetibilidade dos espectros de transmissão associados a cinco configu-<br/>rações de força, apresentadas na Tabela 1 e Tabela 2, aplicadas sobre as<br/>duas matrizes de sensoriamento. (a) Resultados matriz de sensoriamento<br/>unidimensional. (b) Resultados matriz de sensoriamento bidimensional.</b>                                                | <b>59</b> |
| <b>Figura 21 – Módulos dos coeficientes de regressão por comprimento de onda resul-<br/>tantes dos modelos de Rede Elástica com <math>\alpha = 0,9</math> aplicados na matriz de<br/>sensoriamento unidimensional. (a) Modelo de predição da posição da<br/>força. (b) Modelo de predição da magnitude força. . . . .</b>                                                   | <b>63</b> |
| <b>Figura 22 – Predições do modelo baseado em Rede Elástica e alvos associados a<br/>cinco configurações de força aplicadas na matriz de sensoriamento<br/>unidimensional. . . . .</b>                                                                                                                                                                                      | <b>64</b> |
| <b>Figura 23 – Variabilidade cumulativa explicada por componentes principais para<br/>matriz de sensoriamento unidimensional. . . . .</b>                                                                                                                                                                                                                                   | <b>65</b> |
| <b>Figura 24 – Predições do modelo baseado em Vetores Suporte de kernel linear com<br/>5 componentes principais e alvos associados a cinco configurações de<br/>força do conjunto de teste. . . . .</b>                                                                                                                                                                     | <b>67</b> |

|                                                                                                                                                                                                                                                                                                                                                                     |           |
|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------|
| <b>Figura 25 – Predições do modelo baseado em Vetores Suporte de kernel quadrático com 4 componentes principais e alvos associados a cinco configurações de força aplicadas na matriz de sensoriamento unidimensional. . . . .</b>                                                                                                                                  | <b>69</b> |
| <b>Figura 26 – Módulos dos coeficientes de regressão por comprimento de onda resultantes dos modelos de Rede Elástica com <math>\alpha = 0,9</math> aplicados na matriz de sensoriamento bidimensional. (a) Modelo de predição da posição em x da força. (b) Modelo de predição da posição em y da força. (c) Modelo de predição da magnitude da força. . . . .</b> | <b>72</b> |
| <b>Figura 27 – Predições do modelo baseado em Rede Elástica e alvos associados a cinco configurações de força aplicadas na matriz de sensoriamento bidimensional. (a) Predições e alvos para monitoração da posição da força. (b) Predições e alvos para monitoração da magnitude da força. .</b>                                                                   | <b>73</b> |
| <b>Figura 28 – Variabilidade cumulativa explicada por componentes principais para matriz de sensoriamento bidimensional. . . . .</b>                                                                                                                                                                                                                                | <b>74</b> |
| <b>Figura 29 – Predições do modelo baseado em Vetores Suporte de kernel linear com 11 componentes principais e alvos associados a cinco configurações de força aplicadas na matriz de sensoriamento bidimensional. (a) Predições e alvos para monitoração da posição da força. (b) Predições e alvos para monitoração da magnitude da força. . . . .</b>            | <b>76</b> |
| <b>Figura 30 – Predições do modelo baseado em Vetores Suporte de kernel quadrático com 4 componentes principais e alvos associados a cinco configurações de força aplicadas na matriz de sensoriamento bidimensional. (a) Predições e alvos para monitoração da posição da força. (b) Predições e alvos para monitoração da magnitude da força. . . . .</b>         | <b>78</b> |
| <b>Figura 31 – Erros de sensoriamento da posição da força em amostras de teste para o sistema sensor acoplado a matriz unidimensional. . . . .</b>                                                                                                                                                                                                                  | <b>80</b> |
| <b>Figura 32 – Erros de sensoriamento da magnitude da força em amostras de teste para o sistema sensor acoplado a matriz unidimensional. . . . .</b>                                                                                                                                                                                                                | <b>81</b> |
| <b>Figura 33 – Erros de sensoriamento da posição da força em amostras de teste para o sistema sensor acoplado a matriz bidimensional. (a) Eixo x. (b) Eixo y. .</b>                                                                                                                                                                                                 | <b>82</b> |
| <b>Figura 34 – Erros de sensoriamento da magnitude da força em amostras de teste para o sistema sensor acoplado a matriz bidimensional. . . . .</b>                                                                                                                                                                                                                 | <b>84</b> |

## LISTA DE TABELAS

|                                                                                                                                                                                                                   |           |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------|
| <b>Tabela 1 – Configurações de força aplicadas na matriz de sensoriamento unidimensional para análise de repetibilidade. . . . .</b>                                                                              | <b>49</b> |
| <b>Tabela 2 – Configurações de força aplicadas na matriz de sensoriamento bidimensional para análise de repetibilidade. . . . .</b>                                                                               | <b>50</b> |
| <b>Tabela 3 – Erros de predição da posição (cm) da força aplicada na matriz de sensoriamento unidimensional com modelos baseados em Rede Elástica com <math>\alpha</math> variando entre 0,1 e 0,9. . . . .</b>   | <b>61</b> |
| <b>Tabela 4 – Erros de predição da magnitude (gf) da força aplicada na matriz de sensoriamento unidimensional com modelos baseados em Rede Elástica com <math>\alpha</math> variando entre 0,1 e 0,9. . . . .</b> | <b>61</b> |
| <b>Tabela 5 – Erros de predição na matriz de sensoriamento unidimensional com modelos baseados em SVR linear sem redução de dimensionalidade. . .</b>                                                             | <b>65</b> |
| <b>Tabela 6 – Erros de predição de posição (cm) da força aplicada na matriz de sensoriamento unidimensional com modelos baseados em SVR lineares usando de 1 a 5 componentes principais. . . . .</b>              | <b>66</b> |
| <b>Tabela 7 – Erros de predição da magnitude (gf) da força aplicada na matriz de sensoriamento unidimensional com modelos baseados em SVR lineares usando de 1 a 5 componentes principais. . . . .</b>            | <b>66</b> |
| <b>Tabela 8 – Erros de predição na matriz de sensoriamento unidimensional com modelos baseados em SVR quadrática sem redução de dimensionalidade. . . . .</b>                                                     | <b>68</b> |
| <b>Tabela 9 – Erros de predição da posição (cm) da força aplicada na matriz de sensoriamento unidimensional com modelos baseados em SVR quadráticos usando de 1 a 5 componentes principais. . . . .</b>           | <b>68</b> |
| <b>Tabela 10 – Erros de predição da magnitude (gf) da força aplicada na matriz de sensoriamento unidimensional com modelos baseados em SVR quadráticos usando de 1 a 5 componentes principais. . . . .</b>        | <b>68</b> |
| <b>Tabela 11 – Erros de predição de posições (cm) da força aplicada na matriz de sensoriamento bidimensional com modelos baseados em Rede Elástica com <math>\alpha</math> variando entre 0,1 e 0,9. . . . .</b>  | <b>70</b> |

|                                                                                                                                                                                                                  |           |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------|
| <b>Tabela 12 – Erros de predição da magnitude (gf) da força aplicada na matriz de sensoramento bidimensional com modelos baseados em Rede Elástica com <math>\alpha</math> variando entre 0.1 e 0.9. . . . .</b> | <b>71</b> |
| <b>Tabela 13 – Erros de predição na matriz de sensoramento bidimensional com modelos baseados em SVR linear sem redução de dimensionalidade. . . . .</b>                                                         | <b>74</b> |
| <b>Tabela 14 – Erros de predição das posições (cm) da força aplicada na matriz de sensoramento bidimensional com modelos baseados em SVR lineares usando de 1 a 11 componentes principais. . . . .</b>           | <b>75</b> |
| <b>Tabela 15 – Erros de predição da magnitude (gf) da força aplicada na matriz de sensoramento bidimensional com modelos baseados em SVR lineares usando de 1 a 11 componentes principais. . . . .</b>           | <b>75</b> |
| <b>Tabela 16 – Erros de predição na matriz de sensoramento bidimensional com modelos baseados em SVR quadrática sem redução de dimensionalidade. . . . .</b>                                                     | <b>77</b> |
| <b>Tabela 17 – Erros de predição das posições (cm) da força aplicada na matriz de sensoramento bidimensional com modelos baseados em SVR quadráticos usando de 1 a 11 componentes principais. . . . .</b>        | <b>77</b> |
| <b>Tabela 18 – Erros de predição da magnitude (gf) da força aplicada na matriz de sensoramento bidimensional com modelos baseados em SVR quadráticos usando de 1 a 11 componentes principais. . . . .</b>        | <b>78</b> |
| <b>Tabela 19 – Erros preditivos (cm) de modelos implementados para detecção da posição de aplicação da força sobre a matriz de sensoramento unidimensional. . . . .</b>                                          | <b>79</b> |
| <b>Tabela 20 – Erros preditivos (gf) de modelos implementados para detecção da magnitude da força sobre a matriz de sensoramento unidimensional. . . . .</b>                                                     | <b>80</b> |
| <b>Tabela 21 – Erros preditivos (cm) de modelos implementados para detecção da posição de aplicação da força, no eixo x, sobre a matriz de sensoramento bidimensional. . . . .</b>                               | <b>81</b> |
| <b>Tabela 22 – Erros preditivos (cm) de modelos implementados para detecção da posição de aplicação da força, no eixo y, sobre a matriz de sensoramento bidimensional. . . . .</b>                               | <b>82</b> |
| <b>Tabela 23 – Erros preditivos (gf) de modelos implementados para detecção da magnitude da força sobre a matriz de sensoramento bidimensional. . . . .</b>                                                      | <b>83</b> |

## LISTA DE SIGLAS

### Siglas

|       |                                                                                                                      |
|-------|----------------------------------------------------------------------------------------------------------------------|
| OFS   | Sensores em Fibra Ótica, do inglês <i>Optical Fiber Sensors</i>                                                      |
| SHM   | Monitoramento de Integridade Estrutural, do inglês <i>Structural Health Monitoring</i>                               |
| FBG   | Rede de Bragg em Fibra Ótica, do inglês <i>Fiber Bragg Grating</i>                                                   |
| MMF   | Fibra Ótica multimodo, do inglês <i>Multimode Fiber</i>                                                              |
| MCF   | Fibra Ótica multinúcleo, do inglês <i>Multicore Fiber</i>                                                            |
| POF   | Fibra Ótica plástica, do inglês <i>Plastic Optical Fiber</i>                                                         |
| LASSO | Operador de Seleção e Encolhimento Absoluto Mínimo, do inglês <i>Least absolute shrinkage and selection operator</i> |
| LED   | Diodo Emissor de Luz, do inglês <i>Light Emitting Diode</i>                                                          |
| WGM   | Modos de Galeria Sussurrantes, do inglês <i>Whispering Gallery Modes</i>                                             |
| PCA   | Análise de Componentes Principais, do inglês <i>Principal Component Analysis</i>                                     |
| OLS   | Mínimos Quadrados Ordinários, do inglês <i>Ordinary Least Squares</i>                                                |
| SVR   | Regressão por Vetores Suporte, do inglês <i>Support Vector Regression</i>                                            |
| SVM   | Máquina de Vetores Suporte, do inglês <i>Support Vector Machine</i>                                                  |
| MSE   | Erro Quadrático Médio, do inglês <i>Mean Squared Error</i>                                                           |
| MAE   | Erro Absoluto Médio, do inglês <i>Mean Absolute Error</i>                                                            |
| PMMA  | Polimetilmetacrilato                                                                                                 |

## LISTA DE SÍMBOLOS

### Notações

|                      |                                                                    |
|----------------------|--------------------------------------------------------------------|
| $n$                  | Índice de Refração                                                 |
| $V$                  | Frequência normalizada                                             |
| $a$                  | Raio do núcleo da fibra ótica                                      |
| $\lambda_0$          | Comprimento de onda no vácuo                                       |
| $P$                  | Potência ótica                                                     |
| $R$                  | Raio de curvatura                                                  |
| $L$                  | Comprimento do arco de curvatura da fibra                          |
| $2\phi$              | Coefficiente de perda pura por curvatura                           |
| $K_{+1}$             | Função de Henkel modificada                                        |
| $\kappa$             | Constante de fase radial                                           |
| $\gamma$             | Constante de atenuação radial                                      |
| $k$                  | Número de onda                                                     |
| $\beta$              | Constante de propagação                                            |
| $b$                  | Constante de propagação normalizada                                |
| $\Delta$             | Parâmetro de diferença entre índices de refração de núcleo e casca |
| $\mathbf{y}$         | Vetor de alvos das predições                                       |
| $\mathbf{x}$         | Vetor de variáveis características preditivas                      |
| $\boldsymbol{\beta}$ | Vetor dos coeficientes de regressão                                |
| $p$                  | Número de variáveis características preditivas                     |
| $m$                  | Número de observações                                              |
| $\lambda$            | Parâmetro de penalização das regressões                            |
| $\alpha$             | Parâmetro que define a contribuição das penalizações $L_1$ e $L_2$ |
| $\mathbf{w}$         | Vetor de pesos associados às variáveis características             |
| $b$                  | Parâmetro de bias                                                  |
| $\epsilon$           | Largura das margens ou planos suporte                              |
| $\xi$                | Parâmetros de folga em relação aos planos suporte                  |
| $C$                  | Constante de tolerância a amostras fora do $\epsilon$ -tube        |
| $\mathbf{T}$         | Matriz com Componentes Principais                                  |
| $\mathbf{A}$         | Matriz com pesos associados às Componentes Principais              |
| $\hat{y}$            | Valor real                                                         |

## SUMÁRIO

|            |                                                                            |           |
|------------|----------------------------------------------------------------------------|-----------|
| <b>1</b>   | <b>INTRODUÇÃO . . . . .</b>                                                | <b>16</b> |
| <b>1.1</b> | <b>Estrutura do trabalho . . . . .</b>                                     | <b>16</b> |
| <b>1.2</b> | <b>Motivações . . . . .</b>                                                | <b>16</b> |
| <b>1.3</b> | <b>Estado da arte . . . . .</b>                                            | <b>19</b> |
| 1.3.1      | Sensores baseados em curvatura de fibra ótica . . . . .                    | 19        |
| 1.3.2      | Sensores multiplexados em fibra ótica . . . . .                            | 22        |
| 1.3.3      | Modelos de regressão preditivos . . . . .                                  | 23        |
| <b>1.4</b> | <b>Objetivos . . . . .</b>                                                 | <b>25</b> |
| <b>2</b>   | <b>FUNDAMENTAÇÃO TEÓRICA . . . . .</b>                                     | <b>27</b> |
| <b>2.1</b> | <b>Transdutores baseados em Macrocurvatura . . . . .</b>                   | <b>27</b> |
| 2.1.1      | Propagação em fibras óticas . . . . .                                      | 27        |
| 2.1.2      | Sensores óticos modulados em intensidade . . . . .                         | 29        |
| 2.1.3      | Atenuação por curvatura . . . . .                                          | 30        |
| 2.1.4      | Modos de Galeria Sussurrantes . . . . .                                    | 32        |
| 2.1.5      | Macrocurvaturas multiplexadas em série e princípio de operação do sistema  | 32        |
| <b>2.2</b> | <b>Modelos de Regressão . . . . .</b>                                      | <b>33</b> |
| 2.2.1      | Modelo de Rede Elástica . . . . .                                          | 34        |
| 2.2.2      | Modelo de Regressão por Vetores Suporte . . . . .                          | 36        |
| 2.2.3      | Redução de dimensionalidade por Análise de Componentes Principais . . .    | 39        |
| 2.2.4      | Seleção de modelo por Validação Cruzada . . . . .                          | 40        |
| <b>3</b>   | <b>MATERIAL E MÉTODOS . . . . .</b>                                        | <b>43</b> |
| <b>3.1</b> | <b>Desenvolvimento dos sistemas sensores . . . . .</b>                     | <b>43</b> |
| 3.1.1      | Produção dos sistemas de macrocurvaturas multiplexadas . . . . .           | 43        |
| 3.1.2      | Matriz de sensoriamento unidimensional . . . . .                           | 44        |
| 3.1.3      | Matriz de sensoriamento bidimensional . . . . .                            | 45        |
| <b>3.2</b> | <b>Métodos de coleta de dados . . . . .</b>                                | <b>47</b> |
| 3.2.1      | Aquisição de dados espectrométricos . . . . .                              | 47        |
| 3.2.2      | Método de aplicação de forças . . . . .                                    | 48        |
| 3.2.3      | Método de caracterização da operação desacoplada dos elementos sensores .  | 49        |
| 3.2.4      | Método de avaliação da repetibilidade de operação dos sistemas acoplados . | 49        |

|            |                                                                                                         |           |
|------------|---------------------------------------------------------------------------------------------------------|-----------|
| <b>3.3</b> | <b>Caracterização da operação dos sistemas . . . . .</b>                                                | <b>50</b> |
| 3.3.1      | Método de caracterização da operação do sistema na matriz de sensoriamento unidimensional . . . . .     | 50        |
| 3.3.2      | Método de caracterização da operação do sistema na matriz de sensoriamento bidimensional . . . . .      | 51        |
| <b>3.4</b> | <b>Implementação dos modelos preditivos de regressão . . . . .</b>                                      | <b>51</b> |
| 3.4.1      | Implementação e parâmetros dos modelos de Rede Elástica . . . . .                                       | 52        |
| 3.4.2      | Implementação e parâmetros dos modelos de Regressão por Vetores Suporte                                 | 54        |
| <b>4</b>   | <b>RESULTADOS E DISCUSSÃO . . . . .</b>                                                                 | <b>57</b> |
| <b>4.1</b> | <b>Respostas dos elementos sensores desacoplados . . . . .</b>                                          | <b>57</b> |
| <b>4.2</b> | <b>Respostas de repetibilidade dos sistemas sensores . . . . .</b>                                      | <b>59</b> |
| <b>4.3</b> | <b>Matriz de sensoriamento unidimensional . . . . .</b>                                                 | <b>60</b> |
| 4.3.1      | Avaliação dos modelos de Rede Elástica para a matriz de sensoriamento unidimensional . . . . .          | 61        |
| 4.3.2      | Análise de Componentes Principais para a matriz de sensoriamento unidimensional . . . . .               | 64        |
| 4.3.3      | Avaliação dos modelos SVR lineares para a matriz de sensoriamento unidimensional . . . . .              | 65        |
| 4.3.4      | Avaliação dos modelos SVR polinomiais quadráticos para matriz de sensoriamento unidimensional . . . . . | 67        |
| <b>4.4</b> | <b>Matriz de sensoriamento bidimensional . . . . .</b>                                                  | <b>69</b> |
| 4.4.1      | Avaliação dos modelos de Rede Elástica para matriz de sensoriamento bidimensional . . . . .             | 70        |
| 4.4.2      | Análise de componentes principais para matriz de sensoriamento bidimensional                            | 73        |
| 4.4.3      | Avaliação dos modelos SVR lineares para matriz de sensoriamento bidimensional . . . . .                 | 74        |
| 4.4.4      | Avaliação dos modelos SVR polinomiais quadráticos para matriz de sensoriamento bidimensional . . . . .  | 76        |
| <b>4.5</b> | <b>Resultados da operação de sensoriamento . . . . .</b>                                                | <b>79</b> |
| <b>5</b>   | <b>CONCLUSÕES E PERSPECTIVAS . . . . .</b>                                                              | <b>85</b> |
| <b>5.1</b> | <b>Trabalhos futuros . . . . .</b>                                                                      | <b>87</b> |
| <b>5.2</b> | <b>Publicações associadas ao trabalho . . . . .</b>                                                     | <b>87</b> |

|            |                                     |           |
|------------|-------------------------------------|-----------|
| <b>5.3</b> | <b>Outras publicações . . . . .</b> | <b>87</b> |
|            | <b>REFERÊNCIAS . . . . .</b>        | <b>88</b> |

# 1 INTRODUÇÃO

## 1.1 Estrutura do trabalho

No presente capítulo constam as motivações para o desenvolvimento da pesquisa, também será apresentado o estado da arte, abordando sistemas óticos de sensoriamento, e os objetivos gerais e específicos que orientam a pesquisa.

Na sequência será apresentada a fundamentação teórica que aborda geometria e operação de fibras óticas, modelos preditivos de regressão e técnicas computacionais relacionadas a aprendizagem computacional.

O terceiro capítulo discute características metodológicas da pesquisa, com detalhes de materiais utilizados e procedimentos operacionais que resultaram nos conjuntos de dados voltados a implementação de modelos preditivos. Também será apresentada a métrica estabelecida para implementação desses modelos em conjunto aos parâmetros específicos associados a cada modelo avaliado.

O quarto capítulo se refere aos resultados da pesquisa, serão apresentados tanto respostas individuais sem tratamento de dados, quanto resultados de monitoração após implementação dos modelos de regressão. Primeiramente serão apresentados resultados da estrutura unidimensional com três elementos sensores, em sequência serão apresentados resultados referentes à estrutura bidimensional com cinco elementos sensores. O capítulo encerra com a comparação dos desempenhos obtidos por modelos preditivos distintos.

Por fim, serão comentadas as conclusões tomadas com base nos resultados, e descritos trabalhos que darão continuidade a pesquisa.

## 1.2 Motivações

Sensores são fundamentais em grande parte dos dispositivos e máquinas que são propostas na atualidade, é evidente que a alta demanda por aprimoramento tecnológico implica na necessidade de desenvolvimento de sistemas de sensoriamento capazes de realizar operações cada vez mais complexas e específicas. A maior parte dos sensores disponíveis comercialmente são baseados em sinais elétricos, mas o aprimoramento de técnicas de instrumentação ótica tem atuado contribuindo para um novo cenário, onde dispositivos óticos ganham relevância devido a características inerentes às fibras óticas.

Três importantes áreas de aplicação para sensores óticos são sistemas biomédicos, sistemas robóticos e sistemas de monitoração de integridade estrutural, *Structural Health Monitoring* – SHM.

No campo biomédico, sensores óticos são utilizados desde para objetivos mais gerais como para monitoração de temperatura de pacientes (RORIZ *et al.*, 2020), como para finalidades

mais específicas como monitoração de próteses (MASTELLER *et al.*, 2020), e auxílio de detecção viral (HUANG *et al.*, 2009). De maneira direcionada a sistemas de monitoração de forças destaca-se a implementação de dispositivos vestíveis voltados a medicina de precisão e ao monitoramento do estado de saúde. Tecnologias vestíveis são desejáveis pois possibilitam a monitoração de dados com alta informação de parâmetros clinicamente relevantes, além de aprimorar a experiência médica do paciente. Dadas essas características, têm sido desenvolvidos sensores de força não invasivos voltados a monitoração de taxa respiratória, atividade física, compressão abdominal e estrutura plantar (KIM *et al.*, 2018; DOMINGUES *et al.*, 2017).

Semelhantemente, em instrumentos cirúrgicos o uso de sensores de força apresenta grande importância pois participa do controle de forças aplicadas, prevenindo danos a estruturas anatômicas durante etapas de cortes (GIRERD *et al.*, 2021). Em vista dos benefícios de cirurgias minimamente invasivas há grande desenvolvimento de técnicas que permitem a realização dessas operações assistidas por robôs. Um dos fatores limitantes para essas técnicas é a inabilidade dos instrumentos em monitorar as forças empregadas durante a realização das cirurgias (OKAMURA, 2009). Sensores óticos baseados em interferometria e Redes de Bragg já são estudados relacionados a realização de cirurgias minimamente invasivas (BANDARI; DARGAHI; PACKIRISAMY, 2020).

Estima-se que em aproximadamente 15 anos, sensores em fibra ótica (OFS) irão atender entre 80% e 90% das necessidades da robótica (ALEKSANDROVICH; VLADIMIROVICH *et al.*, 2020). Soluções relacionadas a monitoração de forças são frequentes nesse campo devido ao interesse na incorporação de funções táteis que permitem a detecção de contato e manipulação de objetos (GIRERD *et al.*, 2021).

Quanto a sistemas de *SHM*, onde a monitoração de forças é relevante, dispositivos de sensoriamento ótico são amplamente estudados para avaliação de obras de engenharia civil e aeronaves, aumentando a confiabilidade e eficiência de inspeções, bem como manutenções e monitorações operacionais (GARCÍA *et al.*, 2015). Essas aplicações evidenciam a relevância desses sistemas e demonstram um potencial de desenvolvimento tecnológico significativo.

Para garantir a eficiência e segurança de estruturas, o processo de monitoração estrutural envolve a seleção do tipo de sensor, os locais onde os sensores devem ser acoplados e o número de sensores utilizados (SOHN *et al.*, 2003). Usualmente em grandes estruturas monitoradas são utilizados sistemas com um relativo alto número de elementos sensores. Nesse sentido, um ponto a ser avaliado é a possibilidade de multiplexação em vista que com essa técnica cada elemento sensor é responsável pelo sensoriamento de mais de uma região sensível. Tal técnica viabiliza o sensoriamento *quasi*-distribuído com um número de sensores menor do que o número de pontos de monitoração, promovendo redução de custos dos sistemas (FERNANDEZ-VALLEJO; LOPEZ-AMO, 2012; DANDRIDGE; KIRKENDALL, 2002).

Em estruturas e dispositivos monitorados, a grande escolha por sensores óticos é justificada em vista das características operacionais que os tornam adequados para aplicações em áreas como instrumentação aeroespacial, indústria de processamento de óleo e gás e projetos de

energia nuclear (ALEKSANDROVICH; VLADIMIROVICH *et al.*, 2020). Tais características que fundamentam essa recorrente escolha estão relacionadas a grande imunidade a interferências eletromagnéticas, alta resistência a corrosão, relativo baixo custo de manutenção, grande flexibilidade e pequeno tamanho, permitindo o desenvolvimento de sistemas de sensoriamento capazes de operar em locais que seriam inadequados para sistemas elétricos (CHERIN, 1983; WANG; LIU, 2018b).

Entre diversas técnicas e além das amplamente aplicadas redes de Bragg acopladas a fibra (FBGs), um tipo de sensor ótico estudado são os transdutores em macrocurvatura que além de vantagens relacionadas a fibra ótica apresentam relativa facilidade de produção e de multiplexação quando comparados as consolidadas FBGs. O crescente número de propostas utilizando sensores em curvatura têm contribuído para aprimoramentos dos métodos de construção e de demodulação associados a esses. Sob essa perspectiva, entende-se que a demonstração de métodos e a apresentação de dados associados a precisão, acurácia e confiabilidade detectáveis por sistemas sensores baseados em curvatura contribui cientificamente para o desenvolvimento dessa tecnologia.

Nesse trabalho serão apresentados sistemas baseados em macrocurvaturas multiplexadas de fibra ótica voltados a monitoração de força aplicada em estruturas rígidas. Nesses dispositivos, o número de regiões monitoradas é maior do que o número de elementos sensores acoplados ao sistema de sensoriamento.

### 1.3 Estado da arte

#### 1.3.1 Sensores baseados em curvatura de fibra ótica

Em 1970 foram desenvolvidas as primeiras fibras óticas adequadas para sistemas de comunicação e após 8 anos W.A Gambling, S.N Payne e H. Matsumura estudaram a radiação emitida por fibras curvadas (GAMBLING *et al.*, 1978). O primeiro registro de sensoriamento ótico baseado na alteração do sinal ótico induzida por curvatura ocorre em 1980 em um trabalho de J.N Fields e J.H Cole ao elaborarem um sistema baseado em microcurvatura voltado a monitoramento acústico (FIELDS; COLE, 1980). Microcurvaturas são caracterizadas pelo raio de curvatura tipicamente inferior a 1 mm (JAY, 2010) e podem ser facilmente danificadas, requerendo componentes complexos para adequada operação (LEE *et al.*, 2005).

O aprimoramento das técnicas de instrumentação ótica durante as décadas seguintes conduziu a uma grande variedade de propostas para sensores em curvatura, e nesse sentido verificam-se na literatura a utilização de sistemas com configurações diversas, utilizando associações de fibras especiais, fibras multi-modo (MMF) (WANG; LIU, 2018a), fibras com múltiplos núcleos (MCF) (BUDNICKI *et al.*, 2020) e fibras óticas plásticas (POF) (MORALEDA *et al.*, 2013) além de redes de Bragg acopladas em conjunto às macrocurvaturas (WANG; LIU, 2018b; RAJAN *et al.*, 2010).

Em geral, pesquisas elaboradas a respeito de macrocurvaturas possuem objetivos relacionados a caracterizar a operação de monitoramento de sistemas específicos e/ou debater análises conceituais, matemáticas e experimentais para modelar os fenômenos físicos envolvidos na propagação da luz na região de curvatura (TSAO; CHENG, 2002; WANG; FARRELL; FREIR, 2005; BICKHAM *et al.*, 2009).

Trabalhos a respeito dos efeitos induzidos por macrocurvaturas nos guias de onda demonstram comparações entre os modelos teóricos propostos e os resultados experimentais de intensidade transmitida nas fibras (WANG; FARRELL; FREIR, 2005; BICKHAM *et al.*, 2009). Em 1978, Murakami estudou efeitos de curvatura em fibras e identificou picos de perda ótica em comprimentos de onda específicos justificados pela interferência entre os modos de radiação que refletiam no revestimento e voltavam ao núcleo, segundo os autores as previsões teóricas matemáticas estavam de acordo com os dados experimentais (MURAKAMI; TSUCHIYA, 1978). Wang (2005) estudou teoricamente e experimentalmente as atenuações por macrocurvatura em fibras padrão utilizando o modelo SMF-28, mais comum em sistemas de comunicação por fibra ótica, apontando que o revestimento primário dessa fibra absorve significativa parte das perdas por curvatura (WANG; FARRELL; FREIR, 2005). Também nesse sentido, Tsau propôs em um estudo de 2002, uma expressão com três fatores de correção que considerava parâmetros como o raio de curvatura, número de voltas e o comprimento de onda da luz guiada para estimar a atenuação induzida por curvaturas (TSAO; CHENG, 2002).

De modo direcionado aos sistemas de sensoriamento, entre diversas propostas para refratômetros, em 2009, Wang e outros pesquisadores apresentaram um refratômetro baseado em macrocurvatura, o método apontou que o índice de refração do meio líquido externo ao transdutor foi determinado com base na atenuação da luz transmitida. O dispositivo proposto foi baseado em um único laço de fibra ótica padrão (SMF-28) com diâmetro de revestimento reduzido. O diâmetro de curvatura, parâmetro de difícil controle experimental, utilizado nos transdutores foi próximo a 7,7 mm, essa escolha foi justificada devido a relação quase linear existente entre índice de refração e perda ótica por curvatura para laços com diâmetros na vizinhança de 7,7 mm. Os autores compararam resultados de modelos teóricos utilizados para cálculo de perda por curvatura e os dados experimentais obtidos, demonstrando acordo entre os resultados e com isso concluindo a viabilidade do método proposto. Para índices de refração entre 1,4586 e 1,5396, utilizando luz no comprimento de onda de 1550 nm, e com o diâmetro de revestimento reduzido para  $81\mu\text{m}$ , a resolução de índice de refração detectada foi de  $5,75 \cdot 10^{-5}$  (WANG *et al.*, 2009).

Em 2011, Wang e outros pesquisadores demonstraram a capacidade de um sistema baseado em macrocurvatura no monitoramento de diferença de potencial. O sistema operava com base no deslocamento provocado por um atuador piezoelétrico na presença de determinada diferença de potencial responsável por alterar mecanicamente o diâmetro de curvatura de um transdutor ótico em macrocurvatura. Os resultados apresentados referem-se a um alcance de voltagens entre 0 e 100 V com resolução de monitoração próxima a 0,5 V. Entre as características do sistema proposto estão o baixo preço, a facilidade de produção e a possibilidade de modificação da faixa operacional (WANG *et al.*, 2009).

Em 2013, Moraleda demonstrou que a perda induzida por curvatura depende da abertura numérica do guia que por sua vez é variável de acordo com a temperatura por efeito termo-ótico, com isso propôs um sensor de temperatura baseado em macrocurvatura de fibra ótica plástica. Os experimentos conduzidos caracterizaram a operação sob diferentes condições. Para um raio de curvatura de 2,0 mm foi verificada uma resolução de  $0,3\text{ }^{\circ}\text{C}$  na faixa térmica entre  $27,2\text{ }^{\circ}\text{C}$  e  $50,2\text{ }^{\circ}\text{C}$ , além disso foi defendida a possibilidade de melhor resolução de acordo com a modificação de componentes do sistema ótico de detecção (MORALEDA *et al.*, 2013).

Outra proposta de monitoração de temperatura com base em macrocurvatura de fibra ótica polimérica foi realizada em 2019 por Leal-Junior e outros pesquisadores. O sistema desenvolvido e caracterizado opera com base na modificação das propriedades mecânicas da POF quando submetida a variações de temperatura. Sob uma tensão mecânica constante, associada a curvatura, quando modificada as propriedades mecânicas da fibra, devido a variação de temperatura, verifica-se modificação da potência ótica transmitida. Um modelo analítico para o sistema foi simulado, validando os resultados experimentais obtidos. Segundo os autores, os resultados obtidos demonstram maior sensibilidade e linearidade de respostas quando comparados a resultados presentes na literatura, além da possibilidade de medir temperaturas até  $110\text{ }^{\circ}\text{C}$ . A sensibilidade obtida pelo sistema proposto foi de  $1,04 \cdot 10^{-1}\text{ }^{\circ}\text{C}^{-1}$ , e a raiz quadrado do erro médio apresentada foi de  $1,48\text{ }^{\circ}\text{C}$  (LEAL-JUNIOR *et al.*, 2018).

Uma proposta voltada a monitoração de pavimentação, com base em macrocurvatura de fibra ótica, foi estudada em 2019 por Meng e outros pesquisadores. O objetivo do trabalho foi avaliar a capacidade de monitorar grandes deformações relativas com base na perda de intensidade ótica por macrocurvatura detectada em uma fibra fixada em padrão de espiral ao redor de um cilindro de borracha. A alteração do sinal transmitido ocorre quando a borracha é deformada, implicando em alteração do raio de curvatura da fibra ótica em espiral. A detecção foi realizada no comprimento de onda de 850 nm. O trabalho apresenta resultados que evidenciam uma relação monotônica entre a deformação relativa do sistema a perda de potência ótica transmitida (MENG; WANG; HOU, 2019), portanto, indicam viabilidade da técnica proposta.

Em 2015, Sareh e outros pesquisadores implementaram um sistema de macrocurvaturas para o monitoramento de curvatura, alongação e compressão de um braço robótico. O dispositivo foi validado por comparação a um sistema de rastreamento eletromagnético e os testes conduzidos indicaram erros máximos de 18% na monitoração da alongação e compressão do braço e 13% de erros máximos na monitoração da curvatura do braço. As conclusões tomadas no trabalho dizem respeito ao impacto da escolha dos raios de curvatura e número de curvaturas do sistema e dão destaque a aplicabilidade da tecnologia devido a características inerentes às fibras óticas (SAREH *et al.*, 2015).

Kamizi e outros pesquisadores, em 2019, desenvolveram um sistema baseado em macrocurvatura de fibra ótica interrogado por câmera de *smartphone* voltado a monitoração de marchas. Esse objetivo está relacionado a testes clínicos com finalidades de prevenção de lesões e aprimoramento de desempenho esportivo. O elemento sensor utilizado baseia-se em um anel de fibra ótica encapsulado em material elastômero, o sinal transmitido na fibra é atenuado na região de macrocurvatura. Quando o sistema é submetido a deformação devido a força associada a marcha há modificação do sinal, que é recuperado quando o sensor retorna a um estado inicial sem compressão. O sistema sensível foi instalado em palmilhas e um CCD, presente em um *smarthphone*, foi utilizado para captação de imagens formadas por três pontos luminosos associados a luz transmitida, sendo dois referentes aos sensores de cada palmilha e o terceiro um sinal de referência. As imagens capturadas foram tratadas por algoritmo desenvolvido em Matlab. Nos ensaios foram simulados regimes de marchas com diferentes parâmetros como velocidade, cadencia, tempo de suporte unilateral e bilateral, por exemplo. Com base nos dados tratados foi avaliada a máxima reação de força do piso e máxima pressão exercida no sistema. Destaca-se a portabilidade e robustez do sistema que pode ser facilmente instalado para monitoração no campo biomédico sem restrição da mobilidade do usuário. Outro ponto está relacionado a versatilidade do sistema que pode ser implementado para monitoração de múltiplos parâmetros simultaneamente (KAMIZI *et al.*, 2019b).

### 1.3.2 Sensores multiplexados em fibra ótica

Segundo Dakin (1987), sensores multiplexados são sistemas que coletam dados em um número discreto de regiões sensíveis distribuídas ao longo de uma fibra, e que possuem a capacidade de determinar as variações dos parâmetros monitorados ao longo do espaço (DAKIN, 1987). Uma das primeiras propostas de multiplexação de sensores, foi feita por Nelson e outros pesquisadores em 1980, nesse trabalho foi testado experimentalmente um sistema com fonte ótica de laser GaAs pulsado em fibra com sensores refletivos interrogados em intensidade (NELSON; MCMAHON; GRAVEL, 1980).

Sensores em fibra ótica, inicialmente, foram propostos como sensores pontuais, ou seja, o monitoramento dos transdutores era referente à uma única localização da fibra (LU *et al.*, 2019). Nesse cenário, sem a multiplexação, o monitoramento *quasi*-distribuído requer sistemas de interrogação com fonte e detector individuais para as múltiplas fibras acopladas. Em relação a sistemas multiplexados isso potencialmente implica em maior custo de produção, maior dificuldade de instalação e manutenção e uma etapa de tratamento de sinais mais custosa computacionalmente.

O sensoriamento *quasi*-distribuído ocorre quando há a monitoração em pontos específicos localizados dos sistemas em fibra e a possibilidade de monitorar a variação de determinado parâmetro físicos ocorre com base nos dados individuais de cada localização sensível, por outro lado diferencia-se de sensores distribuídos, onde a medida ocorre continuamente ao longo da fibra (KERSEY; DANDRIDGE, 1988).

Entre as técnicas mais consolidadas para sensoriamento distribuído existem a refletometria ótica no domínio do tempo (OTDR) e refletometria ótica no domínio da frequência (OFDR), além de sensores baseados em efeito Brillouin. Em todos esses casos há necessidade de sistemas de interrogação de relativo alto custo devido a complexidade dos *hardwares*. Sistemas de sensoriamento *quasi*-distribuídos baseados em FBGs possibilitam boa resolução de acordo com a separação entre as redes, entretanto a interrogação também é relativamente complexa, outro ponto de dificuldade está na necessidade de sistema voltado a gravação das redes na fibra (LEAL-JUNIOR *et al.*, 2019).

Em 2012, Vallejo e Lopez, abordaram os aprimoramentos realizados e os desafios no desenvolvimento de sistemas de monitoramento remoto, nesse trabalho a capacidade de multiplexação foi considerada na avaliação dos sistemas discutidos em vista das vantagens que a técnica promove em relação a redução de custos e a simplificação da rede operacional (FERNANDEZ-VALLEJO; LOPEZ-AMO, 2012).

Em 2019, Kamizi e outros pesquisadores, demonstraram a capacidade de multiplexação detectada por uma série de elementos sensores baseados em macrocurvatura. Nesse trabalho foram distribuídas cargas, formando configurações de cargas únicas e múltiplas aplicadas diretamente sobre seis elementos sensores multiplexados em série. Considerando que as cargas foram aplicadas diretamente sobre os elementos sensores que formavam o sistema, ressalta-se

que os resultados dessa pesquisa se referem a operação não acoplada. Com base na modulação em intensidade relativa detectada na faixa espectral entre 400 nm e 800 nm, e com a aplicação de um modelo de regressão linear foi possível verificar a capacidade do sistema em reconhecer configurações de cargas desconhecidas. Outro resultado relevante do trabalho refere-se à possibilidade de redução de dados espectrais sem alteração significativa de desempenho de monitoração (KAMIZI *et al.*, 2019a).

Lugarini (2020) avaliou modelos de regressão linear implementados na operação de um sistema tátil de sensoriamento com quatro transdutores baseados em macrocurvatura de fibra ótica. O sistema formava uma estrutura flexível com cinco regiões de monitoração em que cargas eram posicionadas simultaneamente. Os modelos de regressão comparados foram o de Mínimos Quadrados, LASSO e Ridge. Cada região da estrutura foi monitorada a partir de um modelo individual e os resultados apresentados foram as médias dos erros absolutos de cada modelo. Os resultados indicam que os modelos com penalização (LASSO e Ridge) apresentaram desempenho semelhante em termos de erros de predição de carga com uma ligeira diferença a favor do modelo Ridge que é justificada em razão da significativa redução de variáveis características que o modelo LASSO proporciona. Nesse trabalho foram utilizadas cargas entre 0,0 kg e 2,0 kg, e os menores erros obtidos foram de aproximadamente 0,210 kg. O trabalho foi conclusivo quanto a capacidade do método em identificar a região e a magnitude das cargas, além disso algumas considerações foram feitas demonstrando que as faixas espectrais utilizadas para análise bem como a ordenação com que as cargas eram posicionadas no ensaio experimental influenciavam no desempenho verificado pelo sistema. Nesse sentido, foi constatado que a faixa espectral mais larga avaliada, entre 400 nm e 850 nm, apresentou o melhor desempenho dentre as utilizadas, e que a ordenação aleatória de cargas durante os ensaios foi prejudicial para as predições dos modelos (LUGARINI *et al.*, 2020).

### 1.3.3 Modelos de regressão preditivos

Modelos paramétricos, sejam regressões, para predições contínuas, ou classificações, para predições discretas, são recorrentes em projetos de análise de dados, e de modo mais específico em problemas de aprendizagem de máquinas (RASMUSSEN, 2003). No início do século XIX, Karl Gauss utilizou análise de regressão para predição de fenômenos astronômicos. Após mais de um século de aprimoramento de modelos matemáticos estatísticos, aproximadamente em 1944, Milton Friedman desenvolveu um modelo de regressão com o objetivo de prever o tempo de falha de lâminas de turbinas em função do estresse mecânico, da variação de temperatura e de outras variáveis metalúrgicas relacionadas a composição das lâminas. Um computador precisou de 40 horas para calcular a regressão e realizar os testes estatísticos (ARMSTRONG, 2011).

Com desenvolvimento de recursos computacionais de maior potencial foram propostos modelos cada vez mais complexos e flexíveis, resultando em técnicas de modelagem descritiva com melhores resultados quanto a interpretabilidade e aplicabilidade (SAUERBREI *et al.*, 2020).

Isso é evidenciado na literatura, onde constam diversos campos de aplicação para algoritmos de aprendizagem. São exemplos, bioquímica (WILKES *et al.*, 2020), medicina (ZHANG; HAN, 2020), meteorologia (MUÑOZ-ESPARZA; SHARMAN; DEIERLING, 2020), robótica (SHIH *et al.*, 2020) e sensoriamento remoto (MOUNTRAKIS; IM; OGOLE, 2011; LIAKOS *et al.*, 2018).

A presente seção apresenta o desenvolvimento e aplicações recentes de dois modelos de regressão, tais algoritmos são denominados Rede Elástica e Regressão por Vetores Suporte.

Em 2003, Zou e Hestie propõem a técnica de regularização denominada Rede Elástica capaz de realizar seleção e encolhimento de variáveis. Tal elaboração está associada aos modelos Ridge e LASSO, pois opera minimizando a soma residual dos quadrados submetida as penalizações que caracterizam esses dois modelos. A regressão Ridge, de penalização  $L_2$ , executa uma troca viés-variância e encolhe coeficientes. O modelo de Regressão LASSO foi proposto por Tibshirani (1996) com a utilização de uma penalidade  $L_1$  para definição dos coeficientes de regressão, tal penalização além de encolher é capaz de zerar alguns coeficientes, portanto, promove a seleção de variáveis preditivas. Como combinação de estimadores da LASSO e Ridge, o método baseado em Rede Elástica apresenta as vantagens relacionadas as duas técnicas (ZOU; HASTIE, 2003).

Em 2017, Liu e Li desenvolveram um método voltado a seleção de variáveis relevantes aplicado para dados espectrais. Tal método proposto foi baseado em Regressão por Rede Elástica. Os autores justificam que dados espectrais usualmente sofrem de excesso de ruído e colinearidade, portanto, técnicas voltadas a seleção de variáveis são determinantes ao operar com espectros. O método denominado Enet-BETA promove a seleção de variáveis aumentando a interpretabilidade dos dados, também nesse sentido, foi concluído que houve melhora da estabilidade e confiabilidade dos modelos treinados a partir das variáveis selecionadas. As considerações a respeito de dados espectrais são no sentido da recorrência de variáveis sem informação relevante e outras redundantes, contribuindo para que modelos treinados a partir desses dados se encontrem em quadros de sobreajuste, com baixa acurácias preditivas e relativo alto custo computacional (LIU; LI, 2017).

Também nesse sentido, os modelos de regressão LASSO e Rede Elástica são utilizados para identificação e determinação de componentes em determinados compostos com base em dados decorrentes de espectroscopia Raman. Seguindo essa linha, Zeng e outros pesquisadores concluíram que o modelo LASSO, falhou na identificação de compostos com grande correlação. Dando continuidade, propuseram um modelo baseado em Rede Elástica que resultou na identificação de compostos com grande acurácia e baixos erros na estimativa de concentrações. Nesse estudo foi concluído que o modelo baseado em Rede Elástica foi relativamente mais estável para análise de compostos em relação ao modelo LASSO, portanto, segundo os autores o método se mostrou promissor para implementação relacionada a dados de espectros Raman (ZENG *et al.*, 2020).

Em 2021, Choi e outros pesquisadores desenvolveram um sistema para realização simples e rápida do teste “*Timed Up and Go*” voltado a determinar o risco de queda através do exame de mobilidade funcional de idosos. O modelo de predição treinado foi realizado com base em dados coletados por dados tridimensionais de aceleração obtidos por dispositivos vestíveis durante caminhada. Para construção do modelo preditivo foram avaliados métodos baseados em Rede Elástica e regressão Ridge para seleção de variáveis características (CHOI *et al.*, 2021).

O desenvolvimento de um modelo de regressão baseado em Vetores Suporte ocorre com base no algoritmo de SVM usual para classificações, originalmente proposto por Cortes e Vapnik em 1995, que tem base no princípio de Minimização de Risco Estrutural (SRM) (ZHANG *et al.*, 2012). A utilização de técnicas voltadas a reconhecimentos de padrões tem sido significativa para análise de dados obtidos por sistemas óticos, por exemplo na espectroscopia onde algoritmos baseados SVM são utilizados para classificação de diferentes tipos de metais (LIANG *et al.*, 2014).

Em 2012, Zhang e outros pesquisadores desenvolveram um sistema ótico voltado ao monitoramento da posição de um dano estrutural causado por uma carga localizada utilizando FBGs. O algoritmo desenvolvido para operação foi baseado em Regressão por Vetores Suporte. A proposta buscou obter confiabilidade de sensoriamento mesmo em cenários onde alguns elementos sensores do sistema são inválidos, com isso a proposta se mostrou aplicável em sistemas que operam em um grande intervalo de tempo e parte dos sensores podem se tornar inoperantes (ZHANG *et al.*, 2012).

Na área de sensoriamento remoto, modelos baseados em SVR, embora menos conhecidos em relação a Árvores de Decisão e Redes Neurais, são capazes de realizar predições de mesmo, ou melhor, desempenho. Tal consideração justifica o aumento da utilização de trabalhos que utilizam dados multiespectrais para treinamento de modelos preditivos de Regressão por Vetores Suporte (MOUNTRAKIS; IM; OGOLE, 2011).

## 1.4 Objetivos

O trabalho tem como objetivo o desenvolvimento de um sistema ótico sensor baseado em macrocurvaturas em fibra ótica capaz de realizar a detecção da magnitude e posição de força aplicada sobre uma plataforma rígida. Os objetivos específicos que direcionam a pesquisa são listados a seguir.

- Produzir conjuntos de sensores de macrocurvatura encapsulados e conectados em série.
- Construir plataformas rígidas de sensoriamento de forças instrumentadas com os conjuntos de sensores produzidos.
- Caracterizar e testar as plataformas de sensoriamento de forças quanto a capacidade de detecção de forças aplicadas sobre sua superfície.

- Utilizar modelos de regressão para a análise dos dados fornecidos pelos sistemas.
- Comparar o desempenho de predição dos modelos.

## 2 FUNDAMENTAÇÃO TEÓRICA

### 2.1 Transdutores baseados em Macrocurvatura

#### 2.1.1 Propagação em fibras óticas

Fibras óticas são estruturas dielétricas que atuam como guia de ondas eletromagnéticas, possibilitando a transmissão de um determinado sinal ótico. A estrutura de uma fibra ótica padrão é caracterizada pela geometria cilíndrica que agrupa um núcleo, com índice de refração  $n_1$ , a uma região de casca, com índice de refração  $n_2$ , dada a condição  $n_1 > n_2$ . Em termos de raios óticos propagados, esses guias de onda promovem que feixes satisfaçam as condições de reflexão interna total sequencialmente implicando na transmissão do sinal ótico que é acoplado ao guia.


Uma classificação das fibras óticas diz respeito ao perfil do índice de refração verificado em relação a estrutura, caso o núcleo, usualmente de sílica dopada, apresente um índice de refração uniforme, então a fibra é classificada por perfil de índice degrau, por outro lado quando o índice de refração decai do centro do núcleo para as camadas mais externas, a fibra é classificada como de perfil de índice gradual (CHERIN, 1983).

Em termos de propagação de ondas eletromagnéticas, tem-se que configurações de campo propagante permitidas, definidas como modos, são determinadas com base nas soluções das equações de Maxwell aplicadas as condições de contorno que especificam a geometria e perfil de índice de refração do guia de onda. Com isso em vista, no caso das fibras óticas há classificação de fibra entre monomodo e multimodo. Essa especificação diz respeito ao número de modos permitidos no núcleo, dado o comprimento de onda de operação. Fibras monomodais, são caracterizadas por um diâmetro de núcleo relativamente pequeno e quando operando no infravermelho suportam apenas um modo de núcleo, o fundamental com energia máxima coincidindo com o centro da fibra. Quando operando em outras regiões espectrais há alteração no número total de modos permitidos. Por exemplo, operando na faixa espectral visível, usualmente fibras óticas operam em regime multimodal. Isso ocorre pois em uma fibra ótica o número de modos apresenta dependência em relação ao raio do núcleo, índices de refração da casca e núcleo, e comprimento de onda da luz guiada. Essa relação é evidenciada ao avaliar a frequência normalizada, ou número  $V$  de uma fibra. Em uma fibra de perfil de índice de refração degrau o número de modos propagantes é proporcional ao número  $V$ , dado pela Equação 1, onde  $a$  é o raio do núcleo da fibra, e  $\lambda_0$  é o comprimento de onda da luz no vácuo (CHERIN, 1983; DANDLIKER, 1999). Ao ajustar os parâmetros construtivos do guia de onda determina-se o regime modal de operação de acordo com o comprimento de onda da luz guiada, assim permitindo o desenvolvimento de fibras especiais que operam com apenas um modo até mesmo na região espectral visível.

$$V = \frac{2\pi a}{\lambda_0} \sqrt{n_1^2 - n_2^2} \quad (1)$$

Em fibras óticas comerciais é usual uma camada externa de revestimento, comumente de acrilato, voltada ao aumento da resistência mecânica da estrutura do guia. A Figura 1 apresenta a estrutura de uma fibra ótica padrão, a região de núcleo possui diâmetro variável de até  $62.5\ \mu\text{m}$  em fibras multimodo e de unidades de  $\mu\text{m}$  em fibras monomodo, a região de casca tem diâmetro de  $125\ \mu\text{m}$  e o revestimento entre  $242\ \mu\text{m}$  e  $245\ \mu\text{m}$  (JAY, 2010).

**Figura 1 – Corte de seção transversal de uma fibra ótica padrão.**




**Fonte: Adaptado de Jay (2010).**

Em relação a sistemas baseados em transmissão de sinais elétricos, as fibras óticas apresentam grande imunidade a interferências eletromagnéticas e vantagens relacionadas a estrutura física da fibra como alta resistência a corrosão, relativo baixo custo de manutenção, grande flexibilidade e pequeno tamanho, permitindo o desenvolvimento de sistemas tanto de comunicação quanto de sensoriamento capazes de operar em locais que seriam inadequados para sistemas elétricos (CHERIN, 1983; WANG; LIU, 2018b).

A operação de comunicação por fibra ótica requer componentes de emissão e detecção de sinal, respectivamente fonte e detector ótico. A fonte de luz utilizada varia de acordo com a aplicação, usualmente são dispositivos lasers, LEDs ou fontes incandescentes (HISHAM, 2018; FABIÁN *et al.*, 2019). Em uma das extremidades do guia, um detector ótico é responsável pela aquisição dos dados espectrais transmitidos ou refletidos. Em aplicações em que fibra ótica é usada para sensoriamento, ocorre a modulação do sinal ótico durante a etapa de propagação no guia, portanto um estímulo físico promove a alteração do sinal que se propaga e através dessa modulação detectada é possível aferir informações de interesse a respeito do estímulo físico monitorado (BARRIAS; CASAS; VILLALBA, 2016). A Figura 2 apresenta uma estrutura padrão para sensores óticos baseados em sinal transmitido.

**Figura 2 – Configuração de componentes padrão em um sistema sensor em fibra ótica baseado em sinal transmitido.**



### 2.1.2 Sensores óticos modulados em intensidade

Uma das classificações para sensores em fibra ótica diz respeito a natureza da modulação que o transdutor induz no sinal ótico, essas modulações podem ser em intensidade, comprimento de onda, polarização ou fase (HISHAM, 2018). No caso de transdutores baseados em macrocurvatura, percebe-se que a modulação em intensidade é adequada em vista dos fenômenos físicos que alteram o sinal guiado na fibra (ALEMDAR *et al.*, 2013). Nesses dispositivos, a perda de intensidade, ou atenuação, possui dependência com o raio da macrocurvatura, portanto, é evidente que um dos fatores determinantes nas características da modulação induzida é a geometria da estrutura de curvatura. Ao submeter os elementos sensores baseados em macrocurvatura a estímulos físicos capazes de promover alterações de perfil de curvatura cria-se novas condições de guiamento, induzindo alteração de intensidade transmitida.

A seguir serão abordados os fenômenos físicos denominados Perda por Curvatura e Ressonâncias de Modos de Galeria Sussurrantes - *Whispering Gallery Modes* (WGM), determinantes nas modulações do sinal ótico induzidas por macrocurvaturas em fibras monomodo padrão revestidas.


### 2.1.3 Atenuação por curvatura

Em uma fibra monomodo, curvaturas induzem perdas de energia da onda guiada por dois mecanismos distintos. O primeiro fenômeno define-se como Perda Pura por Curvatura ou Radiação Tangencial: um modo guiado ao se propagar no segmento reto do núcleo de uma fibra ótica com potência inicial  $P_i$ , possui velocidade de grupo inferior a velocidade limite de propagação da luz no núcleo. Em um segmento de fibra ótica curvada a luz propaga-se em um padrão de confinamento circular, e consequentemente a velocidade de grupo é linearmente dependente da distância radial em relação centro de curvatura. Define-se raio crítico ( $R_c$ ) a posição radial em que a componente tangencial da velocidade de propagação do grupo é igual a velocidade limite de propagação no meio. Em curvaturas com raios maiores do que  $R_c$ , a componente tangencial da velocidade de propagação excede a velocidade de propagação limite do meio e com isso parte da luz é irradiada para região de casca (RAJAN, 2008).

O segundo mecanismo responsável pela perda de energia em curvaturas de fibra, é definido como Perda por Transição e ocorre devido a diferença de perfil entre os modos de propagação nos segmentos retos e curvados do guia de onda (PAPAKONSTANTINOOU *et al.*, 2007). Nas regiões de junção, limites entre regiões curvadas e retas, verifica-se uma descontinuidade de perfil entre os modos de propagação do guia. O acoplamento entre esses modos não é ideal e, portanto, há perda de energia guiada durante a transição. Entendendo que a distribuição de campo eletromagnético em um guia de onda pode ser descrita por uma gaussiana onde, em segmentos retos, o centro da distribuição da gaussiana coincide com o eixo do guia de onda, tem-se que em regiões de transição o centro da distribuição do campo é deslocado para a parte externa da curvatura e como consequência parte da potência inicial é acoplada aos modos de radiação externos ao núcleo (NEUMANN, 1982). Esse fenômeno ocorre semelhantemente na descontinuidade entre segmento curvado e reto do guia (PAPAKONSTANTINOOU *et al.*, 2007).

A Figura 3 evidencia as regiões determinantes nos fenômenos que contribuem para que parte da energia inicial guiada seja irradiada para fora do núcleo durante a propagação em uma macrocurvatura, como consequência a potência ótica final transmitida é  $P < P_i$ , caracterizando a atenuação do sinal ótico.

**Figura 3 – Perdas óticas associadas às regiões de uma curvatura de fibra ótica.**



**Fonte: Adaptado de Rajan (2008) e Harris e Castle (1986).**

A perda por curvatura resultante, em uma curvatura de comprimento  $L$ , pode ser expressa com base nas Perdas por Transição (em  $a$  e  $c$ ) e Perda por Radiação Tangencial (em  $b$ ), como apresenta a Equação (2) (HARRIS; CASTLE, 1986).

$$\frac{P}{P_i} = \frac{P}{P_i}|_a \times \frac{P}{P_i}|_b \times \frac{P}{P_i}|_c \quad (2)$$

Considera-se que as componentes de Perda por Transição são iguais, e a Perda por Curvatura pode ser expressa de acordo com a Equação (3) (MARCUSE, 1976).

$$\frac{P}{P_i}|_b = \exp(-2\phi L) \quad (3)$$

Portanto, uma relação entre a potência inicial e final na fibra após a atenuação por curvatura pode ser expressa pela Equação (4).

$$\ln\left[\frac{P}{P_i}\right] = -2\phi L + 2\ln\left[\frac{P}{P_i}\right]|_a \quad (4)$$

Onde o Coeficiente de Perda Pura por Curvatura  $2\phi$  é dado de acordo com a Equação (5) (MARCUSE, 1976; WANG *et al.*, 2016).

$$2\phi = \frac{\sqrt{\pi}\kappa^2}{2\gamma^{\frac{3}{2}}V^2\sqrt{R}K_{v-1}(\gamma a)K_{v+1}(\gamma a)} \exp\left(-\frac{2\gamma^3}{\beta^2}R\right) \quad (5)$$

Sendo  $K_v(\gamma a)$  uma função de Henkel modificada de ordem  $v$ ,  $\kappa = \sqrt{(n_1^2 k^2 - \beta^2)}$  e  $\gamma = \sqrt{\beta^2 - n_2^2 k^2}$  com  $k = \frac{2\pi}{\lambda_0}$ ,  $\beta = n_2 k(1 + b\Delta)$ ,  $b = \frac{(\beta/k)^2 - n_2^2}{n_1^2 - n_2^2}$  e  $\Delta = \frac{n_1^2 - n_2^2}{2n_1^2}$ .

Em alguns estudos, nos quais as causas das atenuações podem ser desconsideradas, é comum um modelo que representa o efeito resultante da curvatura por uma diferença localizada do índice de refração com dependência em relação ao raio de curvatura da estrutura da fibra (JAY, 2010).

#### 2.1.4 Modos de Galeria Sussurrantes

Em uma fibra ótica a maior parte da energia modal é propagada no núcleo, e nas camadas externas verifica-se parte da energia do sinal ótico como campo eletromagnético evanescente (CROS; GUILLON, 1990). Na seção anterior, foram descritos mecanismos de atenuação decorrentes de curvaturas, que têm como resultado o aumento da energia de modos evanescentes, fora do núcleo. Em sistemas reais, em que os guias de onda possuem camadas externas de revestimento, esses modos são determinantes no sinal que é transmitido devido a reflexão que ocorre nas interfaces casca-revestimento e revestimento-meio, promovendo o reacoplamento de potência ótica ao núcleo da fibra devido a interferência com modos guiados, caracterizando ressonâncias de Modos de Galeria Sussurrantes, *Whispering Gallery Modes* - WGM (WANG; FARRELL; FREIR, 2005; HARRIS; CASTLE, 1986). A eficiência de reacoplamento de potência dos WGMs ao modo fundamental apresenta dependência em relação ao raio de curvatura, comprimento de onda e diferença de fase entre os modos (WANG *et al.*, 2016).

Esse fenômeno também pode ser verificado em ressonadores toroidais e microesferas, além das estudadas fibras óticas. A geometria e os índices de refração do sistema são determinantes nas ressonâncias de WGM, justificando propostas de sensoriamento baseadas na excitação desses modos (BOLEININGER *et al.*, 2010). A frequência de WGM está associada ao formato do ressonador (ORAEVSKY, 2002), portanto, em fibras óticas curvadas apresenta dependência em relação da geometria de curvatura.

Nesse cenário, fica evidente que apesar da geometria relativamente simples as atenuações finais induzidas por macrocurvaturas de fibras revestidas são complexas e justificam os estudos para modelar diversas configurações de revestimento (FAUSTINI; MARTINI, 1997). No caso de curvaturas de fibras SMF-28, utilizadas no trabalho, a reflexão mais relevante no sinal transmitido ocorre na interface casca e revestimento (WANG; FARRELL; FREIR, 2005).

#### 2.1.5 Macrocurvaturas multiplexadas em série e princípio de operação do sistema

Como discutido, a modificação do perfil da estrutura do guia faz com que modos que seriam guiados, passem a ser irradiados para fora do núcleo. Em situação idealizada, em macrocurvaturas a atenuação ótica aumenta fortemente com a diminuição do raio de curvatura e com o aumento do comprimento de onda da onda guiada (RAJAN, 2008; JAY, 2010). Além disso, em fibras revestidas, as ressonâncias de WGM, que ocorrem devido a reflexão na interface

casca-revestimento, promovem o reacoplamento de modos e consequentemente oscilações características nas intensidades transmitidas. Os dois fenômenos envolvidos na alteração dos espectros de transmissão por efeitos de macrocurvatura apresentam dependência em relação a estrutura de curvatura. Portanto, em operações de sensoriamento de parâmetros mecânicos, o estímulo físico de interesse promove a alteração da geometria de curvatura da fibra, determinando tanto as condições de radiação de modos guiados quanto as condições de ressonâncias de WGMs.

Em um sistema de arranjo de macrocurvaturas em série em um único enlace de fibra ótica o sinal ótico é modificado sequencialmente ao ser transmitido nas regiões de transdução. O sinal de banda larga da fonte interage com o primeiro elemento sensor e sofre alterações devido às perdas por curvatura e aos reacoplamentos devido às ressonâncias de WGM. O espectro inicial alterado por este sensor é o sinal de entrada para o próximo sensor. O sinal alterado pelo segundo sensor passa a ser o sinal de entrada do terceiro sensor e assim por diante. Desta forma, o sinal transmitido detectado é resultante das modulações que ocorreram em todas as macrocurvaturas do arranjo e, portanto, carrega informação de todos os sensores. O cenário descrito é determinante para a operação multiplexada do sistema baseado em macrocurvaturas em série (KAMIZI *et al.*, 2019a).

Com isso, através de um processo de demodulação de sinal ótico transmitido, é possível identificar informações a respeito do estímulo mecânico responsável pelas alterações das estruturas de curvatura do sistema em relação a um estado inicial (sem deformações). Em vista que são muitas as possibilidades de magnitudes e posições de aplicação de forças deformadoras, a demodulação ocorre por modelo computacional preditivo responsável pelo funcionamento do método de multiplexação.

## 2.2 Modelos de Regressão

Definem-se modelos de regressão com objetivo de descrever variações de respostas preditivas em regime contínuo em função de variáveis explicativas de entrada (BREHENY; BURCHETT, 2017). Uma primeira abordagem para caracterização desses modelos diz respeito as relações entre variáveis e grandezas preditas, estabelecendo modelos lineares ou não lineares (DEISS *et al.*, 2020).

A notação para um modelo ordinário de regressão multivariada linear denota  $y$  como resposta, portanto, variável preditiva dependente. O vetor  $\mathbf{x}$  é formado por uma lista de variáveis de predição, definindo as variáveis dependentes que são constantes para uma dada observação individual. O vetor  $\beta$  é formado pelos coeficientes de regressão, sendo  $\beta_0$  um parâmetro de interceptação potencialmente nulo, e  $\beta_1, \beta_2 \dots \beta_p$  equivalentes a pesos associados a  $x_1, x_2 \dots x_p$ . Os modelos são estabelecidos com base na conexão que relaciona os preditores  $\mathbf{x}$  a resposta  $y$  (ZOU; HASTIE, 2003). Um modelo generalizado de regressão linear pode ser expresso pela Equação (6).

$$y = \beta_0 + \mathbf{x}\beta = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots \beta_p x_p \quad (6)$$

O procedimento de treinamento dos modelos pode ser entendido como a obtenção do vetor  $\beta$  que permite executar predições com base em dados coletados prospectivamente (HARRELL, 2019; ZOU; HASTIE, 2003).

Entre as diversas abordagens para o problema da escolha do modelo, uma opção é seguir aproximação orientada pelos dados, ou seja, a construção do modelo é baseada exclusivamente a partir dos dados experimentais. Tal abordagem é conveniente para sistemas complexos em que a conhecimento físico a respeito do processo é limitado e a modelagem a partir dessas informações é virtualmente irrealizável. Em contrapartida, questões como a escolha do tipo de modelo, as funções a serem utilizadas e a complexidade associada aos modelos devem ser objetos de intenso estudo para uma boa modelagem orientada por dados (SOUZA; ARAÚJO; MENDES, 2016).

Em conformidade ao apresentado anteriormente, a primeira decisão tomada nessa abordagem refere-se ao tipo de modelo que será avaliado quanto a linearidade esperada que relaciona as variáveis explicativas às predições, portanto, as opções são de modelos lineares ou não lineares. A aproximação que deve ser considerada primeiramente é a de um modelo linear devido a menor complexidade. Caso o desempenho verificado não seja adequado, então modelos não lineares podem ser considerados para aprimoramento do desempenho (SOUZA; ARAÚJO; MENDES, 2016).

É usual em operações de sensoriamento a utilização de mais de um modelo de regressão em uma mesma implementação para viabilizar a completa operação dos sistemas. Esses casos de abordagem por conjunto de modelos são utilizados em cenários com relativo pequeno número de amostras para modelagem (SOUZA; ARAÚJO; MENDES, 2016). Outra abordagem comum é a utilização de técnicas de redução ou seleção de características em conjunto aos modelos de regressão. Nesses cenários a dimensionalidade dos dados passa por adequação anteriormente as etapas de desenvolvimento da regressão (GRBIĆ; SLIŠKOVIĆ; KADLEC, 2013). De modo direcionado ao objetivo de redução de características, percebe-se a dificuldade em redefinir as variáveis sem que ocorra significativa perda de informação, comprometendo a operação. Com esse objetivo entre os métodos comuns há a técnica de Análise de Componentes Principais, PCA – *Principal Component Analysis*, que atua na conversão da métrica dos dados, reduzindo a dimensionalidade ao criar novas variáveis não relacionadas, definidas por componentes principais, que juntas explicam um determinado percentual da variabilidade dos dados (YANG; WEN, 2018; KAMIZI *et al.*, 2019a).

Na continuidade dessa seção, serão caracterizados os modelos de Regressão por Rede Elástica e Regressão por Vetores Suporte, além dos processos de Validação Cruzada e PCA.

### 2.2.1 Modelo de Rede Elástica

Para determinação dos coeficientes de regressão associados a modelos lineares, um método usual é o de Mínimos Quadrados Ordinários, OLS – *Ordinary Last Squares*, que opera com base na minimização da soma residual dos quadrados. Em vista da grande simplicidade

verifica-se que a acurácia de predição de dados futuros a partir do modelo OLS normalmente é insatisfatória, principalmente devido a amostras discrepantes (ZOU; HASTIE, 2003).

Para aprimorar o desempenho, a partir dessa formulação comum são estabelecidos modelos que contam com um parâmetro de regularização, tais modelos são chamados Ridge e LASSO – *Least Absolute Shrinkage and Selection Operator*, e ambos apresentam vantagens individuais em relação ao modelo base. O modelo Ridge surge com o objetivo de igualar os coeficientes de regressão associados a variáveis com alto grau de correlação, possibilitando reduzir o problema de multicolinearidade (LUGARINI *et al.*, 2020). Esse procedimento é feito adicionando um parâmetro de regularização  $L_2$  na solução por mínimos quadrados. Para um dado  $\lambda_2$  não negativo, a regressão opera minimizando  $L(\lambda_2, \beta)$  sendo,

$$L(\lambda_2, \beta) = \sum_{i=1}^m \|y_i - (\beta_0 + x_i \beta_i)\|^2 + \sum_{j=1}^p \lambda_2 \|\beta_j\|^2 \quad (7)$$

Onde  $m$  é o número de observações,  $y_i$  os alvos associados as  $i$  observações, e  $p$  o número de características preditivas. A penalização  $L_2$ , dada pelo segundo somatório da Equação (7), penaliza coeficientes pouco relevantes para o modelo aproximando os valores a zero.

Por outro lado, o modelo de regressão LASSO além de aproximar a zero é capaz de zerar coeficientes de pouca importância e, portanto, atua também como redutor de dimensionalidade (YANG; WEN, 2018; LUGARINI *et al.*, 2020). Para isso é adicionado um parâmetro de penalização  $L_1$ , dado pelo segundo somatório da Equação (8), na solução do problema de mínimos quadrados e o modelo passa a operar com o objetivo de minimizar  $L(\lambda_1, \beta)$  sendo,

$$L(\lambda_1, \beta) = \sum_{i=1}^m \|y_i - (\beta_0 + x_i \beta_i)\|^2 + \sum_{j=1}^p \lambda_1 \|\beta_j\| \quad (8)$$

O modelo de regressão por Rede Elástica conta com ambas as penalizações,  $L_1$  e  $L_2$ , assumindo a forma de um problema de minimização da função,

$$L(\lambda_1, \lambda_2, \beta) = \sum_{i=1}^m \|y_i - (\beta_0 + x_i \beta_i)\|^2 + \sum_{j=1}^p \lambda_1 \|\beta_j\| + \sum_{j=1}^p \lambda_2 \|\beta_j\|^2 \quad (9)$$

Com isso, o estimador do modelo de Rede Elástica  $\beta$  é obtido sob o critério,

$$\beta = \arg \min_{\beta} L(\lambda_1, \lambda_2, \beta) \quad (10)$$

Definindo  $\alpha = (\lambda_2 / \lambda_1 + \lambda_2)$  e aplicando em  $L(\lambda_1, \lambda_2, \beta)$ , Equação (9), se tem que o modelo com base em Mínimos Quadrados com as penalizações  $L_1$  e  $L_2$  assume a forma do problema de otimização apresentado na Equação (11).

$$\beta = \arg \min_{\beta} \sum_{i=1}^m \|y_i - (\beta_0 + x_i \beta_i)\|^2 + (1 - \alpha) \sum_{j=1}^p \|\beta_j\| + \alpha \sum_{j=1}^p \|\beta_j\|^2 \quad (11)$$


Com  $\alpha$  pertencente ao intervalo  $[0,1]$ , determinando a contribuição das penalizações associadas aos modelos Ridge e LASSO.

### 2.2.2 Modelo de Regressão por Vetores Suporte

O modelo de Regressão por Vetores Suporte, SVR – *Support Vector Regression*, é um método comparável a SVM utilizada para problemas de classificação, entretanto, apresenta o objetivo de determinar parâmetros de uma função multivariada contínua responsável por retornar valores associados às amostras de entrada (ROZENBERG; BÄCK; KOK, 2012). Nessa perspectiva uma função de interesse  $f(x)$  é responsável por associar as componentes  $x_i$  aos alvos  $y_i$  e tem forma  $f(x) = \mathbf{w} \cdot \mathbf{x} - b$ . Com  $\mathbf{w}$  sendo um vetor de pesos associados as características, e  $b$  o parâmetro *bias*, associado aos erros de predição do modelo e que permite generalização frente aos dados de treinamento.

Sob a métrica do modelo de SVR representado na Figura 4, são determinadas margens, ou planos suporte, afastados  $\epsilon$  em relação a curva de ajuste, caracterizando um  $\epsilon$ -tube, onde espera-se que constem os pontos amostrais.

**Figura 4 – Representação de regressão linear por vetor suporte com observações X e margens.**



Fonte: Adaptado de Deiss *et al.* (2020).

Formulando esse problema sobre uma métrica de otimização convexa, se tem objetivo representado por,


$$\min_{\mathbf{w}} \quad \frac{1}{2} \|\mathbf{w}\|^2; \quad \text{sujeito a} \quad \begin{cases} y_i - \mathbf{w} \cdot \mathbf{x}_i - b \leq \epsilon \\ \mathbf{w} \cdot \mathbf{x}_i + b - y_i \leq \epsilon \end{cases} \quad (12)$$

A formulação relaciona todos os valores de  $\mathbf{x}$  aos alvos  $\mathbf{y}$  com precisão de  $\epsilon$ , entretanto em um problema real há necessidade de determinada permissividade a erros (SMOLA; SCHÖLKOPF, 2004), para isso são adicionados parâmetros de folga  $\xi_i$  e  $\xi_i^*$  associados a distâncias ortogonais em relação aos planos suporte e, portanto, o problema assume forma apresentada como,

$$\min_{\mathbf{w}} \quad \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^m (\xi_i + \xi_i^*); \quad \text{sujeito a} \quad \begin{cases} y_i - \mathbf{w} \cdot \mathbf{x}_i - b \leq \epsilon + \xi_i \\ \mathbf{w} \cdot \mathbf{x}_i + b - y_i \leq \epsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (13)$$

Nota-se que a constante  $C$  é responsável por determinar a tolerância quanto a medidas fora do  $\epsilon$ -tube. Sob essas condições destaca-se que apenas erros maiores do que  $\epsilon$  são penalizados pelo modelo. A Figura 5 representa uma função de perda responsável penalizar apenas amostras fora da região insensível a erros,  $\epsilon$ -tube.

**Figura 5 – Função de penalização linear.**



**Fonte: Adaptado de Deiss *et al.* (2020).**

A solução da equação objetiva (13) submetida as condições apresentadas e que deve ser minimizada é realizada adicionando um novo conjunto de variáveis e formulando uma função de Lagrange (L) (WELLING, 2004),

$$L = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^m (\xi_i + \xi_i^*) - \sum_{i=1}^m (\eta_i \xi_i + \eta_i^* \xi_i^*) - \sum_{i=1}^m \alpha_i (\epsilon + \xi_i - y_i + \mathbf{w} \cdot \mathbf{x}_i + b) - \sum_{i=1}^m \alpha_i^* (\epsilon + \xi_i^* + y_i - \mathbf{w} \cdot \mathbf{x}_i - b); \quad \text{com} \quad \begin{cases} \eta_i, \eta_i^* \geq 0 \\ \alpha_i, \alpha_i^* \geq 0 \end{cases} \quad (14)$$

Sendo  $\eta_i, \eta_i^*, \alpha_i, \alpha_i^*$  multiplicadores de Lagrange. Com o objetivo de determinar os pontos de sela, são estabelecidas derivadas parciais de L em relação a  $\mathbf{w}$ ,  $b$ ,  $\xi_i$  e  $\xi_i^*$ . Esse procedimento é realizado para determinar condições de minimização da função L para cada multiplicador de Lagrange, portanto, estabelece critérios de otimização do problema.

$$\frac{\partial L}{\partial b} = \sum_{i=1}^m (\alpha_i - \alpha_i^*) = 0 \quad (15)$$

$$\frac{\partial L}{\partial \mathbf{w}} = \mathbf{w} - \sum_{i=1}^m (\alpha_i - \alpha_i^*) \mathbf{x}_i = 0 \quad (16)$$

$$\frac{\partial L}{\partial \xi_i} = C - \alpha_i - \eta_i = 0 \quad (17)$$

$$\frac{\partial L}{\partial \xi_i^*} = C - \alpha_i^* - \eta_i^* = 0 \quad (18)$$

Com a Equação (16) é possível isolar  $\mathbf{w}$ , semelhantemente as equações 17 e 18 permitem isolar  $\eta_i$  e  $\eta_i^*$ . Fazendo substituições das equações de 15 a 18 na Equação (14), o problema de otimização pode ser simplificado para,

$$\begin{aligned} \max_{\alpha, \alpha^*} \quad & -\frac{1}{2} \sum_{i,j=1}^m (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) \mathbf{x}_i \cdot \mathbf{x}_j - \epsilon \sum_{i=1}^m (\alpha_i + \alpha_i^*) + \\ & + \sum_{i=1}^m y_i (\alpha_i - \alpha_i^*) ; \quad \text{sujeito a } \sum_{i=1}^m (\alpha_i - \alpha_i^*) = 0 \quad \text{com } 0 \leq \alpha_i, \quad \alpha_i^* \leq C \end{aligned} \quad (19)$$

Ao representar  $\mathbf{w}$  através de uma combinação linear de  $\mathbf{x}_i$ , é obtida a expansão de vetor suporte para modelos SVR lineares.

$$f(x) = \sum_{i=1}^m (\alpha_i - \alpha_i^*) \mathbf{x}_i \cdot \mathbf{x} + b \quad (20)$$

Essa equação possibilita a predição de respostas  $y$  através do mapeamento dos vetores de treinamento associados a alvos com valores reais e tem permissividade quanto a erros determinada pelo problema de otimização apresentado na Equação (19).

Para viabilizar o treinamento de modelos não lineares, recorre-se ao "truque de kernel" para substituir o produto interno dos vetores  $x_i$  e  $x_j$ , utilizando uma função kernel  $K(x_i, x_j)$ , responsável por alterar a dimensionalidade das características. Com isso, a Equação (19) assume a forma,

$$\begin{aligned} \max_{\alpha, \alpha^*} \quad & -\frac{1}{2} \sum_{i,j=1}^m (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) K(\mathbf{x}_i, \mathbf{x}_j) - \epsilon \sum_{i=1}^m (\alpha_i + \alpha_i^*) + \\ & + \sum_{i=1}^m y_i (\alpha_i - \alpha_i^*) ; \quad \text{sujeito a } \sum_{i=1}^m (\alpha_i - \alpha_i^*) = 0 \quad \text{com } 0 \leq \alpha_i, \quad \alpha_i^* \leq C \end{aligned} \quad (21)$$

E para modelos não lineares a expansão de vetor suporte é dada por,

$$F(x) = \sum_{i=1}^m (\alpha_i - \alpha_i^*) K(\mathbf{x}_i, \mathbf{x}_j) + b \quad (22)$$

A avaliação de  $b$  é feita através das condições de Karush-Kuhn-Tucker.

A otimização desses modelos de regressão ocorre principalmente através da seleção da função kernel e com a alteração do parâmetro  $\epsilon$ . Entre as funções kernel usuais de menor complexidade há o kernel linear dado por  $K(\mathbf{x}_i, \mathbf{x}) = \mathbf{x}_i^T \mathbf{x}$  (CHE; WANG, 2014; DEISS *et al.*, 2020).

### 2.2.3 Redução de dimensionalidade por Análise de Componentes Principais

O processo de Análise de Componentes Principais atua na alteração de estruturas de dados que podem ser complexas, promovendo a representação de dados iniciais sob uma métrica alterada com menor dimensionalidade. Essa modificação resulta em um novo conjunto de dados, formado por componentes principais, que explicam determinado percentual da variabilidade dos dados iniciais (SHLENS, 2014). Tomando esse novo conjunto é possível identificar estruturas e selecionar a quantidade de informação fornecida para operação de modelos de aprendizagem.

Combinações lineares das  $p$  características dos dados expressam componentes principais (HOLLAND, 2008). Por exemplo, a primeira componente principal ( $t_1$ ) pode ser escrita como,

$$t_1 = a_{11}x_1 + a_{12}x_2 + \dots + a_{1p}x_p \quad (23)$$

A primeira componente principal apresentada tem o objetivo de representar a maior variância possível dos dados iniciais de  $\mathbf{X}$ . Para normalização de todo o processo, os pesos das combinações lineares são normalizados com a condição expressa abaixo para exemplo dos pesos associados a primeira componente principal,

$$a_{11}^2 + a_{12}^2 + \dots + a_{1p}^2 = 1 \quad (24)$$

A segunda componente principal deve ser não correlacionada com a primeira e expressar a próxima maior variância possível. Essas condições se estendem para  $p$  componentes principais. Por fim, a variância explicada por todas as componentes principais será igual a variância dos dados iniciais. Define-se a matriz  $\mathbf{A}$  contendo todos os pesos, ou transformações, associadas a cada componente principal (HOLLAND, 2008).

Sob essas condições, o processo de modificação de métrica de variáveis explicativas para componentes principais é expresso matricialmente por,

$$\mathbf{T} = \mathbf{AX} \quad (25)$$

A solução para PCA, usando decomposição em autovetores, conclui que as componentes principais são autovetores da matriz de covariância de  $\mathbf{X}$ , dada por,

$$\mathbf{C}_x = \frac{1}{m} \mathbf{X} \mathbf{X}^T \quad (26)$$

Portanto, os autovetores de  $\mathbf{C}_x$  são formados pelos pesos associados as transformações.

Além disso, a solução indica que tomando a matriz de covariância das componentes principais,  $\mathbf{C}_t$ , tem-se que os elementos da diagonal principal determinam a variância explicada por cada componente principal (SHLENS, 2014). Onde  $\mathbf{C}_t$  é computado por,

$$\mathbf{C}_t = \mathbf{A} \mathbf{C}_x \mathbf{A}^T \quad (27)$$

Uma escolha que deve ser feita após a implementação da PCA é referente ao número de componentes principais que devem ser investigadas para uso nos modelos de aprendizagem e quantas devem ser ignoradas, portanto, determina-se a quantidade de informação ou variabilidade explicada fornecida para operação. Para essa determinação surgem critérios como os listados na sequência: Um primeiro comum é optar por selecionar apenas as componentes com grande importância para explicar a variância dos dados, ignorando componentes que aumentam pouco a variabilidade explicada. Uma segunda opção é predeterminar um total de variância explicada requerida e utilizar um número de componentes que expliquem a variabilidade mais próxima ao valor predeterminado. Outra possibilidade é ignorar componentes principais de variâncias explicadas com valores muito próximos (HOLLAND, 2008).

#### 2.2.4 Seleção de modelo por Validação Cruzada


Os métodos de validação cruzada apresentam objetivo referente à avaliação da capacidade de generalização de modelos preditivos auxiliando a prevenir casos de sobreajuste, dessa forma esses métodos usualmente estão relacionados a seleção de modelos (BROWNE, 2000; DUBITZKY; GRANZOW; BERRAR, 2007) .

Todos os modelos em algum momento apresentam falhas dadas específicas condições, nesse sentido a obtenção de um modelo ideal em todos os casos é virtualmente irrealizável. Define-se como objetivo central de uma boa modelagem a obtenção de um modelo com aproximação satisfatória a realidade e com capacidade de discriminação (BROWNE, 2000). Para que essas características sejam verificadas em modelos de aprendizagem supervisionada um problema que deve ser evitado é o de sobreajuste. Nesses cenários o modelo torna-se muito adaptado aos dados de treinamento, e quando aplicado a novas amostras verifica-se grande piora de desempenho, portanto, o modelo desenvolvido torna-se específico e com baixa capacidade de generalização. Uma condição que promove o cenário de sobreajuste está associada à relativo alto grau de complexidade com número de variáveis características relativamente muito maior

do que de amostras de treinamento. Por outro lado, um modelo muito simples dificilmente irá discriminar relações entre variáveis e nesse cenário a capacidade preditiva do modelo é prejudicada, apresentando relativos altos erros, com isso é caracterizam-se casos de subajuste (LEVER; KRZYWINSKI; ALTMAN, 2016). Ambos os cenários apresentados não são satisfatórios do ponto de vista de capacidade de aprendizagem dos modelos. Espera-se de um modelo preditivo operacional relativos baixos erros de predição e boa capacidade de generalização frente a amostras desconhecidas. Com base no discutido, se estabelece o desafio central de determinar um ajuste intermediário e adequado.

Ao invés da avaliação individual de um modelo para determinação se o mesmo é adequado ou não, é extremamente conveniente para a avaliação de modelos preditivos a comparação simultânea entre modelos que competem entre si, tal comparação aponta para qual modelo deve ser utilizado (DUBITZKY; GRANZOW; BERRAR, 2007). De modo geral, para realização dos métodos de validação cruzada há a divisão das amostras usadas para aprendizagem em subconjuntos. São definidos conjuntos de treinamento e de validação, em sequência o modelo é construído com base no conjunto de treinamento e testado com o conjunto de validação. Métodos distintos de validação cruzada especificam como são gerados ambos os conjuntos de forma aleatória. Na sequência será abordado o método de validação cruzada *k-fold*.

Para realização da validação cruzada *k-fold* todo o conjunto de amostras para treinamento é separado em  $k$  subconjuntos disjuntos com aproximadamente mesma dimensão. As amostras que formam os subconjuntos são aleatoriamente distribuídas. Em seguida,  $k-1$  subconjuntos são utilizados para o treinamento dos modelos, caracterizando o conjunto de treinamento. O único modelo que não foi utilizado para treinamento representa o conjunto de validação. O modelo treinado a partir do conjunto de treinamento é testado utilizando o conjunto de validação. Esse procedimento é realizado consecutivamente de modo que todos os subconjuntos sejam testados. A Figura 6 representa como são organizados os conjuntos de amostras para validação cruzada *10-fold* (KUHN; JOHNSON *et al.*, 2013).

**Figura 6 – Validação cruzada 10-fold.**

Fonte: Adaptado de (KUHN; JOHNSON *et al.*, 2013).

Cada uma das  $k$  iterações que utiliza um conjunto de validação individual resulta em uma estimativa de erro de predição. Usualmente o erro de validação é dado pela média dos  $k$  erros individuais. Com isso conclui-se que a capacidade de generalização de um modelo preditivo pode ser acessada pela validação cruzada. Frequentemente esse processo é utilizado para seleção de parâmetros, como por exemplo os parâmetros  $\lambda$  para modelos baseados em Rede Elástica. Ao repetir o processo para diversos valores de  $\lambda$  é possível identificar qual valor está associado ao menor erro de validação cruzada e, portanto, indica o melhor parâmetro para treinamento do modelo final.

### 3 MATERIAL E MÉTODOS

#### 3.1 Desenvolvimento dos sistemas sensores

Foram desenvolvidos dois sistemas de sensores multiplexados para realização de testes quanto a capacidade de monitorar a configuração de força individual aplicada sobre estruturas rígidas avaliadas em uma e duas dimensões. As configurações de força, correspondem a magnitude, entre 100 gf e 2000 gf, e a região de aplicação da força. As diferentes configurações de força afetam de maneira diversa o sinal ótico transmitido pelos sistemas que contam com 3 e 5 elementos sensores multiplexados. As etapas de elaboração desses sistemas são descritas a seguir.

##### 3.1.1 Produção dos sistemas de macrocurvaturas multiplexadas

Em fibras monomodo padrão (SSMF, G-652, Draktel) foram feitas curvaturas formando estruturas de anéis, com diâmetros fixos de  $(0,5 \pm 0,1)$  cm. Sobre a região de curvatura foi depositada uma camada de silicone adesivo a base de policloropreno com objetivo de auxiliar na estabilização mecânica da estrutura até a etapa de pré-encapsulamento. Uma macrocurvatura é apresentada na Figura 7. Essas estruturas estavam posicionadas de maneira aproximadamente equidistante separadas por  $(5,0 \pm 1,0)$  cm nos segmentos de fibra.

**Figura 7 – Anel de fibra ótica fixado com um laço simples utilizado para fabricação de transdutor baseado em macrocurvatura.**




**Fonte: Autoria própria (2022).**

As macrocurvaturas em anéis foram submetidas a etapa de pré-encapsulamento, nessa fase foram acoplados cilindros elastoméricos de altura  $(1,1 \pm 0,1)$  cm e diâmetro da base  $(0,5 \pm 0,1)$  cm, aos anéis de fibra ótica. Esse método foi empregado com o objetivo de viabilizar e

garantir o posicionamento adequado das macrocurvaturas na etapa de encapsulamento, ponto esse que se mostrou importante em testes preliminares.

A última etapa para o desenvolvimento do sistema foi a de encapsulamento, em que as estruturas pré-encapsuladas foram posicionadas internamente a um cilindro de material elastomérico com as dimensões apresentadas na Figura 8a. Os anéis são posicionados como exhibe a Figura 8b, de modo que uma força aplicada na base do encapsulamento promova o achatamento do anel.

**Figura 8 – Representações dos elementos sensores utilizados no sistema ótico. (a) Elemento sensor formado por estrutura de fibra curvada em anel e encapsulação. (b) Corte transversal do elemento sensor mostrando posicionamento do anel de fibra interno ao encapsulamento.**




**Fonte: Autoria própria (2022).**

Tanto no pré-encapsulamento quanto no encapsulamento, o material elastomérico utilizado foi elastômero de silicone (Dow Corning, BX3-8001). O tempo mínimo de cura após adição de catalisador foi de 72 horas.

### 3.1.2 Matriz de sensoriamento unidimensional

A Figura 9 exhibe o sistema ótico com 3 elementos sensores multiplexados e a matriz de sensoriamento elaborada, evidenciando a geometria da estrutura. O dispositivo baseia-se no sistema multiplexado, Figura 9a, acoplado entre duas placas planas e retangulares de PMMA (polimetilmetacrilato) com espessura de  $(0,5 \pm 0,1)$  cm, e lados com  $(10,0 \pm 0,1)$  cm e  $(30,0 \pm 0,1)$  cm. A estrutura e o sistema sensor foram fixados utilizando silicone acético. Também foram fixados quatro elementos elastoméricos cúbicos de lado  $(0,8 \pm 0,1)$  cm a fim de garantir a estabilidade mecânica da estrutura quando submetida a forças, resultando na matriz apresentada na Figura 9b.


**Figura 9 – (a) Sistema em fibra ótica com três elementos sensores multiplexados. (b) Matriz de sensoriamento unidimensional para monitoração de força individual aplicada em diferentes áreas colineares. Linha realçada sobre a fibra ótica para visualização.**



Fonte: Autoria própria (2022).

Para rotular as seis posições de aplicação de força, foram utilizadas coordenadas (em cm) associadas a posição central da área onde as forças foram distribuídas. A Figura 10 apresenta as áreas de aplicação de força e a coordenada associada a cada área inscrita na matriz de sensoriamento unidimensional. Os três elementos sensores do sistema são fixos nas posições relativas de 5 cm, 15 cm e 25 cm em relação a extremidade de entrada do sinal ótico do dispositivo.

**Figura 10 – Em preto as áreas e coordenadas centrais de aplicação de força na matriz de sensoriamento unidimensional. Em cinza, posições dos elementos sensores acoplados à estrutura.**



Fonte: Autoria própria (2022).


Destaca-se que o número de elementos sensores responsáveis pela monitoração de forças nessa matriz foi inferior em relação ao número de áreas de aplicação de força, ou seja, regiões monitoradas.

### 3.1.3 Matriz de sensoriamento bidimensional

A segunda estrutura avaliada é composta pelo sistema de 5 elementos sensores multiplexados, Figura 11a, acoplado entre duas placas metálicas, de alumínio, com geometrias quadradas

de lados  $(20,0 \pm 0,1)$  cm, e espessuras de  $(0,05 \pm 0,02)$  cm para placa superior e  $(0,30 \pm 0,05)$  cm para placa inferior. O sistema sensor foi fixado entre as placas utilizando silicone acético. A disposição dos elementos sensores apresenta simetria, com um elemento central e quatro elementos próximos as extremidades das placas, distantes 1 cm em relação as bordas. A diferença de espessura entre a placa inferior e superior foi utilizada para que forças aplicadas pudessem deformar os elementos sensores entre as placas sob resistência mecânica associada a deformação da placa de alumínio superior. A Figura 11b exibe a matriz de sensoriamento utilizada nos ensaios.


**Figura 11 – (a) Sistema em fibra ótica com cinco elementos sensores multiplexados. (b) Matriz de sensoriamento bidimensional para monitoração de força individual aplicada sobre a estrutura. Linha realçada sobre a fibra ótica para visualização.**



**Fonte: Autoria própria (2022).**

Também foram rotuladas as nove áreas de aplicação de força inscritas na matriz de sensoriamento bidimensional. Cada área estava associada a duas coordenadas referentes aos eixos perpendiculares de monitoração. A Figura 12 apresenta essas áreas bem como as coordenadas que as definem e foram utilizadas nas etapas de treinamento dos modelos preditivos. Nessa estrutura, avaliada quanto a possibilidade de monitoração em 9 regiões distintas, foram utilizados 5 elementos sensores, portanto, devido ao acoplamento das modulações resultantes, cada elementos sensor foi responsável pela monitoração de mais de uma região da matriz. As coordenadas referentes às posições de instalação dos elementos sensores são,  $(1,0 ; 1,0)$  cm,  $(1,0 ; 19,0)$  cm,  $(10,0 ; 10,0)$  cm,  $(19,0 ; 1,0)$  cm,  $(19,0 ; 19,0)$  cm.

**Figura 12 – Em preto as áreas e coordenadas centrais de aplicação de força na matriz de sensoriamento bidimensional. Em cinza, posições dos elementos sensores acoplados à estrutura.**



**Fonte: Autoria própria (2022).**


### 3.2 Métodos de coleta de dados

Durante os ensaios experimentais o sinal ótico transmitido pelos sistemas foi interrogado por espectroscopia. Foram detectadas intensidades óticas em comprimentos de onda na faixa compreendida entre 200 nm e 1050 nm. A seguir serão apresentados o *setup* para interrogação do sistema, o mecanismo que permitia o controle e a aplicação de forças e as metodologias experimentais empregadas para caracterizações e avaliações de operação.

#### 3.2.1 Aquisição de dados espectrométricos

A montagem experimental utilizada para aquisição dos dados espectrométricos de transmitância é representada na Figura 13. A fonte ótica (LS-1 Tungsten halogen lamp, Ocean Optics, 360 a 2000 nm), foi conectada ao sistema sensor e ao espectrômetro UV-Vis a fibra ótica (HR4000, Ocean Optics, com resolução de 1,72 nm) em série. A resolução do espectrômetro, 1,72 nm, foi calculada pelo produto entre a dispersão (razão entre alcance espectral da grade, 850 nm, e número de elementos detectores, 3648) e resolução de pixel para fenda com 50  $\mu\text{m}$ , aproximadamente 7,4 pixels. Os dados espectrais transmitidos são apresentados em um computador e salvos cerca de 2 segundos após a aplicação das forças, esse intervalo está associado a estabilização da resposta. Os dados de intensidade por comprimento de onda são apresentados em variações de 0,26 nm.

**Figura 13 – Esquema de montagem experimental conectando em série fonte ótica, estrutura rígida sensora, espectrômetro e computador.**




**Fonte: Autoria própria (2022).**

A referência de intensidade transmitida foi tomada pelo sinal com o sensor em um estado inicial, sem a aplicação de força. A aplicação de força sobre a estrutura promove a perda de intensidade ótica em relação a esse estado, portanto, serão apresentados dados de intensidade relativa para caracterização das respostas detectadas.

### 3.2.2 Método de aplicação de forças

Para controle da magnitude e posição das forças aplicadas sobre as estruturas rígidas foi desenvolvido um mecanismo utilizando hastes como suporte de carga, posicionadas sobre cada região de aplicação de força. A Figura 14 apresenta o mecanismo em que pesos padronizados são posicionados sobre as hastes, permitindo o controle da magnitude do estímulo aplicado.

**Figura 14 – Mecanismo aplicador de forças.**



**Fonte: Autoria própria (2022).**

O mesmo mecanismo foi utilizado para as duas estruturas com geometrias distintas. As áreas de aplicação das forças correspondem as áreas das bases circulares das hastes móveis utilizadas. No caso de aplicação de forças sobre as estruturas foram utilizadas bases com diâmetro de  $(2,00 \pm 0,10)$  cm. As perdas devido ao atrito entre as hastes e a estrutura do suporte que atuava

como guia, ocorria em um comprimento de  $(1,5 \pm 0,1)$  cm, e foi minimizada experimentalmente, portanto não foram consideradas nas estimativas de força efetiva aplicada.

### 3.2.3 Método de caracterização da operação desacoplada dos elementos sensores

Todos os elementos sensores, de ambos os sistemas multiplexados, foram submetidos ao procedimento descrito a seguir voltado a análise de respostas desacopladas. Foram aplicadas quatro forças entre 0 gf e 2000 gf em variações de 500 gf, diretamente sobre um único elemento sensor em toda área de base do encapsulamento. O procedimento foi aplicado sequencialmente nos sensores, referidos por numeração entre 1 e 3, para o sistema com três elementos sensores e entre 1 e 5 para o sistema com cinco elementos sensores, de acordo com a ordem em relação a extremidade de entrada do sinal ótico na fibra. Em vista que o sinal de referência é tomado com todos os elementos sensores livres de forças deformadoras, ressalta-se que apesar dos elementos sensores serem conectados em série em um único enlace de fibra ótica, tem-se que as modulações detectadas nesse ensaio se referem a força aplicada somente sobre o elemento sensor avaliado.

### 3.2.4 Método de avaliação da repetibilidade de operação dos sistemas acoplados

Para avaliação da repetibilidade dos espectros de transmissão resultantes dos sistemas sensores quando acoplados às estruturas rígidas foram conduzidos ensaios sequenciais onde os dispositivos foram submetidos às mesmas configurações de força em intervalos de tempo, fixos e regulares de 20 minutos. Foram coletados espectros de transmissão associados a cinco configurações de forças, aleatoriamente selecionadas, para as duas estruturas propostas. A Tabela 1 apresenta as cinco configurações de força selecionadas para a avaliação da repetibilidade associada ao sistema acoplado na matriz de sensoriamento unidimensional.

**Tabela 1 – Configurações de força aplicadas na matriz de sensoriamento unidimensional para análise de repetibilidade.**

| Configuração | Posição (cm) | Magnitude (gf) |
|--------------|--------------|----------------|
| 1            | 27,5         | 1000           |
| 2            | 22,5         | 600            |
| 3            | 27,5         | 400            |
| 4            | 17,5         | 200            |
| 5            | 22,5         | 1500           |

**Fonte: Autoria própria (2022).**

Para avaliação da repetibilidade de operação associada a matriz de sensoriamento bidimensional, foram utilizadas as configurações de carga apresentadas na Tabela 2.

**Tabela 2 – Configurações de força aplicadas na matriz de sensoriamento bidimensional para análise de repetibilidade.**

| Configuração | Posição x (cm) | Posição y (cm) | Magnitude (gf) |
|--------------|----------------|----------------|----------------|
| 1            | 16,7           | 3,3            | 600            |
| 2            | 10,0           | 10,0           | 600            |
| 3            | 16,7           | 10,0           | 1800           |
| 4            | 10,0           | 3,3            | 1300           |
| 5            | 3,3            | 16,7           | 1500           |

**Fonte: Autoria própria (2022).**

O mesmo teste foi realizado três vezes consecutivas. Durante os intervalos entre as medidas não houve modificação significativa nas conexões óticas e posicionamentos dos aparatos. A partir disso foram traçadas as curvas médias e estimados os desvios padrões para expressar o grau de repetibilidade das curvas de intensidade relativa por comprimento de onda.

### 3.3 Caracterização da operação dos sistemas

Foram conduzidos ensaios experimentais em que os sistemas foram interrogados durante aplicação de configurações de força variadas sobre as estruturas de sensoriamento. Considera-se que uma configuração de força é caracterizada por dois parâmetros: a posição e a magnitude da força individual. Considerando as individualidades, cada estrutura foi submetida a um ensaio específico com os objetivos de monitoração apresentados na presente seção.

#### 3.3.1 Método de caracterização da operação do sistema na matriz de sensoriamento unidimensional

Para avaliação da operação do sistema acoplado a matriz de sensoriamento unidimensional, foram conduzidos ensaios para aquisição de dois conjuntos de dados, sendo o segundo exclusivo para teste.

O primeiro conjunto de dados, voltado a treinamento e validação dos modelos de regressão, contou com 72 amostras, representando 60% das configurações de força possíveis de acordo com o número de áreas de monitoração e faixa de forças aplicadas sobre a estrutura avaliada. Essas amostras estavam associadas a configurações de forças com magnitudes na faixa entre 100 gf e 2000 gf em variações de 100 gf, aplicadas individualmente em uma das seis áreas colineares de monitoração da estrutura.

O segundo conjunto de dados, utilizado para teste dos modelos, resultou de um ensaio conduzido 20 minutos após a finalização do conjunto de treinamento e validação. Esse segundo conjunto foi formado a partir de 24 amostras (equivalente a 20% das configurações de força possíveis) associadas a configurações de forças que obrigatoriamente não passaram por treinamento ou validação.

Os ensaios que originaram os conjuntos foram conduzidos sequencialmente sem modificação da montagem experimental durante os 20 minutos de intervalo. A ordem de aplicação de forças utilizada foi aleatória em vista que a literatura conclui que a ordenação implica em significativa diferença de desempenho de predições (LUGARINI *et al.*, 2020). Tal ordenação aleatória foi determinada de acordo com um algoritmo, desenvolvido em Matlab (R2018b, Mathworks Inc., MA, USA), responsável por gerar as configurações de forças dadas as condições de posições e magnitudes.

### 3.3.2 Método de caracterização da operação do sistema na matriz de sensoriamento bidimensional

Para avaliar a operação da estrutura bidimensional, o primeiro conjunto de dados, voltado a treinamento e validação foi composto por 108 amostras associadas a configurações de forças formadas por estímulos de 100 gf a 2000 gf, em variações de 100 gf, aplicados em uma das nove regiões da estrutura.

Também foi construído um segundo conjunto de dados voltado a teste. Tal conjunto era formado por 36 amostras, referentes à configurações de força com magnitudes da mesma faixa, que obrigatoriamente não passaram por treinamento. Além disso, o ensaio foi realizado após intervalo em 20 minutos em relação ao de treinamento e validação.

Os conjuntos de dados, com 108 e 36 amostras, representaram 60% e 20%, respectivamente, das configurações de força possíveis dadas as magnitudes utilizadas e número de áreas de monitoração da estrutura.

A coleta de dados foi realizada sequencialmente, e a ordem de aquisição aleatória foi determinada por um algoritmo desenvolvido em Matlab (R2018b, Mathworks Inc., MA, USA), responsável por gerar as configurações de forças dadas as condições apresentadas.

## 3.4 Implementação dos modelos preditivos de regressão

A partir dos conjuntos de dados espectrais resultantes dos ensaios foram realizadas etapas associadas a divisão, filtragem, normalização, treinamento, validação e teste. Para todas as implementações, a rotina de implementação foi iniciada com a organização da matriz de entrada. Para isso, primeiramente foi realizada uma filtragem espectral com base em ensaios preliminares e estado da arte (LUGARINI *et al.*, 2020), implicando na utilização de intensidades relativas transmitidas em comprimentos de onda na faixa espectral (400-720) nm. Com isso as matrizes de entrada, formadas por linhas associadas a cada uma das  $n$  amostras e 1229 colunas associadas aos comprimentos de onda são representadas na Figura 15.

**Figura 15 – Métrica das matrizes de entrada para implementação dos modelos.**

|               |   | Comprimentos de onda (nm)                          |                      |                      |     |                      |
|---------------|---|----------------------------------------------------|----------------------|----------------------|-----|----------------------|
|               |   | 400,0                                              | 400,3                | 400,6                | ... | 720,1                |
| Configurações | 1 | $I_{1 \times 400}$                                 | $I_{1 \times 400,3}$ | $I_{1 \times 400,6}$ | ... | $I_{1 \times 720,1}$ |
|               | 2 | $I_{2 \times 400}$                                 | $I_{2 \times 400,3}$ | $I_{2 \times 400,6}$ | ... | $I_{2 \times 720,1}$ |
|               | 3 | $I_{3 \times 400}$                                 | $I_{3 \times 400,3}$ | $I_{3 \times 400,6}$ | ... | $I_{3 \times 720,1}$ |
|               | . | .                                                  | .                    | .                    | ... | .                    |
|               | . | .                                                  | .                    | .                    | ... | .                    |
|               | . | .                                                  | .                    | .                    | ... | .                    |
|               | n | $I_{n \times 400}$                                 | $I_{n \times 400,3}$ | $I_{n \times 400,6}$ | ... | $I_{n \times 720,1}$ |
|               |   | Features de intensidade<br>por comprimento de onda |                      |                      |     |                      |

**Fonte: Autoria própria (2022).**

Utilizando os conjuntos voltados a treinamento e validação foram realizadas separações *hold-out* que resultam em conjuntos de validação compostos por 30% das amostras iniciais. As amostras restantes desses conjuntos (70%) foram utilizados para treinamento. Os dados resultantes dos ensaios conduzidos 20 minutos após a finalização do conjunto treinamento e validação, passaram apenas pela filtragem espectral (400-720) nm, resultando em amostras de teste.

Para predição da posição da força aplicada na matriz de sensoriamento unidimensional foi utilizado apenas um vetor alvo referente à posição e um vetor alvo referente à magnitude da força. Já para completa predição da configuração de força na matriz de sensoriamento bidimensional, foram treinados três modelos, sendo um para predição de magnitude da força e dois para predição de posição, onde cada um desses modelos de predição de posição estava associado à uma dimensão da matriz bidimensional, referidas como posição x e posição y. Todos os dados, entradas e saídas, foram normalizados com alcance dado pelo intervalo [-1, 1].

As implementações foram realizadas em Matlab (R2018b, Mathworks Inc., MA, USA) em computador com CPU de modelo AMD Ryzen 5 2600 com seis núcleos.

#### 3.4.1 Implementação e parâmetros dos modelos de Rede Elástica


Para o modelo de regressão baseado em Rede Elástica, inicializado com 1229 variáveis características, foram treinados 9 modelos preliminares, com valores de  $\alpha$  variando entre 0.1 e 0.9. Para o treinamento de todos esses modelos, foi realizada validação cruzada 10-*fold* para seleção do parâmetro  $\lambda$ . Em seguida os modelos eram submetidos a validação *hold-out*. Os

resultados de validação e o potencial de redução de variáveis características foram considerados na escolha do modelo submetido a teste.

Ressalta-se que parâmetro  $\alpha$  diz respeito a contribuição das penalizações, de modo que, sob a métrica adotada, com  $\alpha = 1$  o modelo é idêntico a uma regressão LASSO e conforme  $\alpha$  tende a 0 o modelo aumenta a contribuição da penalização  $L_2$ , associada a Ridge. Foram utilizados os valores do parâmetro  $\alpha$  variando de 0.1 a 0.9 em variações de 0.1. Essa escolha foi feita para garantir a redução de variáveis características devido a penalização  $L_1$ . Nesse sentido, destaca-se que esse modelo também fundamentou a avaliação dos comprimentos de onda relevantes com base em coeficientes de regressão diferentes de zero.

Todos os modelos passaram por validação cruzada com *10-folds*, essa etapa teve o objetivo de selecionar os valores de  $\lambda$ , parâmetro de regularização. Foram selecionados modelos com valores de  $\lambda$  associados a desempenhos com erro quadrático médio (MSE) igual ao erro quadrático médio mínimo acrescido de um desvio padrão. Portanto, foram utilizados modelos com desempenho ligeiramente inferiores aos desempenhos médios. A etapa de validação *hold-out* teve objetivo de seleção do modelo para teste considerando o erro de validação e o potencial de redução de comprimentos de onda. As etapas de implementação a análise dos modelos são representadas na Figura 16.

**Figura 16 – Fluxuograma de tratamento de dados, implementação e avaliação dos modelos de Regressão por Rede Elástica a partir dos conjuntos de dados.**



**Fonte: Autoria própria (2022).**


### 3.4.2 Implementação e parâmetros dos modelos de Regressão por Vetores Suporte

A seleção dos kernels utilizados foi feita com base em análises prévias conduzidas priorizando a manutenção da baixa complexidade dos modelos, resultando na seleção do kernel linear e polinomial quadrático.

Para implementação e análise dos modelos de regressão baseados em Vetores Suporte a metodologia contou com etapa preliminar de Análise de Componentes Principais. Tal algoritmo foi inicializado com matrizes de entrada, de métrica apresentada na Figura 15. Foram analisadas as variabilidades cumulativas e individuais explicadas por cada componente principal resultante. Com base nos resultados foi definido que os modelos deveriam operar com um número máximo de componentes principais ( $n_{max}$ ) associado à variabilidade cumulativa explicada de 90%. Essa escolha foi feita com o objetivo de não considerar componentes de pouca contribuição e manter a dimensionalidade dos modelos relativamente reduzida, diminuindo a necessidade de processamento computacional.

Foram implementados modelos validados por validação cruzada *10-fold*, com de 1 a  $n_{max}$  componentes principais. Com base nos erros de validação *hold-out* e no número de componentes principais utilizados foram selecionados modelos para etapa de teste. A Figura 17 esquematiza as etapas metodológicas empregadas.

**Figura 17 – Fluxograma de tratamento de dados, implementação e avaliação dos modelos de Regressão por Vetores Suporte a partir dos conjuntos de dados.**



**Fonte: Autoria própria (2022).**

Nas implementações dos modelos a etapa de validação cruzada *10-fold* teve objetivo de selecionar um modelo com desempenho intermediário em termos de erros. Isso foi feito selecionando os modelos que apresentavam MSE de validação cruzada mais próximo ao MSE médio dos *folds*. A validação *hold-out* visou permitir a consideração tanto do erro de validação quanto do número de componentes principais para seleção do modelo para etapa de teste.

Os erros de monitoração apresentados no trabalho se referem a erro absoluto médio (MAE). Matematicamente a MAE é expressa na Equação 28. Uma vantagem associada a esse erro é a possibilidade de expressar os erros de monitoração nas mesmas unidades dos parâmetros físicos monitorados, ou seja, em gf para os modelos e predição de força, e em cm para os modelos de predição de posição.


$$MAE = \sum_{i=1}^m \frac{|y_i - \hat{y}_i|}{n} \quad (28)$$

## 4 RESULTADOS E DISCUSSÃO

### 4.1 Respostas dos elementos sensores desacoplados

A Figura 18 apresenta os espectros de transmissão do sistema contendo três sensores multiplexados em série antes deste ser inserido entre as estruturas rígidas que formavam a matriz de sensoriamento unidimensional. Ressalta-se que apesar da aplicação de forças entre 500 gf e 2000 gf ocorrer individualmente sobre cada elemento sensor, o sinal óptico transmitido no sistema é resultante da interação da luz com todos os sensores em série.


**Figura 18 – Espectros de transmissão com intensidades relativas detectadas no sistema contendo três sensores conectados em série quando aplicadas forças individuais diretamente sobre cada um dos elementos sensores. (a) Elemento sensor 1. (b) Elemento sensor 2. (c) Elemento sensor 3.**



**Fonte: Autoria própria (2022).**

Em continuidade, a Figura 19 apresenta os espectros de intensidade relativa transmitida do sistema formado por cinco sensores multiplexados em série.

**Figura 19 – Espectros de transmissão com intensidades relativas detectadas no sistema contendo cinco sensores conectados em série quando aplicadas forças individuais diretamente sobre cada um dos elementos sensores. (a) Elemento sensor 1. (b) Elemento sensor 2. (c) Elemento sensor 3. (d) Elemento sensor 4. (e) Elemento sensor 5.**



**Fonte: Autoria própria (2022).**


São verificadas as diferenças entre os espectros de transmissão referentes à operação de cada um dos elementos sensores que formavam os sistemas multiplexados. As dissemelhanças

são inerentes ao método construtivo dos transdutores e estão associadas às pequenas variações de parâmetros de difícil controle experimental como, por exemplo, raio de curvatura da estrutura de anel e ângulo de posicionamento do anel dentro do encapsulamento. O quadro descrito implica que forças semelhantes em sensores distintos geram espectros de transmissão diferentes. Outro ponto refere-se ao aumento da força sobre o mesmo elemento sensor promovendo o aumento da atenuação em quase toda faixa espectral analisada e alterações na forma do espectro. Com base nas respostas apresentadas considera-se que cada elemento sensor pode ser individualizado de acordo com os espectros de transmissão decorrentes da aplicação de forças deformadoras. Percebe-se que não há saturação em termos de atenuação do sinal ótico até a força máxima testada de 2000 gf. Isso indica a possibilidade de expandir ou modificar a faixa dinâmica operacional do sistema sem inviabilizar a completa operação do sistema devido a uma possível saturação da intensidade ótica transmitida a partir de determinada magnitude do estímulo.

#### 4.2 Respostas de repetibilidade dos sistemas sensores

Com base nos três ensaios realizados em sequência em intervalos de 20 minutos, sob as condições apresentadas na subseção 3.2.4, a Figura 20 apresenta as curvas médias de intensidade relativa transmitida por comprimento de onda para cinco configurações de força aplicadas nas matrizes de sensoriamento unidimensional e bidimensional. As barras de erro são desvios padrões experimentais, para alguns comprimentos de onda, das três medições realizadas em condições de repetibilidade.

**Figura 20 – Repetibilidade dos espectros de transmissão associados a cinco configurações de força, apresentadas na Tabela 1 e Tabela 2, aplicadas sobre as duas matrizes de sensoriamento. (a) Resultados matriz de sensoriamento unidimensional. (b) Resultados matriz de sensoriamento bidimensional.**



Fonte: Autoria própria (2022).

Os resultados indicam que não ocorreram alterações significativas entre espectros de transmissão associados a configurações semelhantes, foram mantidas as principais características

de forma das curvas espectrais. Esse comportamento indica possibilidade de identificação da configuração de força a partir dessas respostas desempenhadas pelos sistemas. Para representação das barras de erro foram utilizados 1 a cada 30 comprimentos de onda, dos 1229 comprimentos de onda aferidos. Essa redução foi realizada para facilitar a visualização dos dados. A configuração 2, na matriz de sensoriamento bidimensional, demonstrou menor repetibilidade em comprimentos de onda maiores do que 600 nm. Em vista que naquela faixa espectral foram detectadas também as maiores atenuações relativas nesse ensaio, possivelmente a diferença de repetibilidade está associada a uma relativa maior atenuação naquela faixa. Além disso, para estudo específico a respeito do grau de repetibilidade dos sistemas, devem ser consideradas as propriedades mecânicas das estruturas, que nesse caso eram compostas por materiais distintos. Os resultados da etapa de teste dos modelos implementados informam a respeito de como a repetibilidade afetou o desempenho de monitoração.

### **4.3 Matriz de sensoriamento unidimensional**

O conjunto de dados resultante do ensaio com 72 amostras, correspondente a 60% das configurações possíveis de força dadas a faixa de forças entre 100 gf e 2000 gf em variações de 100 gf, aplicadas individualmente sobre uma das 6 áreas possíveis na matriz de sensoriamento unidimensional, foi utilizado para o treinamento e avaliação dos modelos de regressão baseados em Rede Elástica e Vetores Suporte (linear e polinomial quadrático). Os resultados serão apresentados sequencialmente.

Os modelos de Rede Elástica foram inicializados com 1229 comprimentos de onda para operação em vista que a própria formulação do modelo propicia a redução de dimensionalidade, um dos objetivos do trabalho. Por outro lado, os modelos baseados em Vetores Suporte tiveram dimensionalidade reduzida por técnica de PCA que será comentada anteriormente aos resultados desses modelos.

As análises iniciais foram feitas utilizando os conjuntos de treinamento e validação, que foram coletados no mesmo ensaio. Complementando a análise, o conjunto de teste produzido separadamente, no ensaio com 24 amostras (20% das configurações de força possíveis) foi utilizado para apresentação explícita das predições com o objetivo de avaliar um cenário de real operação dos sistemas.

Os erros de predição de posição da força de todos os modelos se referem a diferença entre o centro da área de aplicação real e o centro da área de aplicação predita. Cabe ressaltar que a distância mínima entre os centros das áreas de aplicação de força é de 5 cm na matriz de sensoriamento unidimensional, tal área circular apresenta raio de 1 cm.

#### 4.3.1 Avaliação dos modelos de Rede Elástica para a matriz de sensoriamento unidimensional

Foi avaliado o desempenho do sistema operando com modelos baseados em Rede Elástica submetidos a variação do parâmetro  $\alpha$ . As Tabelas 3 e 4 apresentam erros de treinamento e de validação utilizando valores de  $\alpha$  entre 0,1 e 0,9, implicando na modificação do número de variáveis características utilizadas pelos modelos. Primeiramente, foram avaliados os desempenhos na predição da posição de aplicação da força, os erros detectados (em cm) são apresentados na Tabela 3.

**Tabela 3 – Erros de predição da posição (cm) da força aplicada na matriz de sensoriamento unidimensional com modelos baseados em Rede Elástica com  $\alpha$  variando entre 0,1 e 0,9.**

| $\alpha$ | Treinamento | Validação | Nº de características |
|----------|-------------|-----------|-----------------------|
| 0,1      | 2,52        | 2,84      | 103                   |
| 0,2      | 2,60        | 2,94      | 72                    |
| 0,3      | 2,58        | 2,93      | 52                    |
| 0,4      | 2,58        | 2,93      | 41                    |
| 0,5      | 2,57        | 2,92      | 39                    |
| 0,6      | 2,57        | 2,91      | 34                    |
| 0,7      | 2,56        | 2,90      | 28                    |
| 0,8      | 2,61        | 2,95      | 21                    |
| 0,9      | 2,55        | 2,90      | 15                    |

**Fonte: Autoria própria (2022).**

Nessa avaliação foi detectado que a média dos erros de validação, 2,91 cm, foi 0,34 cm maior do que a média dos erros de treinamento, 2,57 cm, esse valor representa aproximadamente 11% do erro de validação médio.

Na continuidade foi avaliado o desempenho dos modelos para predição da magnitude da força individual monitorada. Esses resultados constam na Tabela 4.

**Tabela 4 – Erros de predição da magnitude (gf) da força aplicada na matriz de sensoriamento unidimensional com modelos baseados em Rede Elástica com  $\alpha$  variando entre 0,1 e 0,9.**

| $\alpha$ | Treinamento | Validação | Nº de características |
|----------|-------------|-----------|-----------------------|
| 0,1      | 206         | 198       | 130                   |
| 0,2      | 196         | 193       | 96                    |
| 0,3      | 202         | 192       | 69                    |
| 0,4      | 198         | 192       | 55                    |
| 0,5      | 195         | 191       | 43                    |
| 0,6      | 193         | 192       | 35                    |
| 0,7      | 191         | 194       | 30                    |
| 0,8      | 190         | 195       | 24                    |
| 0,9      | 189         | 196       | 22                    |

**Fonte: Autoria própria (2022).**

A média dos erros de validação foi de 193 gf, enquanto a de treinamento foi de 196 gf. A diferença entre esses valores, de 3 gf, equivale a menos de 2% do erro de validação médio. Alguns


dos modelos apresentaram erros de validação ligeiramente inferiores aos erros no conjunto de treinamento. Em média a diferença desses erros não foi significativa. Mesmo com o sistema operando com apenas 22 coeficientes de regressão não nulos foi detectado erro de monitoração inferior a 200 gf.

Como esperado para ambos os resultados, conforme há o aumento do valor  $\alpha$  mais coeficientes são zerados e menor o número de características utilizadas para treinamento. Alguns modelos com valores relativamente mais altos de  $\alpha$  apresentaram desempenhos melhores em termos de médias de erros absolutos em relação a modelos com  $\alpha$  menores. Por exemplo, o modelo de predição de magnitude com  $\alpha = 0,5$ , apresentou erro de validação de 191 gf, enquanto modelos que operavam com mais variáveis características (com  $\alpha < 0,5$ ) apresentaram erros entre 192 gf e 198 gf. Uma possível interpretação é de que a redução de coeficientes de regressão contribuiu para esse quadro ao anular comprimentos de onda que prejudicavam as predições. De modo geral esse efeito foi pouco significativo.

No conjunto de validação os erros de predição da posição da força com os modelos de Rede Elástica variaram entre 2,84 cm e 2,95 cm. Em termos de MAE, a piora de desempenho de validação em relação ao de treinamento foi em média de 13,4%. Entende-se que esse resultado não indica sobreajuste dos modelos. Quanto aos erros de predição da magnitude da força monitorada tem-se que os erros de validação variaram entre 191 gf e 198 gf. As diferenças percentuais entre os desempenhos de treinamento e validação variaram entre -3,5% (onde o desempenho de validação foi melhor do que o de treinamento) e 3,5%, também indicando um ajuste adequado para os modelos.

Destaca-se a grande capacidade de redução de características que o modelo baseado em Rede Elástica possibilitou, isso fica evidente em modelos com  $\alpha = 0,9$  que operaram com apenas 15 e 22 coeficientes de regressão não nulos, indicando a possibilidade de interrogação de sistemas baseados em macrocurvatura em um relativo baixo número de comprimentos de onda. A Figura 21 apresenta os módulos dos coeficientes de regressão, dos modelos com  $\alpha = 0,9$ , associados a cada comprimento de onda da faixa espectral entre 400 nm e 720 nm. Essa análise visa sugerir as regiões espectrais e os fenômenos de atenuação mais relevantes para operação dos sensores.

**Figura 21 – Módulos dos coeficientes de regressão por comprimento de onda resultantes dos modelos de Rede Elástica com  $\alpha = 0,9$  aplicados na matriz de sensoriamento unidimensional. (a) Modelo de predição da posição da força. (b) Modelo de predição da magnitude força.**




**Fonte: Autoria própria (2022).**

Tanto o modelo de predição de posição quanto o de magnitude de força apresentaram coeficientes de regressão não nulos com relativos altos valores próximos ao comprimento de onda de 575 nm, outra semelhança é que há poucos desses coeficientes em comprimentos de onda maiores de que 600 nm. Grande parte dos comprimentos de onda importantes para os modelos estão nas faixas espectrais (400-500) nm e (550-600) nm, o que fica evidente no modelo de predição de magnitude da força. Considerando os fenômenos físicos responsáveis pela modulação do sinal, os resultados apresentados evidenciam que para operação dos modelos baseados em Rede Elástica, os efeitos de ressonâncias de WGM são tão relevantes quanto as Perdas por Curvatura que promovem as maiores alterações nos espectros de transmissão.

Para apresentação explícita de predições, foi selecionado o modelo com  $\alpha = 0,9$  devido ao potencial de redução de variáveis preditivas. O tempo de treinamento do modelo foi de 9,4 segundos. Com esse modelo, os erros absolutos médios no conjunto de teste foram de 2,45 cm e 177 gf, para predição da posição e da magnitude da força, respectivamente. A Figura 22 representa predições e alvos referentes a 5 configurações de forças do conjunto de teste selecionadas aleatoriamente, nessa representação o eixo vertical está associado a magnitude da força e o eixo horizontal a posição da força monitorada.

**Figura 22 – Predições do modelo baseado em Rede Elástica e alvos associados a cinco configurações de força aplicadas na matriz de sensoriamento unidimensional.**




**Fonte: Autoria própria (2022).**

A representação apresentada evidencia os erros preditivos em relação ao comprimento total da estrutura e faixa dinâmica monitorada. Entre as cinco configurações selecionadas foi constatado um erro relativamente grande na Configuração 4 quanto a predição da magnitude da força. De modo geral, o resultado exhibe que o sistema foi capaz de monitorar a força individual aplicada na estrutura.

#### 4.3.2 Análise de Componentes Principais para a matriz de sensoriamento unidimensional

Dando continuidade à avaliação, utilizando as 72 amostras do conjunto de dados voltado a treinamento e validação do sistema acoplado a matriz unidimensional, foi implementada a técnica de redução de dimensionalidade por Análise de Componentes Principais. Para isso, primeiramente foi avaliada a variabilidade explicada pelas primeiras componentes principais. A Figura 23 apresenta a variabilidade cumulativa explicada pelas 71 primeiras componentes principais que juntas explicam aproximadamente 100% da variabilidade dos dados. Destaca-se que as cinco primeiras componentes foram capazes de explicar aproximadamente 90% da variabilidade total dos dados de entrada.

**Figura 23 – Variabilidade cumulativa explicada por componentes principais para matriz de sensoriamento unidimensional.**



**Fonte: Autoria própria (2022).**

A partir da quinta componente principal foi considerado que a contribuição de variabilidade explicada era relativamente baixa. Os modelos de regressão baseados em Vetores Suporte foram treinados a partir de dados reduzidos pela PCA para entre 1 e 5 componentes principais explicativas.

#### 4.3.3 Avaliação dos modelos SVR lineares para a matriz de sensoriamento unidimensional

O conjunto de dados referente ao ensaio com matriz de sensoriamento unidimensional foi utilizado para implementação de modelos baseados em regressão por Vetores Suporte. Na sequência serão apresentados resultados referentes aos modelos treinados com kernel linear. Primeiramente, o modelo foi implementado sem redução de dimensionalidade, ou seja, com as 1229 variáveis características de entrada associadas aos comprimentos de onda na faixa espectral utilizada. Os resultados preliminares com esses parâmetros são apresentados na Tabela 5 tanto para predição de posição quanto de magnitude da força monitorada.

**Tabela 5 – Erros de predição na matriz de sensoriamento unidimensional com modelos baseados em SVR linear sem redução de dimensionalidade.**

| Modelo         | Treinamento | Validação |
|----------------|-------------|-----------|
| Posição (cm)   | 1,10        | 1,60      |
| Magnitude (gf) | 84          | 165       |

**Fonte: Autoria própria (2022).**

Devido ao número de variáveis de entrada muito maior do que amostras, como esperado, o modelo apresentou um quadro de sobreajuste, evidenciado por resultados de treinamento muito melhores do que resultados de validação. Isso demonstra que o modelo não apresentou capacidade de generalização e tornou-se específico para os dados de treinamento. Esse cenário proporcionou conveniência para técnica de redução de dimensionalidade, promovendo tanto vantagens computacionais de processamento quanto em termos de ajuste, diminuindo a quantidade de informação para o treinamento do modelo.

Os resultados a seguir apresentam erros de treinamento e validação detectados com modelos implementados usando de 1 a 5 componentes principais decorrentes da PCA. Primeiramente, a Tabela 6 apresenta resultados de monitoração da posição da força.

**Tabela 6 – Erros de predição de posição (cm) da força aplicada na matriz de sensoriamento unidimensional com modelos baseados em SVR lineares usando de 1 a 5 componentes principais.**

| Nº de componentes principais | Treinamento | Validação |
|------------------------------|-------------|-----------|
| 1                            | 3,91        | 3,96      |
| 2                            | 3,72        | 3,60      |
| 3                            | 3,53        | 3,69      |
| 4                            | 3,00        | 2,60      |
| 5                            | 2,81        | 2,19      |

**Fonte: Autoria própria (2022).**

Para 3 dos 5 modelos avaliados os erros de validação foram inferiores aos erros de treinamento, em média ocorreu aprimoramento de desempenho no conjunto de validação. Como esperado, com o maior número de componentes principais foram detectados os menores erros de predição.

Em continuidade foram implementados modelos voltados a predição da magnitude da força aplicada na estrutura. Os resultados de modelos usando de 1 a 5 componentes principais são apresentados na Tabela 7.

**Tabela 7 – Erros de predição da magnitude (gf) da força aplicada na matriz de sensoriamento unidimensional com modelos baseados em SVR lineares usando de 1 a 5 componentes principais.**

| Nº de componentes principais | Treinamento | Validação |
|------------------------------|-------------|-----------|
| 1                            | 393         | 291       |
| 2                            | 362         | 205       |
| 3                            | 357         | 202       |
| 4                            | 358         | 203       |
| 5                            | 328         | 182       |


**Fonte: Autoria própria (2022).**

Semelhantemente aos modelos de predição da posição da força, os resultados apresentados demonstram melhoria de desempenho de validação em relação aos desempenhos de testes.

Esse quadro pode estar associado às dificuldades relativas das amostras selecionadas para validação e treinamento. A utilização de cinco componentes principais para o modelo implicou nos mais baixos erros avaliados.

Para apresentação explícita de previsões, para ambos os modelos foram selecionadas implementações com 5 componentes principais. O tempo de treinamento desse modelo foi de 1,3 segundo. Os erros médios detectados nas amostras de testes foram de 2,41 cm e 329 gf, para os modelos de predição de posição e de magnitude da força, respectivamente. A Figura 24 apresenta os alvos e previsões para 5 configurações de força selecionadas aleatoriamente.

**Figura 24 – Previsões do modelo baseado em Vetores Suporte de kernel linear com 5 componentes principais e alvos associados a cinco configurações de força do conjunto de teste.**



**Fonte: Autoria própria (2022).**

#### 4.3.4 Avaliação dos modelos SVR polinomiais quadráticos para matriz de sensoriamento unidimensional

Preliminarmente foi avaliado o modelo operando com variáveis características associadas a 1229 comprimentos de onda, ou seja, com o modelo sem redução de dimensionalidade. A Tabela 8 explicita os erros de predição em termos de médias de erros absolutos para predição da posição e da magnitude de força monitorada. Nessa análise constam os resultados do modelo predizendo respostas para os dados de treinamento e validação.

**Tabela 8 – Erros de predição na matriz de sensoriamento unidimensional com modelos baseados em SVR quadrática sem redução de dimensionalidade.**

|                | <b>Treinamento</b> | <b>Validação</b> |
|----------------|--------------------|------------------|
| Posição (cm)   | 1,00               | 0,91             |
| Magnitude (gf) | 71                 | 95               |

**Fonte: Autoria própria (2022).**

Dando continuidade a análise foram implementados modelos de predição operando com dimensionalidade reduzida pela PCA, usando de 1 a 5 componentes principais. A Tabela 9 apresenta os erros de predição detectados para o modelo de predição da posição da força.

**Tabela 9 – Erros de predição da posição (cm) da força aplicada na matriz de sensoriamento unidimensional com modelos baseados em SVR quadráticos usando de 1 a 5 componentes principais.**

| <b>Nº de componentes principais</b> | <b>Treinamento</b> | <b>Validação</b> |
|-------------------------------------|--------------------|------------------|
| 1                                   | 3,43               | 3,50             |
| 2                                   | 2,95               | 1,95             |
| 3                                   | 2,48               | 2,36             |
| 4                                   | 0,94               | 1,04             |
| 5                                   | 1,26               | 1,33             |

**Fonte: Autoria própria (2022).**

Semelhantemente, foram implementados os modelos de predição da magnitude da força. Os resultados são apresentados na Tabela 10.


**Tabela 10 – Erros de predição da magnitude (gf) da força aplicada na matriz de sensoriamento unidimensional com modelos baseados em SVR quadráticos usando de 1 a 5 componentes principais.**

| <b>Nº de componentes principais</b> | <b>Treinamento</b> | <b>Validação</b> |
|-------------------------------------|--------------------|------------------|
| 1                                   | 384                | 309              |
| 2                                   | 288                | 180              |
| 3                                   | 245                | 139              |
| 4                                   | 221                | 197              |
| 5                                   | 230                | 140              |

**Fonte: Autoria própria (2022).**

Os resultados apresentados evidenciam melhoria de desempenho em relação aos modelos lineares apresentados na seção anterior. Os modelos selecionados para análise explícita de predições foram implementados com 4 componentes principais. O tempo de treinamento total dos modelos complementares foi de 29,9 segundos. No conjunto de teste esses modelos apresentaram erros médios de 2,41 cm e 271 gf para predição de posição e magnitude da força, respectivamente. Dentre as 21 amostras de teste foram aleatoriamente selecionadas 5 configurações de força para apresentação dos alvos e predições na Figura 25.

**Figura 25 – Predições do modelo baseado em Vetores Suporte de kernel quadrático com 4 componentes principais e alvos associados a cinco configurações de força aplicadas na matriz de sensoriamento unidimensional.**



**Fonte: Autoria própria (2022).**

#### 4.4 Matriz de sensoriamento bidimensional

O conjunto de dados resultante do ensaio com 108 amostras, correspondente a 60% das configurações possíveis de força dadas a faixa de forças entre 100 gf e 2000 gf em variações de 100 gf, aplicadas individualmente sobre uma das 9 áreas possíveis na matriz de sensoriamento bidimensional foi utilizado para implementação de modelos de regressão. Os resultados são apresentados na sequência. Novamente, os modelos foram avaliados preliminarmente nos conjuntos de treinamento e validação, em continuidade, para avaliação explícita das previsões foi utilizado o conjunto de dados de teste coletado separadamente.

Por se tratar de um sistema bidimensional, os resultados apresentados serão referentes à estimativa de posição em dois eixos perpendiculares (x e y), que juntos determinam a posição predita, além da magnitude da força. Outra diferença em relação aos resultados apresentados anteriormente se refere as representações das previsões explícitas, as previsões de posição e de magnitude da força serão feitas individualmente.

Os erros apresentados se referem a distância entre o centro das áreas de aplicação real e centro da área de aplicação predita. A distância mínima entre duas áreas nessa matriz foi de 6,6 cm e o raio da área circular de aplicação de força é de 1 cm.

#### 4.4.1 Avaliação dos modelos de Rede Elástica para matriz de sensoriamento bidimensional

Primeiramente apresenta-se os resultados de modelos referentes à determinação das posições centrais da área de aplicação de força, a resposta em dois eixos configura a posição de aplicação predita. Os resultados que constam na Tabela 11 são erros de predição de modelos baseados em Rede Elástica com o parâmetro  $\alpha$  variando entre 0,1 e 0,9.

**Tabela 11 – Erros de predição de posições (cm) da força aplicada na matriz de sensoriamento bidimensional com modelos baseados em Rede Elástica com  $\alpha$  variando entre 0,1 e 0,9.**

| $\alpha$ | Posição x   |           |                       | Posição y   |           |                       |
|----------|-------------|-----------|-----------------------|-------------|-----------|-----------------------|
|          | Treinamento | Validação | Nº de características | Treinamento | Validação | Nº de características |
| 0,1      | 2,58        | 2,99      | 100                   | 2,45        | 3,06      | 113                   |
| 0,2      | 2,74        | 3,02      | 72                    | 2,48        | 3,09      | 74                    |
| 0,3      | 2,6         | 2,99      | 65                    | 2,54        | 3,15      | 51                    |
| 0,4      | 2,58        | 2,99      | 50                    | 2,52        | 3,13      | 47                    |
| 0,5      | 2,57        | 2,99      | 47                    | 2,50        | 3,12      | 40                    |
| 0,6      | 2,56        | 2,99      | 39                    | 2,49        | 3,11      | 32                    |
| 0,7      | 2,44        | 2,96      | 33                    | 2,57        | 3,16      | 27                    |
| 0,8      | 2,43        | 2,96      | 28                    | 2,56        | 3,16      | 23                    |
| 0,9      | 2,42        | 2,96      | 21                    | 2,55        | 3,16      | 18                    |

**Fonte: Autoria própria (2022).**

Para estimativa da posição no eixo x, a média dos erros de treinamento nesse ensaio foi de 2,55 cm enquanto a média de erros de validação foi de 2,98 cm, representando uma piora de desempenho de 0,43 cm, equivalente a cerca de 15% em relação ao erro de validação. Quanto a estimativa de posição predita no eixo y a piora de desempenho médio foi de cerca de 0,60 cm, ou 19% da média dos erros de validação. Destaca-se a grande capacidade de redução de variáveis características dos modelos, que por exemplo com valor de  $\alpha$  igual a 0,9 foi capaz de operar com 21 e 18 coeficientes de regressão não nulos.

Dando continuidade a avaliação do modelo de Rede Elástica para monitoração da força na matriz de sensoriamento bidimensional, foram avaliados modelos de predição da magnitude da força. Os resultados constam na Tabela 12.

**Tabela 12 – Erros de predição da magnitude (gf) da força aplicada na matriz de sensoriamento bidimensional com modelos baseados em Rede Elástica com  $\alpha$  variando entre 0.1 e 0.9.**


| $\alpha$ | Treinamento | Validação | Nº de características |
|----------|-------------|-----------|-----------------------|
| 0,1      | 195         | 336       | 110                   |
| 0,2      | 191         | 338       | 80                    |
| 0,3      | 195         | 343       | 67                    |
| 0,4      | 193         | 345       | 54                    |
| 0,5      | 193         | 345       | 41                    |
| 0,6      | 197         | 350       | 39                    |
| 0,7      | 197         | 350       | 32                    |
| 0,8      | 197         | 350       | 27                    |
| 0,9      | 191         | 346       | 23                    |

**Fonte: Autoria própria (2022).**

Os resultados apresentam diferença de desempenho de treinamento e validação, em média o erro de validação foi de 344 gf, enquanto o de treinamento foi de 194 gf. Tal diferença corresponde a aproximadamente 44% do erro médio de validação. Nesse sentido cabe ressaltar que todos os modelos passaram por validação cruzada, sendo implementados modelos com  $\lambda$  de desempenho associado ao menor MSE mais um desvio padrão.

Como comentado os modelos apresentaram capacidade significativa de redução de variáveis características, a Figura 26 apresenta os módulos dos coeficientes de regressão associados a cada comprimento de onda para os três modelos de predição com  $\alpha$  igual a 0,9.

**Figura 26 – Módulos dos coeficientes de regressão por comprimento de onda resultantes dos modelos de Rede Elástica com  $\alpha = 0,9$  aplicados na matriz de sensoriamento bidimensional. (a) Modelo de predição da posição em x da força. (b) Modelo de predição da posição em y da força. (c) Modelo de predição da magnitude da força.**




**Fonte: Autoria própria (2022).**

Os resultados apresentados evidenciam apenas coeficientes de regressão nulos em comprimentos de onda maiores do que 650 nm, nesse sentido também se nota que apenas o modelo de predição de magnitude de força utilizou alguns comprimentos de onda maiores do que 600 nm. De modo geral os comprimentos de onda mais significativos estão nas faixas espectrais (400-500) nm e (550-600) nm. Constata-se novamente a importância dos efeitos de ressonâncias de WGM para operação dos modelos baseados em Rede Elástica.

Para apresentação explícita de predições, foi selecionado o modelo com  $\alpha = 0,9$  devido ao potencial de redução de variáveis preditivas. Com esse modelo, treinado em 20,5 segundos, os erros no conjunto de teste foram de 2,95 cm, 3,06 cm e 254 gf, para predição da posição x, posição y e da magnitude da força, respectivamente. Nota-se que na etapa de teste o modelo de predição da magnitude da força (com  $\alpha = 0,9$ ) apresentou menor erro em relação a etapa validação com o mesmo modelo. A diferença entre esses erros foi de 92 gf. A Figura 27a

apresenta exclusivamente as predições de posição enquanto a Figura 27b a magnitude de força para as cinco configurações de força aleatoriamente selecionadas.

**Figura 27 – Predições do modelo baseado em Rede Elástica e alvos associados a cinco configurações de força aplicadas na matriz de sensoriamento bidimensional. (a) Predições e alvos para monitoração da posição da força. (b) Predições e alvos para monitoração da magnitude da força.**




Fonte: Autoria própria (2022).

#### 4.4.2 Análise de componentes principais para matriz de sensoriamento bidimensional

Para implementação dos modelos baseados em Vetores Suportes foi utilizada técnica de redução de dimensionalidade por componentes principais a partir do conjunto de dados de treinamento e validação com 108 amostras elaborado para avaliação do sistema acoplado a matriz bidimensional. A variabilidade cumulativa explicada pelas componentes principais é apresentada na Figura 28. Destaca-se as 11 primeiras componentes principais que juntas explicavam cerca de 90% da variabilidade dos dados e, portanto, foram utilizadas para avaliação dos modelos.

**Figura 28 – Variabilidade cumulativa explicada por componentes principais para matriz de sensoriamento bidimensional.**



**Fonte: Autoria própria (2022).**

#### 4.4.3 Avaliação dos modelos SVR lineares para matriz de sensoriamento bidimensional

Preliminarmente foram implementados modelos utilizando intensidades relativas em 1229 comprimentos de onda como variáveis características. Os resultados são apresentados na Tabela 13.

**Tabela 13 – Erros de predição na matriz de sensoriamento bidimensional com modelos baseados em SVR linear sem redução de dimensionalidade.**

|                | Treinamento | Validação |
|----------------|-------------|-----------|
| Posição x (cm) | 1,07        | 2,91      |
| Posição y (cm) | 1,19        | 3,11      |
| Magnitude (gf) | 83          | 278       |

**Fonte: Autoria própria (2022).**

Como esperado, os erros de validação detectados foram muito maiores do que os de treinamento, indicando sobreajuste. Esse quadro possivelmente está associado ao número de variáveis em relação ao de amostras, tornando o modelo muito específico para os dados de treinamento.

Dando continuidade, foram implementados modelos com dimensionalidade reduzida pela PCA. Os modelos foram treinados usando de 1 a 11 componentes principais, os resultados de treinamento e validação constam na Tabela 14 para os modelos de predição em dois eixos da estrutura.

**Tabela 14 – Erros de predição das posições (cm) da força aplicada na matriz de sensoriamento bidimensional com modelos baseados em SVR lineares usando de 1 a 11 componentes principais.**

| Nº de componentes principais | Posição x   |           | Posição y   |           |
|------------------------------|-------------|-----------|-------------|-----------|
|                              | Treinamento | Validação | Treinamento | Validação |
| 1                            | 4,42        | 3,37      | 4,64        | 5,22      |
| 2                            | 3,70        | 4,08      | 4,62        | 4,57      |
| 3                            | 3,68        | 4,08      | 4,11        | 5,04      |
| 4                            | 3,53        | 3,94      | 3,76        | 4,00      |
| 5                            | 2,70        | 3,12      | 3,50        | 4,04      |
| 6                            | 2,68        | 3,32      | 3,38        | 4,03      |
| 7                            | 2,68        | 3,54      | 3,29        | 4,07      |
| 8                            | 2,64        | 3,44      | 3,23        | 3,60      |
| 9                            | 2,50        | 3,01      | 2,68        | 3,50      |
| 10                           | 2,32        | 2,80      | 2,64        | 3,58      |
| 11                           | 2,32        | 3,16      | 2,61        | 3,47      |

**Fonte: Autoria própria (2022).**

Em média a piora de desempenho de validação representou 17% e 19% dos erros médios de validação para predição de posição no eixo x e y, respectivamente. Os menores erros de validação detectados foram com modelos treinados com 10 e 11 componentes principais de acordo com o eixo de predição, com esses parâmetros as diferenças percentuais de desempenho de treinamento e validação foram de 21% e 33%, respectivamente.

Na sequência foram implementados modelos voltados a predição da magnitude da força monitorada. Os resultados constam na Tabela 15.

**Tabela 15 – Erros de predição da magnitude (gf) da força aplicada na matriz de sensoriamento bidimensional com modelos baseados em SVR lineares usando de 1 a 11 componentes principais.**

| Nº de componentes principais | Treinamento | Validação |
|------------------------------|-------------|-----------|
| 1                            | 330         | 449       |
| 2                            | 319         | 410       |
| 3                            | 318         | 390       |
| 4                            | 283         | 365       |
| 5                            | 277         | 336       |
| 6                            | 276         | 368       |
| 7                            | 248         | 400       |
| 8                            | 244         | 376       |
| 9                            | 240         | 349       |
| 10                           | 208         | 336       |
| 11                           | 204         | 242       |


**Fonte: Autoria própria (2022).**

Entre os modelos apresentados o menor erro de validação foi detectado com 11 componentes principais. Esse modelo apresentou diferença percentual de treinamento e validação equivalente a cerca de 18% do erro de validação.

Para continuidade da avaliação com o modelo SVR linear aplicado ao sistema da matriz de sensoriamento bidimensional, foram selecionados os modelos treinados a partir de 11 componentes principais, para predição da posição no eixo x, posição no eixo y e magnitude da força, o tempo de treinamento desses modelos foi de 2,8 segundos. A seleção do número de componentes principais utilizado foi feita com base nos erros de validação e diferença percentual entre erro de treinamento e validação e teve objetivo de selecionar modelos com ajustes adequados. Os erros médios de predição no conjunto de teste foram de 2,84 cm, 4,10 cm e 282 gf para monitoração da posição no eixo x, posição no eixo y e magnitude da força, respectivamente.

A Figura 29 apresenta predições e alvos de 5 configurações de força em regiões distintas selecionadas aleatoriamente no conjunto de teste.

**Figura 29 – Predições do modelo baseado em Vetores Suporte de kernel linear com 11 componentes principais e alvos associados a cinco configurações de força aplicadas na matriz de sensoriamento bidimensional. (a) Predições e alvos para monitoração da posição da força. (b) Predições e alvos para monitoração da magnitude da força.**



Fonte: Autoria própria (2022).

Em vista que a estrutura foi dividida em 9 regiões de monitoração, as predições mostram que apesar de erros quanto a área exata de aplicação de força o sistema pode identificar as regiões aproximadas de aplicação, portanto, foi verificada capacidade de monitoração da posição de aplicação e da magnitude da força com o modelo linear baseado em SVR.

#### 4.4.4 Avaliação dos modelos SVR polinomiais quadráticos para matriz de sensoriamento bidimensional

O modelo de regressão baseado em SVR foi implementado com kernel polinomial quadrático para predição das posições e magnitude da força na estrutura avaliada em duas dimensões de monitoração. A alteração para o kernel relativamente mais complexo em relação ao linear foi feita com o objetivo de avaliar a capacidade de operação com número de componentes principais menor além da possibilidade de redução de erros preditivos. Como análise de resultados

preliminar, é apresentado na Tabela 16, os erros de monitoração com dados de entrada sem redução de dimensionalidade.

**Tabela 16 – Erros de predição na matriz de sensoriamento bidimensional com modelos baseados em SVR quadrática sem redução de dimensionalidade.**

|                | <b>Treinamento</b> | <b>Validação</b> |
|----------------|--------------------|------------------|
| Posição x (cm) | 0,91               | 2,80             |
| Posição y (cm) | 1,12               | 2,45             |
| Magnitude (gf) | 83                 | 270              |

**Fonte: Autoria própria (2022).**

As piores dos desempenhos na etapa de validação evidenciam a necessidade de redução de complexidade do modelo que operou com 1229 variáveis características de entrada. Com isso, na sequência foram avaliados modelos com dimensionalidade reduzida por PCA para entre 1 e 11 componentes principais. Os resultados da implementação para predição das posições de aplicação de força são apresentados na Tabela 17.

**Tabela 17 – Erros de predição das posições (cm) da força aplicada na matriz de sensoriamento bidimensional com modelos baseados em SVR quadráticos usando de 1 a 11 componentes principais.**

|                                     | <b>Posição x</b>   |                  | <b>Posição y</b>   |                  |
|-------------------------------------|--------------------|------------------|--------------------|------------------|
| <b>Nº de componentes principais</b> | <b>Treinamento</b> | <b>Validação</b> | <b>Treinamento</b> | <b>Validação</b> |
| 1                                   | 4,51               | 3,52             | 4,33               | 5,18             |
| 2                                   | 3,53               | 4,87             | 3,84               | 4,51             |
| 3                                   | 2,97               | 4,06             | 3,45               | 3,84             |
| 4                                   | 2,79               | 4,39             | 2,70               | 2,97             |
| 5                                   | 2,10               | 3,36             | 2,18               | 4,05             |
| 6                                   | 2,08               | 3,71             | 1,89               | 3,51             |
| 7                                   | 1,72               | 3,72             | 1,81               | 4,91             |
| 8                                   | 1,80               | 6,83             | 1,80               | 4,39             |
| 9                                   | 1,76               | 3,71             | 1,91               | 5,80             |
| 10                                  | 1,80               | 6,53             | 2,29               | 13,50            |
| 11                                  | 1,79               | 15,78            | 1,98               | 11,59            |

**Fonte: Autoria própria (2022).**

Os resultados evidenciam tendência de sobreajuste dos modelos operando com mais de 4 componentes principais. Os modelos com mais de 4 componentes principais apresentaram em média 240% de piora de desempenho em relação aos erros de validação, enquanto modelos com até 4 componentes principais apresentaram em média 21%. Esse tipo de resultado está associado a quantidade de informação que os modelos operaram definindo a capacidade de generalização dos mesmos.

Na sequência foram implementados modelos voltados a predição da magnitude da força monitorada, os resultados obtidos são apresentados na Tabela 18.

**Tabela 18 – Erros de predição da magnitude (gf) da força aplicada na matriz de sensoriamento bidimensional com modelos baseados em SVR quadráticos usando de 1 a 11 componentes principais.**


| Nº de componentes principais | Treinamento | Validação |
|------------------------------|-------------|-----------|
| 1                            | 311         | 406       |
| 2                            | 247         | 310       |
| 3                            | 219         | 310       |
| 4                            | 283         | 276       |
| 5                            | 230         | 378       |
| 6                            | 211         | 435       |
| 7                            | 195         | 466       |
| 8                            | 201         | 538       |
| 9                            | 135         | 382       |
| 10                           | 128         | 455       |
| 11                           | 108         | 245       |

**Fonte: Autoria própria (2022).**

Semelhantemente aos modelos de predição de posição, foi detectado grande piora de desempenho de validação para modelos treinados com mais de 4 componentes principais. Em média os erros aumentaram 148% em relação aos erros de validação para modelos operando com mais de 4 componentes principais e 23% com modelos de até 4 componentes principais.

Para predições explícitas foram selecionados os modelos com 4 componentes principais para os modelos de predição de posição em x, posição em y e magnitude da força. O tempo de treinamento dos modelos foi de 63,3 segundos. Em média os erros de predição no conjunto de teste foram de 3,28 cm, 3,90 cm e 397 gf nas estimativas de posição no eixo x, posição no eixo y e magnitude da força, respectivamente. As predições e alvos de cinco configurações de força em regiões distintas selecionadas aleatoriamente constam na Figura 30.

**Figura 30 – Predições do modelo baseado em Vetores Suporte de kernel quadrático com 4 componentes principais e alvos associados a cinco configurações de força aplicadas na matriz de sensoriamento bidimensional. (a) Predições e alvos para monitoração da posição da força. (b) Predições e alvos para monitoração da magnitude da força.**



**Fonte: Autoria própria (2022).**

#### 4.5 Resultados da operação de sensoriamento

Nessa seção serão apresentados os resultados de sensoriamento decorrentes da operação dos sistemas sensores ao monitorar forças individuais aplicadas sobre as matrizes rígidas. Essa apresentação tem como objetivo a comparação de desempenho entre modelos considerando tanto os erros preditivos quanto o número de variáveis preditivas utilizadas, com isso serão selecionados os modelos para análise individual de amostras de teste, fundamentando a avaliação da operação efetiva de sensoriamento. Será debatido como os erros preditivos detectados influenciam na operação dos sistemas, as considerações feitas serão baseadas nas dimensões das estruturas, separações mínimas entre áreas de aplicação de força, passos de magnitude de forças e magnitude máxima de força avaliada. Por constarem os resultados de teste, foram selecionados os modelos que passaram por essa etapa, especificando o valor do parâmetro  $\alpha$  para modelos baseados em Rede Elástica, e o número de componentes principais para modelos baseados em Regressão por Vetores Suporte.

A matriz de sensoriamento unidimensional possui seis áreas de aplicação de força. Os centros de áreas consecutivas estão distantes em 5 cm. Os resultados apresentados na Tabela 19, se referem a desempenhos obtidos com os modelos de Rede Elástica operando com  $\alpha = 0,9$ , e com os modelos baseados em Regressão por Vetores Suportes operando com 5 e 4 componentes principais, que explicam cumulativamente, menos de 90% da variabilidade dos dados de treinamento.


**Tabela 19 – Erros preditivos (cm) de modelos implementados para detecção da posição de aplicação da força sobre a matriz de sensoriamento unidimensional.**

| Modelo         | Treinamento | Validação | Teste | Nº de coeficientes de regressão $\neq 0$ | Nº de componentes principais |
|----------------|-------------|-----------|-------|------------------------------------------|------------------------------|
| Rede Elástica  | 2,55        | 2,90      | 2,45  | 15                                       | x                            |
| SVR linear     | 2,81        | 2,19      | 2,41  | x                                        | 5                            |
| SVR quadrática | 0,94        | 1,04      | 2,41  | x                                        | 4                            |

**Fonte: Autoria própria (2022).**

Para os modelos apresentados, os erros médios absolutos de monitoração da posição da força na etapa de teste variaram entre 2,41 cm e 2,45 cm. Tais erros correspondem a 8,0% e 8,2% do comprimento total da estrutura no eixo analisado, 30 cm. Avaliando o sistema quanto à capacidade de sensoriamento, em vista que os centros das áreas consecutivas estavam distantes em 5 cm na estrutura, considera-se que em média o sistema aponta a posição central de aplicação de força mais próxima à real do que a qualquer outra. Para avaliar a operação objetivamente, a Figura 31 exhibe os erros detectados para cada amostra do conjunto de teste da estrutura unidimensional, com a demodulação realizada com o modelo baseado em Vetores Suporte com 5 componentes principais.

**Figura 31 – Erros de sensoriamento da posição da força em amostras de teste para o sistema sensor acoplado a matriz unidimensional.**



**Fonte: Autoria própria (2022).**

A maioria das amostras está próxima a linha de erro nulo. Entretanto, são verificadas três amostras que apresentam erros absolutos superiores a 5 cm. Dando continuidade, é realizada uma análise que visa avaliar a confiabilidade da operação de sensoriamento. Para isso, considera-se cada posição de aplicação de força da estrutura associada a uma área, assim a matriz de 30 cm é entendida composta por 6 regiões quadradas de lados de 5 cm. Nesse cenário, tendo como proposta de sensoriamento monitorar a região de aplicação da força, detecta-se que 71% das amostras são classificadas corretamente.

A Tabela 20 apresenta resultados de monitoração da magnitude da força aplicada sobre a matriz unidimensional. As magnitudes utilizadas nos ensaios variaram de 100 gf a 2000 gf em passos de 100 gf.


**Tabela 20 – Erros preditivos (gf) de modelos implementados para detecção da magnitude da força sobre a matriz de sensoriamento unidimensional.**

| Modelo         | Treinamento | Validação | Teste | Nº de coeficientes de regressão $\neq 0$ | Nº de componentes principais |
|----------------|-------------|-----------|-------|------------------------------------------|------------------------------|
| Rede Elástica  | 189         | 196       | 177   | 22                                       | x                            |
| SVR linear     | 328         | 182       | 329   | x                                        | 5                            |
| SVR quadrática | 221         | 197       | 271   | x                                        | 4                            |

**Fonte: Autoria própria (2022).**

Quanto à predição da magnitude da força, na etapa de teste, os erros médios absolutos variaram entre 177 gf e 329 gf, correspondentes a 8,8% e 16,4% da magnitude de força máxima testada de 2000 gf. A Figura 32 apresenta o erro associado a cada amostra do conjunto de teste, tal resultado foi obtido com o modelo baseado em Rede Elástica com  $\alpha = 0,9$ .

**Figura 32 – Erros de sensoriamento da magnitude da força em amostras de teste para o sistema sensor acoplado a matriz unidimensional.**



**Fonte: Autoria própria (2022).**

A variação de magnitude de forças utilizadas nos ensaios experimentais foi de 100 gf, o sistema não foi capaz de identificar variações dessa ordem. Destaca-se que entre as 27 amostras de teste que simulavam a operação efetiva do sistema, 3 tiveram erro absoluto superior a 300 gf. Tal resultado, sugere que ao operar com resolução de 300 gf, o sistema acerta a magnitude da força monitorada em 88,9% das amostras.

Na sequência serão apresentados os resultados referentes à monitoração da matriz de sensoriamento bidimensional. Primeiramente, a Tabela 21 apresenta os erros médios referentes aos modelos de predição da posição central da área de aplicação de força, no eixo x. Ressalta-se que nessa estrutura, a menor distância entre o centro de duas áreas vizinhas é de 6,6 cm.

**Tabela 21 – Erros preditivos (cm) de modelos implementados para detecção da posição de aplicação da força, no eixo x, sobre a matriz de sensoriamento bidimensional.**

| Modelo         | Treinamento | Validação | Teste | Nº de coeficientes de regressão $\neq 0$ | Nº de componentes principais |
|----------------|-------------|-----------|-------|------------------------------------------|------------------------------|
| Rede Elástica  | 2,42        | 2,96      | 2,95  | 21                                       | x                            |
| SVR linear     | 2,32        | 3,16      | 2,84  | x                                        | 11                           |
| SVR quadrática | 2,79        | 4,39      | 3,28  | x                                        | 4                            |

**Fonte: Autoria própria (2022).**

Nessa monitoração foram detectados erros médios absolutos na etapa de teste entre 2,84 cm e 3,28 cm. Esses erros correspondem a 14,2% e 16,4% do comprimento total da estrutura em cada eixo, 20 cm.

Similarmente, a Tabela 22 sumariza os erros médios para modelos treinados para predição da posição central da área de aplicação de força, no eixo y da estrutura bidimensional. A menor distância entre o centro de duas dessas áreas também é de 6,6 cm.

**Tabela 22 – Erros preditivos (cm) de modelos implementados para detecção da posição de aplicação da força, no eixo y, sobre a matriz de sensoriamento bidimensional.**


| Modelo         | Treinamento | Validação | Teste | Nº de coeficientes de regressão $\neq 0$ | Nº de componentes principais |
|----------------|-------------|-----------|-------|------------------------------------------|------------------------------|
| Rede Elástica  | 2,55        | 3,16      | 3,06  | 18                                       | x                            |
| SVR linear     | 2,61        | 3,47      | 4,01  | x                                        | 11                           |
| SVR quadrática | 2,70        | 2,97      | 3,90  | x                                        | 4                            |

**Fonte: Autoria própria (2022).**

Os erros médios absolutos apresentados na etapa de teste variaram entre 3,06 cm e 4,01 cm, de acordo com o modelo. Esses valores correspondem a 15,3% e 20,0%, respectivamente, do comprimento total da estrutura em cada eixo, 20 cm.

Avaliando as predições da posição da área central de aplicação de força, nas duas dimensões da estrutura, destaca-se o modelo baseado em Rede Elástica, que apresentou erros médios de teste de 2,95 cm e 3,06 cm e operou com respectivamente, 21 e 18 variáveis preditivas. Quanto à capacidade prática de sensoriamento, considerando a menor distância entre centros de áreas de aplicação de força nessa matriz, de 6,6 cm, tem-se que o sistema executava predições que em média estavam mais próximas das áreas corretas do que qualquer outra da estrutura. A Figura 33, exibe os erros de mapeamento associados a cada amostra do conjunto de teste da estrutura bidimensional, tais resultados são referentes à demodulação realizada pelo modelo baseado em Rede Elástica com  $\alpha = 0,9$ .

**Figura 33 – Erros de sensoriamento da posição da força em amostras de teste para o sistema sensor acoplado a matriz bidimensional. (a) Eixo x. (b) Eixo y.**



**Fonte: Autoria própria (2022).**

Para apresentar resultados de sensoriamento, a estrutura bidimensional foi considerada composta por nove regiões quadradas de lado 6,6 cm, onde cada região de aplicação de força

estava associada a uma área. Definindo que predições dentro da área correta são consideradas acertos na monitoração, tem-se que o sistema acertou 70% das amostras no eixo x, 64% das amostras no eixo y e 56% para a área exata, considerando acerto em ambos os eixos da estrutura.

Por fim, na Tabela 23, são apresentados os erros de predição das magnitudes de forças aplicadas na matriz bidimensional. Os estímulos utilizados para formulação dos conjuntos de dados variaram entre 100 gf e 2000 gf, aplicadas individualmente sobre uma das nove áreas de aplicação sobre a matriz.


**Tabela 23 – Erros preditivos (gf) de modelos implementados para detecção da magnitude da força sobre a matriz de sensoriamento bidimensional.**

| Modelo         | Treinamento | Validação | Teste | Nº de coeficientes de regressão $\neq 0$ | Nº de componentes principais |
|----------------|-------------|-----------|-------|------------------------------------------|------------------------------|
| Rede Elástica  | 191         | 346       | 254   | 23                                       | x                            |
| SVR linear     | 204         | 242       | 282   | x                                        | 11                           |
| SVR quadrática | 283         | 276       | 397   | x                                        | 4                            |

**Fonte: Autoria própria (2022).**

Avaliando o desempenho na predição da magnitude da força, os erros médios variaram entre 254 gf e 397 gf, valores correspondentes a 12,7% e 19,8% da magnitude de força máxima testada de 2000 gf. Modelos lineares apresentaram melhores resultados quando avaliados os erros preditivos. O modelo baseado em SVR linear, apresentou menores variações entre desempenhos de treinamento, validação e teste, além disso esse modelo operou com 11 componentes principais decorrentes da PCA. A partir do sensor operando com esse modelo, a Figura 34 apresenta os erros associados à cada amostra de teste, tal resultado exhibe o desempenho de sensoriamento efetivo detectado.

**Figura 34 – Erros de sensoriamento da magnitude da força em amostras de teste para o sistema sensor acoplado a matriz bidimensional.**



**Fonte: Autoria própria (2022).**

Novamente, destaca-se que variações de cerca de 100 gf, realizadas nos testes, não são detectáveis pelo sistema proposto. Nesse sentido, nota-se que apenas 9 entre as 36 amostras apresentaram erros de sensoriamento inferiores a 100 gf. Observando os erros para cada amostra também verificam-se 9 com erros absolutos superiores a 300 gf na detecção da magnitude da força, demonstrando acerto de 75% das amostras quando a operação de sensoriamento é realizada com resolução de 300 gf.

Considerando ambas as matrizes, ressalta-se que nenhuma monitoração sugerida indicou a posição central da área de aplicação de força em ponto externo às estruturas. Também nessa perspectiva, nenhuma magnitude monitorada foi apontada como negativa ou superior a 2000 gf.

## 5 CONCLUSÕES E PERSPECTIVAS

Foram desenvolvidos dois sistemas óticos, sendo um com três e outro com cinco elementos sensores multiplexados em série em um único segmento de fibra. Os elementos sensores são formados por estruturas em anel de fibra ótica encapsuladas em material elastômero, e quando deformados por força normal induzem modificações na atenuação ótica decorrente das macrocurvaturas. Para interrogação dos sistemas, uma fonte de luz branca foi responsável pela emissão de um sinal ótico de banda larga, o sinal modulado sequencialmente nos elementos sensores durante a transmissão foi detectado por um espectrômetro voltado a aquisição da intensidade ótica transmitida.

A caracterização dos sensores multiplexados quanto à detecção de força permitiu a escolha preliminar da faixa dinâmica para operação de sensoriamento. Foram avaliados espectros de transmissão quando aplicadas forças com magnitudes de até 2000 gf sobre os elementos sensores que formavam os sistemas, com isso foram verificadas diferenças de forma nos espectros resultantes, evidenciando a possibilidade de obter informações a respeito de todos os sensores simultaneamente.

Os sistemas multiplexados foram instalados em estruturas rígidas do tipo placa para análise da capacidade de sensoriamento da configuração de força individual aplicada sobre as matrizes avaliadas em uma e duas dimensões. Cada configuração de força foi definida por uma posição e uma magnitude de força. A matriz unidimensional, com 30 cm de comprimento, composta de PMMA, foi monitorada em seis posições da estrutura e instrumentada com o sistema de três elementos sensores. A matriz bidimensional, quadrada com lados 20 cm, composta por alumínio, teve nove posições de monitoração e contou com o sistema de cinco elementos sensores responsáveis pela modulação do sinal ótico. Foram utilizadas forças na faixa dinâmica entre 100 gf e 2000 gf, em variações de 100 gf.

Na etapa de teste que simulava a operação de monitoramento efetiva desempenhada pelo sistema, a matriz projetada para sensoriamento unidimensional, ao operar com os modelos computacionais sugeridos, apresentou erro médio absoluto de 2,41 cm para predição da posição central da área de aplicação de força, equivalente a 8,0% do comprimento total da estrutura monitorada. Além disso, em um cenário onde a matriz foi organizada em seis regiões de 5 cm de comprimento, o sistema se mostrou capaz de acertar a região de aplicação de força em 71% das amostras. Quanto à detecção da magnitude da força, o erro médio absoluto foi de 177 gf, correspondente a 8,8% da magnitude de força máxima testada. Ao operar com a resolução sugerida de 300 gf, o sensoriamento apresentou acerto em 88,9% das amostras.

Para estudo da capacidade de sensoriamento da matriz avaliada em duas dimensões foram estimados erros de predição da posição da força em dois eixos além da magnitude da força. Implementando os modelos computacionais com melhores desempenhos, e que são sugeridos para sensoriamento efetivo, o erro médio absoluto na estimativa da posição central da área de aplicação de força foi de 2,95 cm e 3,06 cm, para mapeamento no eixo x e no eixo y,

respectivamente. Tais erros correspondem a 14,7% e 15,3% do comprimento total de cada eixo. Ao organizar a estrutura bidimensional em nove regiões quadradas com mesmas dimensões, o sistema foi capaz de acertar a região exata de aplicação da força em 56,0% das amostras. Em continuidade, o erro médio absoluto no sensoriamento da magnitude da força aplicada sobre a na matriz bidimensional, foi de 282 gf, correspondente a 14,1% da magnitude de força máxima testada. Considerando a operação com resolução de 300 gf, em 75,0% das amostras o sistema teve sucesso ao monitorar a magnitude da força aplicada sobre a estrutura.

Um ponto determinante que foi evidenciado no trabalho é a possibilidade de desenvolvimento de sistemas com um número de sensores reduzido em relação ao número de regiões de monitoração. Essa característica mostra-se relevante para o campo da monitoração *quasi*-distribuída no que se refere a simplificação de projetos e redução de custos. Em relação a pesquisas preliminares que demonstram capacidade de multiplexação de elementos sensores baseados em macrocurvatura, o trabalho apresentado contribui ao evidenciar a operação dos dispositivos com respostas acopladas por estruturas rígidas.

Em consonância com o estado da arte, os resultados evidenciam a viabilidade da implementação de modelos de regressão na demodulação do sinal decorrente da operação de sensores baseados em macrocurvaturas de fibra ótica em série. Considerando a complexidade computacional e os desempenhos preditivos em termos de erros médios, modelos de regressão lineares indicaram melhores resultados em relação aos modelos não-lineares, além disso ficou evidente que de acordo com a complexidade dos modelos implementados, verificam-se casos de sobreajuste. A técnica de PCA, implementada em conjunto aos modelos baseados em Vetores Suporte, possibilitou contornar esse impasse, ao passo que também garantiu vantagens computacionais relacionadas a redução de variáveis de entrada, entretanto, no processo de reduzir a dimensionalidade dos dados foi perdida informação a respeito da relevância dos fenômenos físicos envolvidos na modulação do sinal ótico uma vez que as variáveis preditivas passaram a ser representadas por componentes principais ao lugar de intensidades relativas transmitidas por comprimentos de onda. Por outro lado, os modelos baseados em Rede Elástica possibilitaram avaliar quais faixas espectrais foram relevantes para o processamento do sinal considerando que a penalização  $L_1$  associada ao modelo promovia apenas a seleção de variáveis preditivas, a análise foi feita com base nos módulos dos coeficientes de regressão selecionados. Os resultados evidenciaram que comprimentos de onda acima de 600 nm tiveram baixa relevância quando comparados as faixas espectrais (400-500) nm e (550-600) nm, apontando que do ponto de vista físico, para a operação de sensoriamento com base em macrocurvaturas de fibra ótica, as ressonâncias de WGM foram tão relevantes quanto as Perdas por Curvatura, responsáveis pelas maiores alterações espectrais.

Os resultados apresentados no trabalho demonstram a possibilidade de implementação de sensores óticos baseados em macrocurvatura para monitorar a posição e a magnitude de forças individuais aplicada sobre estruturas rígidas do tipo placa, utilizando um sistema simples em termos de produção de sensores. Para as etapas computacionais relacionadas a demodulação do

sinal ótico, sugere-se com base nos resultados a implementação de modelos de regressão lineares em conjunto a etapas de redução de dimensionalidade.

A respeito dos sistemas sensores baseados em macrocurvatura destaca-se a necessidade de calibração individual de cada sistema em vista das peculiaridades construtivas de cada elemento sensor que influencia no sinal ótico resultante detectado e utilizado para monitoração. Outro ponto é a necessidade de determinada estabilização de intensidade da fonte ótica utilizada no sistema pois flutuações inerentes a essas fontes implicam em variações de intensidade do sinal ótico detectado que não estão associadas às modulações induzidas pelas macrocurvaturas. Também nesse sentido, ressalta-se que a estabilidade da montagem experimental é determinante na operação do sistema, em um sistema aplicado espera-se que os componentes óticos sejam fixos e imóveis desde a calibração até a monitoração efetiva.

## **5.1 Trabalhos futuros**

Uma possibilidade avaliada diz respeito a implementação de modelos de classificação para etapa de predição da posição de aplicação de força, tal formulação requer a divisão da matriz de sensoriamento em sub-regiões associadas a classes individuais. Outra proposta para continuidade do trabalho está relacionada a análise da capacidade dos sistemas na monitoração de múltiplas forças simultâneas aplicadas em estruturas rígidas. Para isso sugere-se uma nova métrica de implementação onde cada região predefinida da estrutura é associada a um modelo de regressão individual com treinamento específico para predição da magnitude da força aplicada sobre cada respectiva região estabelecida.

## **5.2 Publicações associadas ao trabalho**

CARVALHO, V.; KAMIZI, M. A. ; LUGARINI, D. ; FABRIS, J. L. ; MULLER, M. . Plataforma Tátil com Sensores Multiplexados de Macrocurvatura em Fibra Ótica. In: 19º Simpósio Brasileiro de Micro-ondas e Optoeletrônica e 14º Congresso Brasileiro de Eletromagnetismo, 2020, São Caetano do Sul. v. 1. p. 209-212.

## **5.3 Outras publicações**

WENDT, N. C. S. ; CARVALHO, V. ; MULLER, M. ; FABRIS, J. L. . Análise de Propriedades Elásticas de Sensores à Fibra Ótica Encapsulados em Elastômero. In: 19º Simpósio Brasileiro de Micro-ondas e Optoeletrônica e 14º Congresso Brasileiro de Eletromagnetismo, 2020, São Caetano do Sul. v. 1. p. 205-208.

## REFERÊNCIAS

- ALEKSANDROVICH, M. S.; VLADIMIROVICH, S. M. *et al.* Fiber-optic sensors of tactile force for anthropomorphic robot grippers. *In: IEEE. 2020 6th International Conference on Mechatronics and Robotics Engineering (ICMRE)*. Barcelona, Spain, 2020. p. 48–52.
- ALEMDAR, K. *et al.* A novel periodic macrobending hetero-core fiber optic sensor embedded in textiles. *In: IEEE. 2013 8th International Conference on Electrical and Electronics Engineering (ELECO)*. Antalya , Turkey, 2013. p. 467–471.
- ARMSTRONG, J. S. Illusions in regression analysis. **International Journal of Forecasting**, 2011.
- BANDARI, N.; DARGAHI, J.; PACKIRISAMY, M. Image-based optical-fiber force sensor for minimally invasive surgery with ex-vivo validation. **Journal of The Electrochemical Society**, IOP Publishing, v. 167, n. 12, p. 127504, 2020.
- BARRIAS, A.; CASAS, J. R.; VILLALBA, S. A review of distributed optical fiber sensors for civil engineering applications. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 16, n. 5, p. 748, 2016.
- BICKHAM, S. R. *et al.* Theoretical and experimental studies of macrobend losses in multimode fibers. *In: CORNING. Proceedings 58th International. Wire & Cable Symposium*. New York, USA, 2009. p. 450–457.
- BOLEININGER, A. *et al.* Whispering gallery modes in standard optical fibres for fibre profiling measurements and sensing of unlabelled chemical species. **Sensors**, Molecular Diversity Preservation International, v. 10, n. 3, p. 1765–1781, 2010.
- BREHENY, P.; BURCHETT, W. Visualization of regression models using visreg. **The R Journal**, Citeseer, v. 9, n. 2, p. 56, 2017.
- BROWNE, M. W. Cross-validation methods. **Journal of Mathematical Psychology**, Elsevier, v. 44, n. 1, p. 108–132, 2000.
- BUDNICKI, D. *et al.* All-fiber vector bending sensor based on a multicore fiber with asymmetric air-hole structure. **Journal of Lightwave Technology**, IEEE, v. 38, n. 23, p. 6685–6690, 2020.
- CHE, J.; WANG, J. Short-term load forecasting using a kernel-based support vector regression combination model. **Applied Energy**, Elsevier, v. 132, p. 602–609, 2014.
- CHERIN, A. H. **An Introduction To Optical Fibers**. New York, USA: McGraw-Hill College, 1983.
- CHOI, J. *et al.* Wearable sensor-based prediction model of timed up and go test in older adults. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 21, n. 20, p. 6831, 2021.
- CROS, D.; GUILLON, P. Whispering gallery dielectric resonator modes for w-band devices. **IEEE Transactions on Microwave Theory and Techniques**, IEEE, v. 38, n. 11, p. 1667–1674, 1990.
- DAKIN, J. Multiplexed and distributed optical fibre sensor systems. **Journal of Physics E: Scientific Instruments**, IOP Publishing, v. 20, n. 8, p. 954, 1987.

DANDLIKER, R. Concept of modes in optics and photonics. *In: SPIE - THE INTERNATIONAL SOCIETY FOR OPTICAL ENGINEERING. Sixth International Conference on Education and Training in Optics and Photonics*. Bellingham, EUA, 1999. p. 193–199.

DANDRIDGE, A.; KIRKENDALL, C. Passive fiber optic sensor networks. **Handbook of Optical Fiber Sensing Technology**, Wiley, New York, USA, p. 433–448, 2002.

DEISS, L. *et al.* Tuning support vector machines regression models improves prediction accuracy of soil properties in mir spectroscopy. **Geoderma**, Elsevier, v. 365, p. 114227, 2020.

DOMINGUES, M. F. *et al.* Insole optical fiber bragg grating sensors network for dynamic vertical force monitoring. **Journal of Biomedical Optics**, International Society for Optics and Photonics, v. 22, n. 9, p. 091507, 2017.

DUBITZKY, W.; GRANZOW, M.; BERRAR, D. P. **Fundamentals of Data Mining in Genomics and Proteomics**. New York, USA: Springer Science & Business Media, 2007.

FABIÁN, N. S. *et al.* Multimode-coreless-multimode fiber-based sensors: theoretical and experimental study. **Journal of Lightwave Technology**, IEEE, v. 37, n. 15, p. 3844–3850, 2019.

FAUSTINI, L.; MARTINI, G. Bend loss in single-mode fibers. **Journal of Lightwave Technology**, IEEE, v. 15, n. 4, p. 671–679, 1997.

FERNANDEZ-VALLEJO, M.; LOPEZ-AMO, M. Optical fiber networks for remote fiber optic sensors. **Sensors**, Molecular Diversity Preservation International, v. 12, n. 4, p. 3929–3951, 2012.

FIELDS, J.; COLE, J. Fiber microbend acoustic sensor. **Applied optics**, Optical Society of America, v. 19, n. 19, p. 3265\_1–3267, 1980.

GAMBLING, W. *et al.* Measurement of radiation loss in curved single-mode fibres. **IEE Journal on Microwaves, Optics and Acoustics**, IET, v. 2, n. 4, p. 134–140, 1978.

GARCÍA, I. *et al.* Optical fiber sensors for aircraft structural health monitoring. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 15, n. 7, p. 15494–15519, 2015.

GIRERD, C. *et al.* Towards a wireless force sensor based on wave backscattering for medical applications. **IEEE Sensors Journal**, IEEE, v. 21, n. 7, p. 8903–8915, 2021.

GRBIĆ, R.; SLIŠKOVIĆ, D.; KADLEC, P. Adaptive soft sensor for online prediction and process monitoring based on a mixture of gaussian process models. **Computers & Chemical Engineering**, Elsevier, v. 58, p. 84–97, 2013.

HARRELL, F. E. **Regression modeling strategies**. [S.l.]: Springer, 2019. v. 608.

HARRIS, A.; CASTLE, P. Bend loss measurements on high numerical aperture single-mode fibers as a function of wavelength and bend radius. **Journal of Lightwave Technology**, IEEE, v. 4, n. 1, p. 34–40, 1986.

HISHAM, H. K. Optical fiber sensing technology: basics, classifications and applications. **American Journal of Remote Sensing**, Science Publishing Group, v. 6, n. 1, p. 1–5, 2018.

HOLLAND, S. M. Principal components analysis (pca). **Department of Geology, University of Georgia**, p. 30602–2501, 2008.

HUANG, J. C. *et al.* Detection of severe acute respiratory syndrome (sars) coronavirus nucleocapsid protein in human serum using a localized surface plasmon coupled fluorescence fiber-optic biosensor. **Biosensors and Bioelectronics**, Elsevier, v. 25, n. 2, p. 320–325, 2009.

- JAY, J. A. An overview of macrobending and microbending of optical fibers. **White Paper of Corning**, p. 1–21, 2010.
- KAMIZI, M. A. *et al.* Multiplexing optical fiber macro-bend load sensors. **Journal of Lightwave Technology**, IEEE, v. 37, n. 18, p. 4858–4863, 2019.
- KAMIZI, M. A. *et al.* A smartphone based fiber sensor for recognizing walking patterns. **IEEE Sensors Journal**, IEEE, v. 19, n. 21, p. 9782–9789, 2019.
- KERSEY, A. D.; DANDRIDGE, A. Distributed and multiplexed fiber-optic sensors. *In*: OPTICAL SOCIETY OF AMERICA. **Optical Fiber Sensors**. New Orleans, Louisiana United States, 1988. p. WDD1.
- KIM, T.-H. *et al.* Development of real time abdominal compression force monitoring and visual biofeedback system. **Physics in Medicine & Biology**, IOP Publishing, v. 63, n. 5, p. 055014, 2018.
- KUHN, M.; JOHNSON, K. *et al.* **Applied predictive modeling**. New York, USA: Springer, 2013. v. 26.
- LEAL-JUNIOR, A. *et al.* A polymer optical fiber temperature sensor based on material features. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 18, n. 1, p. 301, 2018.
- LEAL-JUNIOR, A. G. *et al.* Multiplexing technique for quasi-distributed sensors arrays in polymer optical fiber intensity variation-based sensors. **Optics & Laser Technology**, Elsevier, v. 111, p. 81–88, 2019.
- LEE, D.-H. *et al.* Bending-sensitive fiber for macrobend fiber sensors. **Japanese Journal of Applied Physics**, IOP Publishing, v. 44, n. 2R, p. 920, 2005.
- LEVER, J.; KRZYWINSKI, M.; ALTMAN, N. Points of significance: model selection and overfitting. **Nature Methods**, Nature Publishing Group, v. 13, n. 9, p. 703–705, 2016.
- LIAKOS, K. G. *et al.* Machine learning in agriculture: A review. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 18, n. 8, p. 2674, 2018.
- LIANG, L. *et al.* Classification of steel materials by laser-induced breakdown spectroscopy coupled with support vector machines. **Applied Optics**, Optical Society of America, v. 53, n. 4, p. 544–552, 2014.
- LIU, W.; LI, Q. An efficient elastic net with regression coefficients method for variable selection of spectrum data. **PloS one**, Public Library of Science San Francisco, v. 12, n. 2, p. e0171122, 2017.
- LU, P. *et al.* Distributed optical fiber sensing: Review and perspective. **Applied Physics Reviews**, AIP Publishing LLC, v. 6, n. 4, p. 041302, 2019.
- LUGARINI, D. *et al.* **Sistema Tátil Flexível com Sensores Óticos Multiplexados Baseados em Macrocurvatura**. 2020. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, 2020.
- MARCUSE, D. Curvature loss formula for optical fibers. **Journal of the Optical Society of America**, Optical Society of America, v. 66, n. 3, p. 216–220, 1976.
- MASTELLER, A. *et al.* Recent developments in prosthesis sensors, texture recognition, and sensory stimulation for upper limb prostheses. **Annals of Biomedical Engineering**, Springer, p. 1–18, 2020.

- MENG, L.; WANG, L.; HOU, Y. Development of large-strain macrobend optical-fiber sensor with helical-bending structure for pavement monitoring application. **Journal of Aerospace Engineering**, American Society of Civil Engineers, v. 32, n. 3, p. 04019021, 2019.
- MORALEDA, A. T. *et al.* A temperature sensor based on a polymer optical fiber macro-bend. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 13, n. 10, p. 13076–13089, 2013.
- MOUNTRAKIS, G.; IM, J.; OGOLE, C. Support vector machines in remote sensing: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, Elsevier, v. 66, n. 3, p. 247–259, 2011.
- MUÑOZ-ESPARZA, D.; SHARMAN, R. D.; DEIERLING, W. Aviation turbulence forecasting at upper levels with machine learning techniques based on regression trees. **Journal of Applied Meteorology and Climatology**, v. 59, n. 11, p. 1883–1899, 2020.
- MURAKAMI, Y.; TSUCHIYA, H. Bending losses of coated single-mode optical fibers. **IEEE Journal of Quantum Electronics**, IEEE, v. 14, n. 7, p. 495–501, 1978.
- NELSON, A.; MCMAHON, D. H.; GRAVEL, R. Passive multiplexing system for fiber-optic sensors. **Applied Optics**, Optical Society of America, v. 19, n. 17, p. 2917–2920, 1980.
- NEUMANN, E.-G. Curved dielectric optical waveguides with reduced transition losses. *In*: IET. **IEE Proceedings H-Microwaves, Optics and Antennas**. [S.l.], 1982. v. 129, n. 5, p. 278–280.
- OKAMURA, A. M. Haptic feedback in robot-assisted minimally invasive surgery. **Current Opinion in Urology**, NIH Public Access, v. 19, n. 1, p. 102, 2009.
- ORAEVSKY, A. N. Whispering-gallery waves. **Quantum Electronics**, IOP Publishing, v. 32, n. 5, p. 377, 2002.
- PAPAKONSTANTINO, I. *et al.* Transition, radiation and propagation loss in polymer multimode waveguide bends. **Optics Express**, Optical Society of America, v. 15, n. 2, p. 669–679, 2007.
- RAJAN, G. A macro-bend fiber based wavelength demodulation system for optical fiber sensing applications. **PhD, School of Electrical and Electronics Engineering, Dublin Institute of Technology**, p. 17–23, 2008.
- RAJAN, G. *et al.* A fiber bragg grating-based all-fiber sensing system for telerobotic cutting applications. **IEEE Sensors Journal**, IEEE, v. 10, n. 12, p. 1913–1920, 2010.
- RASMUSSEN, C. E. Gaussian processes in machine learning. *In*: SPRINGER. **Summer School on Machine Learning**. Tübingen, Germany, 2003. p. 63–71.
- RORIZ, P. *et al.* Optical fiber temperature sensors and their biomedical applications. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 20, n. 7, p. 2113, 2020.
- ROZENBERG, G.; BÄCK, T.; KOK, J. N. **Handbook of Natural Computing**. Leiden, Netherlands: Springer, 2012.
- SAREH, S. *et al.* Macrobend optical sensing for pose measurement in soft robot arms. **Smart Materials and Structures**, IOP Publishing, v. 24, n. 12, p. 125024, 2015.
- SAUERBREI, W. *et al.* State of the art in selection of variables and functional forms in multivariable analysis—outstanding issues. **Diagnostic and Prognostic Research**, Springer, v. 4, n. 1, p. 1–18, 2020.

- SHIH, B. *et al.* Electronic skins and machine learning for intelligent soft robots. **Science Robotics**, Science Robotics, v. 5, n. 41, 2020.
- SHLENS, J. A tutorial on principal component analysis. **arXiv preprint arXiv:1404.1100**, 2014.
- SMOLA, A. J.; SCHÖLKOPF, B. A tutorial on support vector regression. **Statistics and Computing**, Springer, v. 14, n. 3, p. 199–222, 2004.
- SOHN, H. *et al.* A review of structural health monitoring literature: 1996–2001. **Los Alamos National Laboratory**, Citeseer, v. 1, 2003.
- SOUZA, F. A.; ARAÚJO, R.; MENDES, J. Review of soft sensor methods for regression applications. **Chemometrics and Intelligent Laboratory Systems**, Elsevier, v. 152, p. 69–79, 2016.
- TSAO, S.-L.; CHENG, W.-M. Simplified formula of bending loss for optical fiber sensors. **Fiber & Integrated Optics**, Taylor & Francis, v. 21, n. 5, p. 333–344, 2002.
- WANG, P. *et al.* Macrobending single-mode fiber-based refractometer. **Applied Optics**, Optical Society of America, v. 48, n. 31, p. 6044–6049, 2009.
- WANG, Q.; FARRELL, G.; FREIR, T. Theoretical and experimental investigations of macro-bend losses for standard single mode fibers. **Optics Express**, Optical Society of America, v. 13, n. 12, p. 4476–4484, 2005.
- WANG, Q.; LIU, Y. Optical fiber curvature sensor based on mmf-scf-mm structure. **Optical Fiber Technology**, Elsevier, v. 43, p. 1–5, 2018.
- WANG, Q.; LIU, Y. Review of optical fiber bending/curvature sensor. **Measurement**, Elsevier, v. 130, p. 161–176, 2018.
- WANG, S.-F. *et al.* A fbg intensity modulation system combined with an optical whispering gallery mode edge filter. **Applied Sciences**, Multidisciplinary Digital Publishing Institute, v. 6, n. 4, p. 92, 2016.
- WELLING, M. Support vector regression. **Department of Computer Science, University of Toronto**, Toronto, Canada, 2004.
- WILKES, E. H. *et al.* A machine learning approach for the automated interpretation of plasma amino acid profiles. **Clinical Chemistry**, Oxford University Press, v. 66, n. 9, p. 1210–1218, 2020.
- YANG, X.; WEN, W. Ridge and lasso regression models for cross-version defect prediction. **IEEE Transactions on Reliability**, IEEE, v. 67, n. 3, p. 885–896, 2018.
- ZENG, H.-T. *et al.* Mixture analysis using non-negative elastic net for raman spectroscopy. **Journal of Chemometrics**, Wiley Online Library, v. 34, n. 10, p. e3293, 2020.
- ZHANG, X. *et al.* Genetic algorithm-support vector regression for high reliability shm system based on fbg sensor network. **Optics and Lasers in Engineering**, Elsevier, v. 50, n. 2, p. 148–153, 2012.
- ZHANG, Z.; HAN, Y. Detection of ovarian tumors in obstetric ultrasound imaging using logistic regression classifier with an advanced machine learning approach. **IEEE Access**, IEEE, v. 8, p. 44999–45008, 2020.

ZOU, H.; HASTIE, T. Regression shrinkage and selection via the elastic net, with applications to microarrays. **Journal of the Royal Statistical Society**, v. 67, p. 301–20, 2003.