

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E INFORMÁTICA
INDUSTRIAL

DIOGO LUGARINI

**SISTEMA TÁTIL FLEXÍVEL COM SENSORES ÓTICOS
MULTIPLEXADOS BASEADOS EM MACROCURVATURA**

DISSERTAÇÃO DE MESTRADO

**CURITIBA
2020**

DIOGO LUGARINI

**SISTEMA TÁTIL FLEXÍVEL COM SENSORES ÓTICOS
MULTIPLEXADOS BASEADOS EM MACROCURVATURA**

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.

Orientadora: Prof^a. Dr^a. Marcia Muller
Coorientador: Prof. Dr. José Luís Fabris

CURITIBA

2020

Dados Internacionais de Catalogação na Publicação

Lugarini, Diogo

Sistema tátil flexível com sensores óticos multiplexados baseados em macrocurvatura [recurso eletrônico] / Diogo Lugarini. -- 2020.

1 arquivo eletrônico (103 f.): PDF; 8,25 MB.

Modo de acesso: World Wide Web.

Texto em português com resumo em inglês.

Dissertação (Mestrado) - Universidade Tecnológica Federal do Paraná. Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial.

Área de Concentração: Fotônica em Engenharia. Linha de Pesquisa: Estruturas e Dispositivos Fotônicos, Curitiba, 2020.

Bibliografia: f. 99-103.

1. Engenharia elétrica - Dissertações. 2. Detectores ópticos. 3. Fibras ópticas. 4. Detectores táteis. 5. Curvatura. 6. Multiplexação. 7. Análise espectral. 8. Análise de regressão. 9. Processamento de sinais - Modelos matemáticos. 10. Espectroscopia ultravioleta-visível (UV/VIS). 11. Métodos de simulação. I. Muller, Márcia, orient. II. Fabris, José Luís, coorient. III. Universidade Tecnológica Federal do Paraná. Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial. IV. Título.

CDD: Ed. 23 -- 621.3

Biblioteca Central do Câmpus Curitiba - UTFPR
Bibliotecária: Luiza Aquemi Matsumoto CRB-9/794



Ministério da Educação

Universidade Tecnológica Federal do Paraná
Diretoria Geral do Campus Curitiba
Diretoria de Pesquisa e Pós-Graduação
Programa de Pós-Graduação em Engenharia Elétrica e
Informática Industrial - CPGEI



TERMO DE APROVAÇÃO DE DISSERTAÇÃO Nº 872

A Dissertação de Mestrado intitulada SISTEMA TÁTIL FLEXÍVEL COM SENSORES ÓTICOS MULTIPLEXADOS BASEADOS EM MACROCURVATURA, defendida em sessão pública pelo(a) candidato(a) Diogo Lugarini, no dia 26 de agosto de 2020, foi julgada para a obtenção do título de Mestre em Ciências, área de concentração Fotônica em Engenharia, linha de pesquisa Estruturas e Dispositivos Fotônicos, e aprovada em sua forma final, pelo Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial.

Este Termo de Aprovação encontra-se na pasta do aluno na Secretaria do Programa, contendo a assinatura da Coordenação realizada após a entrega da versão final, incluindo correções necessárias, permitindo o encaminhamento para análise e publicação no Repositório Institucional.

Prof(a). Dr(a). Marcia Muller - UTFPR - Presidente
Prof(a). Dr(a). Ivo de Lourenço Junior - UTFPR-PB
Prof(a). Dr(a). Lucas Hermann Negri - IFMS - Participação por videoconferência

Assinado eletronicamente por
Coordenador do Programa
André Schneider de Oliveira

AGRADECIMENTOS

Aos meus orientadores, Marcia Muller e José Luís Fabris, agradeço imensamente pela oportunidade de realizar o mestrado, por compartilharem os conhecimentos na área de ótica e pela dedicação ao me auxiliar neste trabalho. Agradeço também aos professores do CPGEI que, de algum modo, contribuíram para a conclusão desta etapa.

Aos meus colegas de laboratório pelos momentos que passamos neste período.

À Universidade Tecnológica Federal do Paraná e servidores por fornecerem o ambiente oportuno à pesquisa.

Ao apoio financeiro disponibilizado pelos órgãos de fomento CAPES, CNPq, Fundação Araucária e Finep. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

À minha família e àqueles que me apoiaram.

RESUMO

LUGARINI, Diogo. SISTEMA TÁTIL FLEXÍVEL COM SENSORES ÓTICOS MULTIPLEXADOS BASEADOS EM MACROCURVATURA. 2020. 103 f. Dissertação de Mestrado – Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial, Universidade Tecnológica Federal do Paraná. Curitiba, 2020.

Neste trabalho são apresentadas as etapas de fabricação e teste de uma matriz de sensoriamento tátil constituída por 4 sensores de macrocurvatura em fibras óticas, multiplexados e encapsulados em silicone. Para a interrogação do sistema são usadas as informações contidas nos espectros de transmissão da matriz na região espectral do visível. A intensidade de transmissão, nos diferentes comprimentos de onda da luz, é afetada por perturbações externas causadas por cargas aplicadas sobre a superfície da matriz, permitindo o sensoriamento tátil. A resposta acoplada dos 4 sensores permitiu a identificação da magnitude e posição de cargas aplicadas simultaneamente em até 5 regiões de sensoriamento pré-estabelecidas. Regressões lineares foram usadas para analisar os espectros de transmissão obtidos quando da aplicação de cargas entre 0,0 kg e 2,0 kg sobre a superfície da matriz. O sensoriamento na matriz com um número de sensores menor do que o número de regiões de sensoriamento foi alcançado. O sistema mostrou-se capaz de reconhecer cargas e posições com erro de 0,208 kg usando a regressão Ridge. Este erro representa 10,40 % da maior carga aplicada por região e 3,47 % da maior carga total aplicada na matriz.

Palavras-chave: Sensores óticos. Macrocurvatura em fibras óticas. Multiplexação de sensores óticos. Regressões lineares. Matriz de sensoriamento tátil.

ABSTRACT

LUGARINI, Diogo. FLEXIBLE TACTILE ARRAY WITH MULTIPLEXED MACRO-BEND OPTICAL FIBER SENSORS. 2020. 103 f. Masters Dissertation– Graduate Program in Electrical and Computer Engineering, Federal University of Technology – Paraná. Curitiba, 2020.

In this work, fabrication and testing of a tactile sensing array consisting of 4 macro-bend optical fiber sensors, multiplexed and encapsulated in silicone are presented. The array transmission spectra in the visible spectral range carries information used for the sensing system interrogation. Intensity at different wavelengths of the transmission spectrum is affected by external perturbations caused by loads applied on the array surface, allowing tactile sensing. The coupled response of the 4 sensors allowed the identification of the magnitude and position of loads applied simultaneously in up to 5 previously established sensing regions. Linear regressions were used in the analysis of the transmission spectra obtained when the array was submitted to loads from 0.0 kg to 2.0 kg. Tactile sensing with fewer sensors than the number of sensing regions has been achieved. The system was able to recognize the magnitude and location of loads with an error of 0.208 kg using Ridge regression. This error represents 10.40 % of the highest applied load per region and 3.47 % of the highest total load applied on the sensing array.

Keywords: Optical Sensors. Macrocurvature in optical fibers. Multiplexing of optical sensors. Linear regressions. Tactile sensing matrix.

LISTA DE ILUSTRAÇÕES

Figura 1 – Aspecto geral de uma fibra ótica (a) e caminho de um raio propagando com ângulo geométrico para a reflexão interna total (b).	22
Figura 2 – Representação da criação de microcurvaturas.	24
Figura 3 – Diagrama representando a macrocurvatura em fibras óticas.	25
Figura 4 – Curvatura em fibra indicando a formação dos <i>whispering gallery modes</i>	27
Figura 5 – Desenho esquemático dos componentes básicos de um sistema baseado em sensor a fibra ótica.	28
Figura 6 – Representação básica de um sistema ótico multiplexado.	29
Figura 7 – Representação da técnica de multiplexação espacial.	30
Figura 8 – Exemplo de utilização de k-fold para separar um conjunto de dados em 3 subgrupos de teste.	42
Figura 9 – Desenho esquemático do laço na fibra ótica utilizado para criação dos sensores de macrocurvatura.	45
Figura 10 – Aspecto do encapsulamento do laço em pequeno cilindro, referente à segunda etapa da produção dos sensores.	46
Figura 11 – Diagrama esquemático do sensor final indicando: (a) visão geral do sensor e (b) um corte transversal.	46
Figura 12 – Sensor de macrocurvatura produzido.	47
Figura 13 – Detalhamento da estrutura utilizada para aplicação de cargas: (a) detalhe da estrutura inteira e (b) com as hastes de aplicação.	48
Figura 14 – Diagrama esquemático do sistema experimental usado na caracterização dos elementos sensores.	48
Figura 15 – Espectros de transmissão do elemento sensor sujeito a cargas de 0,0 a 5,0 kg.	49
Figura 16 – Espectros de transmissão do elemento sensor sujeito a cargas entre 0,0 e 3,0 kg, aplicadas com passo de 0,3 kg em ordem crescente (a) e em ordem decrescente (b)	51
Figura 17 – Comparação entre medições de cargas iguais para pressão constante sobre o elemento sensor, sendo as em vermelho medidas no sentido crescente de aplicação e as em preto no sentido decrescente de aplicação.	52
Figura 18 – Espectros de transmissão do sensor obtidos em 3 testes consecutivos de aplicação de cargas de 0,0 a 3,0 kg.	53
Figura 19 – Sensores individuais em série para produção da matriz.	55
Figura 20 – Esquema completo da matriz do sistema com indicação das posições dos sensores óticos em série distribuídos.	56
Figura 21 – Matriz produzida com (a) vista superior e (b) vista em perspectiva.	56
Figura 22 – Regiões de aplicação de cargas para testes dos sensores da matriz.	57
Figura 23 – Espectros referentes às medições de cargas aplicadas para as caracterizações dos elementos sensores presentes na matriz.	57
Figura 24 – Comparação entre os espectros de transmissão da matriz quando da aplicação individual de cargas de 1,0 kg, 1,5 kg, 2,0 kg e 3,0 kg em cada sensor.	59

Figura 25 – Diagrama representando as 5 áreas de sensoriamento estabelecidas para testar a capacidade de sensoriamento da matriz.	59
Figura 26 – Espectros de transmissão da matriz de sensores resultantes da aplicação individual de cargas de 0,0 a 3,0 kg nas regiões de sensoriamento.	60
Figura 27 – Espectros de transmissão referentes a cada carga aplicada, comparando as cinco regiões do sistema.	61
Figura 28 – Representação na matriz das 4 primeiras configurações da Tabela 1.	63
Figura 29 – Espectros de transmissão obtidos com as 155 configurações de carga aplicadas em sequência aleatória sobre a matriz.. . . .	64
Figura 30 – Espectros de transmissão obtidos com as 155 configurações ordenadas aplicadas sobre a matriz.	65
Figura 31 – Matrizes de entrada de dados: valores de intensidade dos espectros e alvos (valores em kg), respectivamente.	67
Figura 32 – Resultado da regressão por mínimos quadrados para as aplicações aleatórias, das 3 configurações de testes apresentadas na Tabela 3, que incluem a de menor erro (a), uma aleatória (b) e a de maior erro (c).	70
Figura 33 – Resultado da regressão por mínimos quadrados para as aplicações ordenadas, das 3 configurações de testes apresentadas Tabela 4, que incluem a de menor erro (a), uma aleatória (b) e a de maior erro (c).	72
Figura 34 – Resultado da regressão Ridge para as aplicações em ordem aleatória, das 3 configurações de testes apresentadas na Tabela 5, que incluem a de menor erro (a), uma aleatória (b) e a de maior erro (c).	74
Figura 35 – Resultado da regressão Ridge para as aplicações ordenadas, das 3 configurações de testes apresentadas na Tabela 6, que incluem a de menor erro (a), uma aleatória (b) e a de maior erro (c).	76
Figura 36 – Resultado da regressão Lasso para as aplicações em ordem aleatória, das 3 configurações de testes apresentadas na Tabela 7, que incluem a de menor erro (a), uma aleatória (b) e a de maior erro (c).	78
Figura 37 – Coeficientes associados aos comprimentos de onda não anulados pela regressão Lasso para as configurações aleatórias.	79
Figura 38 – Resultado da regressão Lasso para as aplicações ordenadas, das 3 configurações de testes apresentadas na Tabela 8, que incluem a de menor erro (a), uma aleatória (b) e a de maior erro (c).	81
Figura 39 – Coeficientes associados aos comprimentos de onda não anulados pela regressão Lasso para as configurações ordenadas.	82
Figura 40 – Espectros utilizados para as regressões para os comprimentos de onda entre 400 e 800 nm, com (a) configurações aleatórias e (b) configurações ordenadas.	85
Figura 41 – Espectros utilizados para as regressões para os comprimentos de onda entre 400 e 750 nm, com (a) configurações aleatórias e (b) configurações ordenadas.	87
Figura 42 – Espectros utilizados para as regressões para os comprimentos de onda entre 400 e 650 nm, com (a) configurações aleatórias e (b) configurações ordenadas.	89

Figura 43 – Espectros utilizados para as regressões para os comprimentos de onda entre 650 e 800 nm, com (a) configurações aleatórias e (b) configurações ordenadas.	91
--	----

LISTA DE TABELAS

Tabela 1 – Exemplo de configurações geradas aleatoriamente para teste de multiplexação, indicando os valores em kg das cargas aplicadas em cada região.	63
Tabela 2 – Parâmetros definidos para os modelos de regressão a partir da validação cruzada antes do treinamento dos mesmos.	68
Tabela 3 – Exemplo de três configurações aplicadas à matriz na regressão por mínimos quadrados para as configurações aleatórias, indicando o erro individual, incluindo os dois extremos: configuração de menor erro (17) e configuração de maior erro (40).	69
Tabela 4 – Exemplo de três configurações aplicadas à matriz na regressão por mínimos quadrados para as configurações ordenadas, indicando o erro individual, incluindo os dois extremos: configuração de maior erro (38) e configuração de menor erro (20).	71
Tabela 5 – Exemplo de três configurações aplicadas à matriz na regressão Ridge para as configurações em ordem aleatória, indicando o erro individual, incluindo os dois extremos: configuração de maior erro (40) e configuração de menor erro (7).	73
Tabela 6 – Exemplo de três configurações aplicadas à matriz na regressão Ridge para as configurações ordenadas, indicando o erro individual, incluindo os dois extremos: configuração de maior erro (38) e configuração de menor erro (26).	75
Tabela 7 – Exemplo de três configurações aplicadas à matriz na regressão Lasso para as configurações em ordem aleatória, indicando o erro individual, incluindo os dois extremos: configuração de maior erro (40) e configuração de menor erro (43).	77
Tabela 8 – Exemplo de três configurações aplicadas à matriz na regressão Lasso para as configurações ordenadas, indicando o erro individual, incluindo os dois extremos: configuração de maior erro (38) e configuração de menor erro (26)	80
Tabela 9 – Comparação das regressões lineares aplicadas ao sistema usando os espectros entre 400 e 850 nm, indicando os valores associados a cada erro analisado	83
Tabela 10 – Comparação das regressões lineares aplicadas ao sistema usando os espectros entre 400 e 800 nm, indicando os valores associados a cada erro analisado	86
Tabela 11 – Comparação das regressões lineares aplicadas ao sistema usando os espectros entre 400 e 750 nm, indicando os valores associados a cada erro analisado.	88
Tabela 12 – Comparação das regressões lineares aplicadas ao sistema usando os espectros entre 400 e 650 nm, indicando os valores associados a cada erro analisado	90
Tabela 13 – Comparação das regressões lineares aplicadas ao sistema usando os espectros entre 650 e 800 nm, indicando os valores associados a cada erro analisado	92

Tabela 14 – Valores associados aos erros obtidos usando as 155 configurações
como treinamento e 32 duas configurações externas aferidas para
teste 94

LISTA DE SIGLAS

RGB	Vermelho, verde e azul, do inglês <i>Red, Green and Blue</i>
UV-VIS	Ultravioleta-Visível
SMF	Fibra Ótica Monomodo, do inglês <i>Single Mode Fiber</i>
MMF	Fibra Ótica Multimodo, do inglês <i>Multimode Fiber</i>
FBG	<i>Fiber Bragg Grating</i>
WGM	Modos de Galeria Sussurrantes, do inglês <i>Whispering Gallery Modes</i>
TDM	<i>Time Domain Multiplexing</i>
FDM	<i>Frequency Domain Multiplexing</i>
WDM	<i>Wavelength Domain Multiplexing</i>
OLS	Regressão por Mínimos Quadrados, do inglês <i>Ordinary Least Squares</i>
Lasso	<i>Least Absolute Shrinkage and Selection Operator</i>
MSE	Erro Quadrático Médio, do inglês <i>Mean Squared Error</i>
MAE	Erro Absoluto Médio, do inglês <i>Mean Absolut Error</i>
MDF	<i>Medium Density Fiberboard</i>
PVC	Policloreto de Vinila

LISTA DE SÍMBOLOS

AN	Abertura Numérica
r	Raio do núcleo da fibra
n	Índice de refração
V	Frequência normalizada
λ	Comprimento de onda da luz guiada
λ_c	Comprimento de onda de corte
A_m	Magnitude das perdas por curvatura
N	Quantidade de microcurvaturas
h	Altura projetada da microcurvatura
$\langle h^2 \rangle$	Média da altura projetada
c	Diâmetro do revestimento
Δ	Índice relativo
E	Módulo elástico
P	Potência ótica
R	Raio de curvatura na fibra
At	Perda por curvatura
K_1	Função modificada de Henkel
κ	Constante de fase radial
γ	Constante de atenuação radial
β	Constante de propagação
m	Mínimos de perda oscilatória
ϕ	Constante de fase
L	Comprimento dos raios dos WGM
Z	Comprimento do arco para os WGM
w	Posição em que os WGM entre casca e meio externo em relação ao núcleo da fibra

d	Local em relação ao núcleo da fibra em que os raios WGM ficam confinados
ε	Valor a ser minimizado nas regressões lineares
$\bar{x}$	Média das variáveis x
$\bar{y}$	Média das variáveis y
$\mathbf{X}$	Matriz das variáveis x
β	Matriz dos parâmetros das regressões lineares
$\mathbf{y}$	Matriz das variáveis y
$\mathbf{B}$	Estimadores reais das regressões lineares
α	Parâmetro de penalização das regressões lineares

SUMÁRIO

1	INTRODUÇÃO	17
1.1	MOTIVAÇÕES	17
1.2	ESTADO DA ARTE	18
1.2.1	Sensores óticos baseados em curvatura	18
1.2.2	Multiplexação de sensores baseados em curvatura em fibras óticas	20
1.3	OBJETIVOS	21
1.3.1	Objetivos específicos	21
1.4	ESTRUTURA	21
2	FUNDAMENTAÇÃO TEÓRICA	22
2.1	FIBRAS ÓTICAS	22
2.1.1	Atenuação do sinal em fibras óticas	24
2.1.1.1	Modos Sussurantes (<i>Whispering Gallery Modes</i>)	26
2.2	SENSORES DE MACROCURVATURA	28
2.3	TÉCNICAS DE MULTIPLEXAÇÃO	29
2.4	REGRESSÕES LINEARES	31
2.4.1	Mínimos Quadrados	33
2.4.2	Métodos de regressão alternativos ao OLS	36
2.4.2.1	Regressão Ridge	37
2.4.2.2	Regressão Lasso	40
2.5	VALIDAÇÃO CRUZADA	40
2.6	ERRO ABSOLUTO MÉDIO	42
3	METODOLOGIA E RESULTADOS	44
3.1	SENSOR DE MACROCURVATURA	44
3.1.1	Produção do elemento sensor	44
3.1.2	Caracterização do elemento sensor	47
3.2	MATRIZ DE SENSORIAMENTO TÁTIL	54
3.2.1	Produção da matriz de sensoriamento tátil	54
3.2.2	Caracterização dos sensores da matriz	56
3.2.3	Caracterização das regiões do sistema	59
3.3	TESTES COM A MATRIZ DE SENSORIAMENTO TÁTIL	62
3.3.1	Metodologia adotada para a realização dos testes	62
3.3.2	Método de tratamento dos dados do teste da matriz	66
3.3.3	Resultados obtidos com a regressão por mínimos quadrados usando os dados da faixa espectral entre 400 e 850 nm	69
3.3.4	Resultados obtidos com a regressão Ridge usando os dados da faixa espectral entre 400 e 850 nm	72
3.3.5	Resultados obtidos com a regressão Lasso usando os dados da faixa espectral entre 400 e 850 nm	76
3.3.6	Comparativo do desempenho da matriz usando as 3 regressões e a faixa espectral entre 400 e 850 nm	82
3.3.7	Comparativo do desempenho da matriz usando as 3 regressões e a faixa espectral entre 400 e 800 nm	84

3.3.8	Comparativo do desempenho da matriz usando as 3 regressões e a faixa espectral entre 400 e 750 nm	87
3.3.9	Comparativo do desempenho da matriz usando as 3 regressões e a faixa espectral entre 400 e 650 nm	89
3.3.10	Comparativo do desempenho da matriz usando as 3 regressões e a faixa espectral entre 650 e 800 nm	91
3.3.11	Comparativo do desempenho da matriz usando as 3 regressões e diferentes faixas espectrais	92
3.3.12	Validação com conjunto de testes adicional externo	94
4	CONCLUSÕES	96
5	PUBLICAÇÕES ASSOCIADAS COM O TRABALHO	98
5.1	PUBLICAÇÕES	98
5.2	PUBLICAÇÕES EM COAUTORIA	98
	REFERÊNCIAS	99

1 INTRODUÇÃO

1.1 MOTIVAÇÕES

As fibras óticas e suas tecnologias associadas tiveram um importante e amplo crescimento nas últimas décadas, permitindo avanços e inovações em diversas áreas. Imerso nesse crescimento, a optoeletrônica e as comunicações óticas possibilitaram o desenvolvimento, e a comercialização por consequência, de diferentes tipos de componentes óticos, que, em grande parte foram aplicados para o uso de sensores óticos (CONNELLY, 2005). Esses sensores óticos, portanto, puderam substituir o uso de sensores elétricos, criando alternativas e melhorias para aquisição de dados. Isso foi possível devido a algumas características das fibras. Dentre essas propriedades, pode-se citar a grande redução em relação à massa do sistema necessária, quando se compara com os cabos de cobre, por exemplo. Relacionado a isso, está diretamente conectada a redução do espaço necessário, substituindo vários cabos coaxiais por um único em fibra, além de serem imunes à interferência eletromagnética, o que é uma vantagem em instalações industriais (MITSCHKE, 2010). Adicionalmente, quimicamente, o vidro é bastante inerte, podendo ser utilizado em ambientes em que metais (dos sensores elétricos) não seriam viáveis.

Esses sensores são capazes de medir diversos parâmetros físicos, incluindo temperatura, pressão, tensão mecânica, campo magnético, radiação, fluxo de fluidos etc. Pela evolução dos sistemas de sensoriamento, houve necessidade de utilizar estruturas mais complexas para medir parâmetros simultâneos. Desse modo, foram propostas técnicas de multiplexação e distribuição de sensores óticos, mostrando a versatilidade das fibras em relação às suas aplicações (CRANCH, 2014).

Sistemas distribuídos para detecção de forças já foram desenvolvidos, utilizando sensoriamento baseado em redes de Bragg, como em 2017, em que Negri utilizou métodos de inteligência computacional para avaliar deformações mecânicas em sistema distribuído e *quasi*-distribuído (NEGRI, 2017), assim como Pedroso, em 2018, desenvolveu um sistema *quasi*-distribuído com transdutores de redes de Bragg para captar forças em posições de uma matriz tátil com número maior em relação ao número de transdutores (PEDROSO, 2018).

Sistemas táteis e distribuídos podem ser utilizados em dispositivos médicos, na robótica ou na indústria (GIRÃO *et al.*, 2013). Tais aplicações envolvem monitorar pressões exercidas ao longo de uma articulação robótica, pressões resultantes de humanos em assentos de veículos de transporte ou acompanhar a reabilitação de pacientes que perderam tônus muscular.

Em 2018, Kamizi et al. verificaram a capacidade de multiplexação de sensores óticos baseados em macrocurvatura em fibras óticas não acoplados, utilizando a detecção por RGB (KAMIZI *et al.*, 2018). Posteriormente, em 2019, Kamizi et al. demonstraram um novo método de multiplexação, com o mesmo tipo de sensores óticos em série, sendo possível identificar magnitude e posição de cargas aplicadas em um sistema distribuído com a detecção por espectrômetro, e análise através de regressões lineares (KAMIZI *et al.*, 2019). No presente trabalho, também utilizam-se sensores óticos baseados em macrocurvatura em fibras óticas, que é obtida ao se curvar a fibra de modo a gerar um raio de curvatura com dimensões grandes em relação às dimensões da própria fibra. Este tipo de sensor utiliza a modulação por intensidade do sinal e possui baixo custo de fabricação quando comparado a outros sistemas óticos.

Portanto, uma das motivações deste trabalho é explorar a capacidade de multiplexação de sensores óticos baseados em macrocurvatura fazendo uso da resposta acoplada dos mesmos para detecção *quasi*-distribuída de cargas. Para tanto, são monitoradas cargas aplicadas em regiões de sensoriamento pré-definidas em maior número do que o número de sensores. Um espectrômetro UV-Vis é utilizado como interrogador e a análise computacional é realizada por meio de regressões lineares dos dados fornecidos pelo sistema.

1.2 ESTADO DA ARTE

1.2.1 Sensores óticos baseados em curvatura

Os sensores de fibras óticas podem ser classificados em 2 grupos: sensores extrínsecos, que captam características relacionadas a parte externa da fibra, e sensores intrínsecos, que utilizam a estrutura da fibra em si como sensor. Dentre os sensores intrínsecos, estão presentes os sensores interferométricos, que são um grande grupo

de sensores de alta performance, assim como os sensores baseados em redes de Bragg (*Fiber Bragg Grating* – FBG), que possuem uma enorme área de aplicação (UDD, 2011). Ainda no grupo dos sensores intrínsecos, estão presentes os sensores baseados em modulação de intensidade, como os de curvatura, foco deste trabalho.

O conceito de curvatura, e sua formulação, iniciou-se com o objetivo de mensurar o problema associado a esse efeito, as perdas por curvatura. Elas ocorrem quando a curvatura gerada é suficiente para que o ângulo crítico para reflexão total seja excedido. Ao longo dos anos, portanto, constatou-se a possibilidade de utilizar a curvatura e sua perda para sistemas de sensoriamento. Esse tipo de sensor utiliza a modulação por intensidade e sua aplicação é relativamente simples de ser implementada, uma vez que pode necessitar, apenas, de uma fonte de luz e um detector.

Em 1976, Marcuse propôs a equação de aproximação para esse efeito da curvatura para fibras de índice degrau (MARCUSE, 1976), concluindo que a atenuação é exponencialmente proporcional ao raio de curvatura e ao comprimento de onda da luz incidente. Outros trabalhos comprovaram essa dependência, como Sharma et al., em 1984, com a aplicação de uma nova técnica para medir a perda em função do raio de curvatura (SHARMA *et al.*, 1984), Harris e Castle, em 1986, com a investigação da perda por curvatura em função do comprimento de onda para fibras monomodo (HARRIS; CASTLE, 1986) e Sakai, em 1979, que propôs uma simplificação da fórmula para fibras monomodo (SAKAI, 1979).

Estas formulações para os efeitos de curvatura são o que permite a aplicação dos sensores baseados em macrocurvatura. Porém, microcurvaturas também podem ser produzidas em fibras para sensoriamento. Geralmente, as microcurvaturas são feitas ao longo de um pedaço da fibra, gerando um padrão periódico para sensoriamento, como é o caso de algumas aplicações com sensoriamento para monitoramento de água (JUNG *et al.*, 2006) ou temperatura (DENISOV *et al.*, 2005), por exemplo.

Em relação aos sensores de macrocurvatura, dentre as suas aplicações, trabalhos utilizaram seu conceito para análise de índice de refração, como Wang et al., em 2009, em que a macrocurvatura, quando submetida a diferentes líquidos, representava diferentes tipos de perdas, principalmente pelo efeito de modos sussurrantes, podendo fazer a correlação com os índices de refração (WANG *et al.*, 2009). Em 2011, Wang et al., também utilizaram o recurso da macrocurvatura que, quando conectada a um

transdutor piezoelétrico, era alterada por meio da excitação com tensões elétricas, podendo monitorar tal grandeza (WANG *et al.*, 2011).

Um sensor para detecção de concentração de sal foi desenvolvido em 2013 por Chian e Chao, utilizando raios de curvatura para soluções entre 1 e 25%, o que mostrou a relação entre perdas de curvatura, comprimento de onda e intensidade dos dados obtidos, para identificar as concentrações (CHIANG; CHAO, 2013).

Chen *et al.*, em 2019, propuseram um sensor utilizando a curvatura imersa em líquidos para verificar a inclinação gerada no recipiente (CHEN *et al.*, 2019). Ao se alterar o ângulo de referência do recipiente, a parte da fibra imersa no líquido de prova era mais, ou menos, exposta ao líquido, alterando o índice de refração ao redor da curvatura, podendo identificar qual a magnitude da inclinação.

Recentemente, em 2020, Yin *et al.* propuseram um sensor baseado em macrocurvatura utilizando uma fibra com dois núcleos (YIN *et al.*, 2020). Verificaram que era viável criar um sensor com tais características, indicando que a curvatura pode ser abordada não somente para as fibras comumente utilizadas de núcleo único.

Como se nota, há aplicações dos sensores baseados em curvaturas para diferentes tipos de grandezas, principalmente pela facilidade de implementar o dispositivo.

1.2.2 Multiplexação de sensores baseados em curvatura em fibras óticas

O trabalho que motivou e serviu como base a respeito da multiplexação de sensores baseados em curvatura para o presente trabalho, foi desenvolvido em 2018 por Kamizi *et al.*, no qual se utilizou a distribuição de 3 sensores em série, não acoplados, de macrocurvatura para teste de multiplexação (KAMIZI *et al.*, 2018). Os sensores foram construídos com laços de 5,0 mm de diâmetro encapsulados em elastômero de silicone, resultando em pequenos dispositivos cilíndricos com 30,0 mm de diâmetro e 8,0 mm de altura. A multiplexação foi avaliada a partir da aplicação de cargas entre 0,2 e 1,0 kg sobre os sensores. A detecção do sinal foi feita a partir de imagens captadas por uma câmera de *smartphone* em uma das saídas da fibra. A intensidade captada foi analisada por meio de canais RGB, concluindo a capacidade do sistema em diferenciar graficamente regiões espaciais referentes às cargas aplicadas e sensores, tornando viável a multiplexação desse tipo de sensor em um único caminho de fibra.

1.3 OBJETIVOS

Produzir uma matriz de sensoriamento tátil flexível usando sensores de macrocurvatura em fibra ótica multiplexados em série.

1.3.1 Objetivos específicos

- Produzir os elementos sensores individuais baseados em macrocurvatura em fibra ótica;
- Caracterizar os elementos sensores individuais quanto à sua resposta a cargas aplicadas sobre sua superfície;
- Produzir a matriz de sensoriamento tátil com 4 sensores multiplexados em série;
- Caracterizar e testar a matriz de sensoriamento tátil quanto à capacidade de detecção de cargas aplicadas sobre a sua superfície utilizando um número de regiões de sensoriamento maior do que o número de sensores;
- Utilizar métodos matemáticos e computacionais para a análise dos sinais óticos fornecidos pela matriz de sensoriamento.

1.4 ESTRUTURA

Este trabalho está dividido em 4 capítulos. O primeiro apresenta as motivações, estado da arte e objetivos.

O segundo apresenta uma revisão teórica acerca dos sensores óticos baseados em macrocurvatura e os métodos computacionais utilizados.

O terceiro capítulo apresenta a metodologia abordada durante o desenvolvimento do trabalho, juntamente com os resultados e discussões.

Por fim, no quarto capítulo, são expostas as considerações finais que resumem os resultados dos métodos propostos e avalia trabalhos futuros.


2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são apresentados alguns conceitos fundamentais para entendimento do desenvolvido no capítulo 3.

2.1 FIBRAS ÓTICAS

As fibras ópticas fazem parte de um subconjunto de estruturas nomeado de guias de onda óticos dielétricos, nos quais a potência luminosa derivada do emissor de luz é guiada para, por exemplo, um fotodetector. São constituídas por núcleo e casca de materiais dielétricos em que a diferença (ligeira) de índice de refração permite a propagação da luz por reflexões sucessivas (GIOZZA *et al.*, 1991). Caso o índice de refração do núcleo seja constante na dimensão do próprio núcleo, a fibra é considerada de índice degrau. Se o índice de refração do núcleo depender da posição radial, a fibra é classificada como fibra de índice gradual. A Figura 1 apresenta o desenho esquemático do aspecto geral de uma fibra óptica, apresentando (a) suas camadas (com o índice de refração do núcleo superior ao da casca) e (b) parte de um raio de luz sofrendo o fenômeno de reflexão interna total.

Figura 1 – Aspecto geral de uma fibra óptica (a) e caminho de um raio propagando com ângulo geométrico para a reflexão interna total (b).



Fonte: Adaptado de Brown (2002)

Existe um ângulo máximo de incidência da fonte de luz que penetra no núcleo da fibra em relação ao seu eixo longitudinal que permite a energia luminosa propagar no núcleo sem que haja perda significativa para a casca. Assim, o seno do ângulo máximo

pode ser chamado de abertura numérica da fibra. Por meio da análise geométrica, define-se a abertura numérica como (MITSCHKE, 2010)

$$AN = \sqrt{n_0^2 - n_1^2} \quad (1)$$

sendo n_0 e n_1 os índices de refração do núcleo e da casca, respectivamente.

Para que a luz (comportando-se como uma onda) permaneça no guia de onda, a fibra ótica, deve ser satisfeita a condição de auto interferência, o que seria demonstrado geometricamente por uma faixa contínua de feixes refletidos. Esta condição é solucionada por caminhos finitos existentes que são chamados de modos eletromagnéticos de propagação que dependem da estrutura do guia. Existem as fibras que suportam um grande número de modos, geralmente caracterizadas por grande núcleo, que permitem análise geométrica. E as fibras que suportam poucos modos, que são analisadas através das soluções das equações de Maxwell com adequadas condições de contorno (BROWN, 2002).

As fibras que possuem um diâmetro de núcleo muito grande comparado ao comprimento de onda da luz guiada e, portanto, muitos modos, são chamadas de multimodo (MMF – Multimode fiber). As que suportam modo único, por consequência, são chamadas de monomodo (SMF – Single mode fiber).

Um parâmetro importante que caracteriza a presença de modos em fibras é chamado de frequência normalizada definida por V , descrita como

$$V = \frac{2\pi}{\lambda} r AN \quad (2)$$

em que λ_0 é o comprimento de onda da luz guiada, r é o raio do núcleo da fibra e AN , a abertura numérica definida na Equação (1). Para que uma fibra se comporte como monomodo o valor da frequência normalizada deve ser inferior a 2,405, caracterizado como condição de corte (MITSCHKE, 2010). Quanto maior o valor da frequência normalizada, mais modos são encontrados, proporcionalmente, para menores valores de comprimentos de onda. Pode-se associar ao V o comprimento de onda de corte que define o valor mínimo para que as fibras se comportem como monomodo. Dessa forma, a equação que apresenta o comprimento de onda de corte é (em μm)


$$\lambda_c = \frac{2\pi}{2,405} r AN \quad (3)$$

2.1.1 Atenuação do sinal em fibras óticas

As perdas de sinal nas fibras óticas podem ser causadas por fatores como: absorção do material, que ocorre pela absorção da própria sílica fundida ou por impurezas presentes; espalhamento Rayleigh, causado pelas perdas resultantes das diferentes densidades das moléculas da sílica no momento de fabricação da fibra; e imperfeições do próprio guia, como anormalidades entre o núcleo e a casca ou curvaturas (AGRAWAL, 2010).

Portanto, perdas do sinal ótico podem estar associadas com curvaturas, que podem ser classificadas em micro ou macrocurvatura. As microcurvaturas possuem raios de curvatura de ordem de grandeza próxima de nanômetros e estão associadas, geralmente, a pequenos defeitos durante o processo de fabricação das fibras óticas, mas podem ser produzidas propositalmente para sensoriamento através de dispositivos pontiagudos, como representado na Figura 2.

Figura 2 – Representação da criação de microcurvaturas.



Fonte: Adaptado de Krohn *et al.* (2014)

A magnitude das perdas por microcurvaturas pode ser calculada por

$$A_m = \frac{N \langle h^2 \rangle r^4}{c^6 \Delta^3} \left[\frac{E}{E_f} \right]^{\frac{3}{2}} \quad (4)$$


onde N é a quantidade de microcurvaturas na seção da fibra, $\langle h^2 \rangle$ representa a média da altura projetada h da curvatura, r é o raio do núcleo da fibra, c o diâmetro externo da fibra (revestimento), E e E_f são os módulos elásticos do revestimento e do núcleo da fibra, respectivamente, e Δ indica o índice relativo, diferença entre os índices de refração da casca e do núcleo (QIU *et al.*, 2015).

Nota-se a relação proporcional entre atenuação e o raio do núcleo da fibra, indicando que, para aumentar a atenuação, deve haver incremento no raio do núcleo

ou diminuição do diâmetro externo do revestimento, que é inversamente proporcional, assim como a diminuição do índice de refração relativo.

As macrocurvaturas são da ordem de milímetros ou alguns centímetros de raio de curvatura e, portanto, muito maiores em relação às dimensões do núcleo da fibra. Como se observa na Figura 3, a região de macrocurvatura é compreendida entre os pontos 1 e 2, onde existe a perda de potência ótica, resultando em uma potência, após o ponto 2, menor do que a encontrada antes do ponto de início da curvatura, ponto 1.

Figura 3 – Diagrama representando a macrocurvatura em fibras óticas.



Fonte: Autoria própria (2020)

A perda por curvatura para uma fibra de índice degrau foi estabelecida matematicamente em 1976 por Dietrich Marcuse (MARCUSE, 1976) e possui o seguinte formato:

$$At = \frac{A}{\sqrt{R}} \exp(-BR) \quad (5)$$

em que At representa a atenuação por unidade de comprimento, R é o raio de curvatura estabelecido e A e B são dados por:

$$A = \frac{\sqrt{\pi} \kappa^2}{2\gamma^{\frac{3}{2}} (VK_1(\gamma r))^2} \quad (6)$$

$$B = \frac{2\gamma^3}{3\beta^2} \quad (7)$$

sendo r o raio do núcleo da fibra, K_1 a função modificada de Hankel, κ é a constante de fase radial dada por $\kappa = \sqrt{n_{\text{núcleo}}^2 k^2 - \beta^2}$ (sendo $k = \frac{2\pi}{\lambda}$), γ é a constante de atenuação radial descrita por $\gamma = \sqrt{\beta^2 - n_{\text{casca}}^2 k^2}$, β é a constante de propagação, $\beta = n_{\text{casca}} k$, e V (Equação (2)) a frequência normalizada. Esses parâmetros, com exceção do raio de curvatura, serão fixos para fibras monomodo e a partir do momento que se define o comprimento de onda da luz incidente. Assim, a atenuação por curvatura dependerá exponencialmente do raio da macrocurvatura e do comprimento de onda da luz incidente.

2.1.1.1 Modos Sussurantes (*Whispering Gallery Modes*)

O conceito associado aos modos sussurrantes (ou modos de galeria sussurrantes), do inglês *Whispering gallery modes* (WGM), teve início no século passado quando se observou o efeito de ondas acústicas em uma galeria na catedral de St. Paul em Londres Rayleigh (1910). O fenômeno, registrado por Lord Rayleigh, permitia que sussurros fossem escutados ao longo da superfície do domo, côncavo, desde que o emissor e o receptor estivessem próximos à essa superfície. Tal fato foi justificado pelas sucessivas reflexões das ondas acústicas emitidas de superfícies próximas do topo da galeria. Antes da definição desses modos, sabia-se que ondas propagadas em arcos pertencentes ao formato côncavo da galeria deveriam se concentrar no ponto localizado exatamente oposto diametralmente à fonte sonora. Contudo, Rayleigh somou a esse efeito o fato de que o som se “prende” à superfície e é transmitido ao longo da mesma (ORAEVSKY, 2002).

Este efeito pode ser aplicado para as macrocurvaturas em fibras óticas, na qual a curvatura induz a presença de WGMs, facilitando sua propagação pelo acoplamento do modo do núcleo com o modo de casca (CHIANG; CHAO, 2013). Assim, quando a fibra é curvada, energia é perdida na forma de radiação, que pode ser refletida na superfície entre a casca e o meio externo ou entre a casca e o revestimento, criando esses modos de “sussurro”. Contudo, como mencionado, esses modos podem ser acoplados novamente ao núcleo formando padrões de interferência. As curvas de interferência podem ser distintas e dependem do tamanho do raio de curvatura estabelecido, assim como do ângulo de curvatura (MORGAN *et al.*, 1990). De acordo com a Figura 4, os mínimos de perda de potência oscilatória seguem a condição de

interferência (HARRIS; CASTLE, 1986)


$$2\pi n_{casca} \frac{(L_1 + L_2)}{\lambda} + \phi - Z\beta = m2\pi \quad (8)$$

com m sendo um inteiro de valor 0, 1, 2 etc., ϕ é a constante de fase, β é a constante de propagação, L_1 e L_2 são os comprimentos dos raios dos WGM e Z é o comprimento do arco. Os últimos três parâmetros, podem ser escritos em função do raio de curvatura (R) como

$$L_1 = L_2 = \sqrt{(R + w)^2 - (R + d)^2} \quad (9)$$

$$Z = 2R \tan^{-1}\left(\frac{L_1}{R + d}\right) \quad (10)$$

Figura 4 – Curvatura em fibra indicando a formação dos *whispering gallery modes*.



Fonte: Adaptado de Harris e Castle (1986)


A distância y representa a posição em que os raios dos WGM tocam o limite entre a casca e o meio externo em relação ao núcleo da fibra, assim como a distância d indica o local em relação ao núcleo da fibra em que os raios ficarão confinados para a reflexão total. Essa última pode ser chamada de distância de acoplamento, podendo também ser expressa em função do raio de curvatura

$$d = R \left(\frac{\beta \lambda}{2\pi n_{casca}} - 1 \right) \quad (11)$$

2.2 SENSORES DE MACROCURVATURA

As perdas por curvatura e os WGM podem contribuir para a aplicação das fibras óticas como sensores. Neste sentido, os sensores de macrocurvatura são sensores baseados em modulação por intensidade, que utilizam o sinal ótico transmitido, ou refletido, como medição e, provavelmente, são os sensores mais simples dessa classificação (CONNELLY, 2005). A modulação por intensidade é resultado de perturbações causadas na fibra ou de alterações em transdutores presentes no caminho ótico (KROHN *et al.*, 2014). A Figura 5 ilustra o esquema básico dos componentes presentes num sistema baseado em sensores óticos. É necessário haver a fonte de luz (Laser, LED etc.), o transdutor (que neste trabalho é representado pelo sensor de curvatura), o detector (espectrômetro, por exemplo) e a análise do resultado obtido. A ação externa é feita pelo que se deseja ser medido, podendo ser vibração, pressão ou força.

Figura 5 – Desenho esquemático dos componentes básicos de um sistema baseado em sensor a fibra ótica.



Fonte: Autoria própria (2020)

O princípio de funcionamento do sensoriamento por macrocurvatura baseia-se na transformação do parâmetro físico a ser medido em sinal ótico. Assim, com o sistema montado, define-se um estado de referência do sinal que, ao sofrer as perturbações externas, é captado e avaliado. A curvatura presente no transdutor altera-se conforme é excitada e, portanto, altera o estado de referência do sistema pelas perdas de sinal, podendo ser medido em relação ao anterior.


A implementação desse tipo de sistema é relativamente simples, pois não apresenta nenhuma modificação na fibra em si, a não ser pela criação da curvatura, diferentemente do caso de outros sensores como os de FBG que necessitam alterar a estrutura da fibra, ou seja, basicamente alterar um trecho do núcleo. Outras vantagens

desse tipo de sensor são o baixo custo, quando comparadas aos outros sensores óticos que necessitam mais equipamentos ou processos intermediários para o sistema final, e podem ser multiplexados e atuarem como sensores distribuídos (FIDANBOYLU K; EFENDIOGLU, 2009). Como desvantagem, pode haver oscilação e variações na medição por conta da fonte de luz, problema que pode ser resolvido com um sistema de referência.

2.3 TÉCNICAS DE MULTIPLEXAÇÃO

Um sistema é considerado multiplexado quando se utiliza apenas um detector ou fonte única para pelo menos dois sensores. A Figura 6 apresenta um exemplo de esquema básico de um sistema multiplexado ótico em que se compartilha o mesmo detector e a mesma fonte de luz para a captação de parâmetros ('A') por sensores distribuídos no mesmo caminho de fibra ótica.

Figura 6 – Representação básica de um sistema ótico multiplexado.



Fonte: Autoria própria (2020)


Os sistemas óticos multiplexados possuem algumas características que são utilizadas para otimizar sua implementação. É preciso definir a quantidade de elementos sensores presentes, o tamanho da matriz sensorial, as distâncias entre os elementos distribuídos e seus componentes (fonte e detector, por exemplo), assim como a quantidade de parâmetros a serem medidos.

Existem diferentes técnicas de multiplexação que podem ser classificadas em cinco categorias: multiplexação espacial, multiplexação por divisão de tempo, multiplexação por divisão de frequência, multiplexação por divisão de comprimento de onda e multiplexação por coerência (CRANCH, 2014). Assim como as técnicas, também é possível classificar os sistemas multiplexados de acordo com a topologia: paralela, na qual os sensores são distribuídos em fibras distintas compartilhando a

mesma fonte de luz e/ou detector(es); série, em que se utiliza apenas uma fibra com os sensores distribuídos ao longo do caminho da mesma podendo ser utilizados em reflexão ou transmissão; e a escada, que é similar à paralela com a diferença de que se utiliza quando há necessidade de se distribuir os sensores muito próximos e espaçados igualmente para que a energia da fonte seja distribuída igualmente.

A multiplexação espacial é a mais simples e utiliza sensores distribuídos em fibras separadas e paralelas compartilhando a mesma fonte de luz. Possui facilidade de implementação, porém dispõe de vários detectores, cabos e conectores, podendo o peso e o custo serem desfavoráveis em comparação com as outras técnicas (DAKIN, 1987). A Figura 7 apresenta um exemplo de esquema básico da técnica por multiplexação espacial composto por uma fonte de luz, três sensores e um detector para cada caminho de fibra.

Figura 7 – Representação da técnica de multiplexação espacial.



Fonte: Autoria própria (2020)

A segunda técnica de multiplexação é a por divisão de tempo, TDM do inglês *time division multiplexing*. É baseada pela diferença de tempo de retorno entre os sensores causada pelo atraso na propagação do sinal de cada elemento sensor. A TDM pode ser implementada em série, paralelo ou topologias escada, e pode ser utilizada no domínio do tempo com pulsos óticos ou no domínio da frequência, com diferenças de trânsito entre os sensores, em que se observa a mudança de fase da luz refletida (ou transmitida) em cada frequência em relação à referência de atraso nulo (CRANCH, 2014). Como vantagens em relação à técnica anterior, a TDM possui apenas um detector, assim como uma fonte de luz, podendo num único caminho de fibra conter centenas de elementos por longas distâncias, além de poder utilizar topologias

em série ou paralelo. Como negativa, não satisfaz sistemas que necessitam sensores muito próximos, pois é utilizada com separação de alguns metros entre os pontos de medição.

A técnica seguinte, também conhecida como FDM, do inglês *frequency domain multiplexing*, utiliza a frequência espacial como base. Assim como a TDM, pode ser utilizada em paralelo, série ou escada. Esta técnica usa o fato de que cada sensor presente pode ser identificado por baixas frequências específicas pertencentes à uma fonte de banda larga. São fáceis de implementar, porém limitantes em relação à largura de banda utilizada que, por consequência, limita a quantidade de elementos no sistema, além de possuírem velocidade menor quando comparadas ao método anterior (TDM).

A técnica por divisão de comprimento de onda (WDM – *wavelength division multiplexing*) utiliza a banda larga (dezenas de terahertz) para codificar os sensores. Utiliza o princípio da FDM, porém combina múltiplos canais portadores de diferentes comprimentos de onda num único, para depois separá-los novamente, técnica muito usada em sistemas de comunicação (AGRAWAL, 2010). Pode-se utilizar várias fontes com comprimentos de onda distintos ou uma fonte com espectro largo, subdividindo-o para canais menores. A principal diferença da WDM para a FDM está no fato de que a FDM não precisa ser utilizada necessariamente em sistemas óticos, por ser baseada em poucos canais de transmissão. Já a WDM, é utilizada exclusivamente para sistemas óticos, com a possibilidade de multiplexar milhões de sinais.

A última técnica, multiplexação por coerência, utiliza o conceito de que um sinal modulado pode ter suas informações recuperadas relacionando o sinal recebido com um sinal de referência definido, podendo esse último ser de uma fonte de luz como o laser (CRANCH, 2014). Possui como desvantagem em relação aos métodos anteriores não poder suportar a mesma capacidade de multiplexação, mas não necessita de equipamentos como moduladores de comprimento de onda ou de amplificação.

2.4 REGRESSÕES LINEARES

Os primeiros formatos dos modelos lineares foram baseados no método de mínimos quadrados (*least squares*) originados de trabalhos publicados pelo francês Legendre, em 1805, e pelo alemão Gauss, em 1809 (YAN; SU, 2009). Estes trabalhos aplicaram o método à astronomia para determinar a órbita de objetos ao redor do sol.

Em 1821, Gauss publicou uma versão mais desenvolvida do método utilizada até hoje, conhecida como teorema Gauss-Markov.

Os métodos de regressão tentam verificar a relação entre variáveis dependentes (chamadas também de preditas ou respostas, denotadas geralmente por y) e independentes, denotadas usualmente por x . As regressões podem ser classificadas em três grupos: regressões lineares simples, regressões lineares múltiplas e regressões não lineares. Como os métodos do presente trabalho foram baseados em regressões lineares, trataremos das regressões lineares simples e múltiplas.

Na regressão linear simples, há apenas uma variável independente x e uma variável dependente y (ALTMAN; KRZYWINSKI, 2015). O formato típico desta regressão é indicado por uma função do primeiro grau, dada por

$$y = \beta_0 + \beta_1 x + \varepsilon \quad (12)$$

em que β_0 representa o termo independente (local onde a função intercepta o eixo das ordenadas), β_1 é o coeficiente angular (inclinação da reta da regressão) e ε é um erro aleatório associado ao modelo. De forma geral, a expressão para uma regressão pode ser escrita como

$$y = E(y) + \varepsilon \quad (13)$$

sendo $E(y)$ a resposta esperada para a variável dependente. Se a expressão $E(y)$ for uma função linear, a regressão será linear. Se a expressão for, por exemplo, uma exponencial, a regressão será não linear. Portanto, definindo como linear a regressão, geralmente assume-se que $E(\varepsilon) = 0$ e a variância constante $Var(\varepsilon) = \sigma^2$ (YAN; SU, 2009). Experimentalmente, para a regressão linear simples, observa-se pares de dados $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ expressos por

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i, \text{ para } i = 1, 2, \dots, n \quad (14)$$

com $E(\varepsilon_i) = 0$ e variância constante $Var(\varepsilon_i) = \sigma^2$. Cada erro é independente e a variância desconhecida, sendo os valores das variáveis independentes sem erro associado. Assim, a Equação (14) define o formato básico que representa as regressões lineares simples. O próximo passo seria, com os dados coletados em um suposto

experimento, estimar os valores de β_0 e β_1 , também chamados de parâmetros do modelo.

A diferença da regressão linear simples para a regressão linear múltipla é que, nesta última, há possibilidade de associar mais de uma variável independente (x) para cada variável dependente (y) (WEISBERG, 2013). Dessa forma, o modelo da regressão múltipla pode ser descrito por

$$y = \beta_0 + \beta_1 x + \beta_2 x_2 + \cdots + \beta_k x_k + \varepsilon \quad (15)$$

Portanto, cada dado não será mais descrito como um par, mas como um valor resposta referente a um vetor de parâmetros independentes, ou seja, apenas um parâmetro medido ou coletado não pode representar totalmente os valores de y , dependendo de mais fatores para ser estabelecido. Como anteriormente, o próximo passo da regressão é definir os valores de $\beta_0, \beta_1, \dots, \beta_k$ que vão caracterizar o modelo. Esses parâmetros podem ser definidos de acordo com alguns métodos, descritos na sequência.

2.4.1 Mínimos Quadrados

O método dos mínimos quadrados, OLS – *Ordinary Least Squares*, é um dos que podem ser utilizados para determinar os parâmetros, ou coeficientes, da regressão linear. O objetivo é minimizar uma quantidade chamada de soma residual dos quadrados, também conhecida por RSS – *Residual Sum of Squares*. Para que isso ocorra, o método desenvolve-se buscando definir estimadores que relacionam a resposta real do sistema com a resposta prevista. Se y_i é a resposta real (ou desejada), $\hat{y}_i$ é o valor previsto. De forma geral, a RSS é apresentada por

$$RSS = \sum_{i=1}^n \varepsilon_i^2 \quad (16)$$

sendo ε o valor a ser minimizado (BINGHAM; FRY, 2010).

Assim, o valor a ser minimizado para a regressão linear será dado pela diferença entre o valor real ou desejado e o valor obtido experimentalmente, por exemplo. Substituindo, então, na Equação (16) o valor a ser minimizado, inicialmente para a

regressão linear simples, de acordo com a Equação (14), obtém-se

$$RSS = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (17)$$

$$(\beta_0, \beta_1) = RSS(\beta_0, \beta_1) = \sum_{i=1}^n [y_i - (\beta_0 + \beta_1 x_i)]^2 \quad (18)$$

Como se deseja obter o mínimo dessa função, deve-se derivá-la em relação a cada estimador a ser encontrado e igualá-la a zero, gerando as seguintes equações

$$\frac{\partial}{\partial \beta_0} RSS = \frac{\partial}{\partial \beta_0} \sum_{i=1}^n [y_i - (\beta_0 + \beta_1 x_i)]^2 = 0 \quad (19)$$

$$\frac{\partial}{\partial \beta_1} RSS = \frac{\partial}{\partial \beta_1} \sum_{i=1}^n [y_i - (\beta_0 + \beta_1 x_i)]^2 = 0 \quad (20)$$

tendo por resultado

$$\frac{\partial}{\partial \beta_0} RSS = -2 \sum_{i=1}^n [y_i - (\beta_0 + \beta_1 x_i)] = 0 \quad (21)$$

$$\frac{\partial}{\partial \beta_1} RSS = -2 \sum_{i=1}^n x_i [y_i - (\beta_0 + \beta_1 x_i)] = 0 \quad (22)$$

Multiplicando a Equação (21) por $\frac{1}{n}$ e separando o operador, tem-se

$$-\frac{\sum_{i=1}^n y_i}{n} + \frac{\sum_{i=1}^n \beta_0}{n} - \frac{\sum_{i=1}^n \beta_1 x_i}{n} = 0 \quad (23)$$

$$-\frac{\sum_{i=1}^n y_i x_i}{n} + \frac{\sum_{i=1}^n \beta_0 x_i}{n} - \frac{\sum_{i=1}^n \beta_1 x_i^2}{n} = 0 \quad (24)$$

Os termos que apresentam as variáveis no aspecto $\frac{\sum_{i=1}^n u_i}{n}$ representam as médias amostrais das variáveis em questão (x e y), podendo representa-los por $\bar{x}$ e $\bar{y}$. Pode-se então reescrevê-las como

$$-\bar{y} + \beta_0 - \beta_1 \bar{x} = 0 \quad (25)$$

$$-\bar{y}\bar{x} + \beta_0 \bar{x} - \beta_1 \bar{x}^2 = 0 \quad (26)$$

Da Equação (25) obtêm-se β_0 ,

$$\beta_0 = \bar{y} + \beta_1 \bar{x} \quad (27)$$

Para representar β_1 , substitui-se a Equação (27) na Equação (26), resultando em

$$\beta_1 = \frac{\overline{yx} - \bar{x}\bar{y}}{\overline{x^2} - (\bar{x})^2} \quad (28)$$

Com esses valores, é possível definir a equação que representa a regressão linear que ajusta os valores de dados obtidos experimentalmente em comparação com o que se esperava encontrar.

Expandindo a análise para a regressão linear múltipla, leva-se em consideração as múltiplas variáveis independentes para cada variável dependente, de acordo com a equação Equação (15). O modelo linear também pode ser expresso como

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon} \quad (29)$$

em que

$$\mathbf{y} = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix}, \mathbf{X} = \begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1k} \\ x_{21} & x_{22} & \cdots & x_{2k} \\ \cdots & \cdots & \cdots & \cdots \\ x_{n1} & x_{n2} & \cdots & x_{nk} \end{pmatrix}, \boldsymbol{\beta} = \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_{k-1} \end{pmatrix} \text{ e } \boldsymbol{\varepsilon} = \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_k \end{pmatrix} \quad (30)$$

Da mesma forma, espera-se minimizar o RSS que, de acordo com seu princípio para regressão linear múltipla (YAN; SU, 2009), pode ser obtido pela multiplicação de uma matriz transposta por sua original

$$RSS(\boldsymbol{\beta}) = \sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n [(\mathbf{y} - \mathbf{X}\boldsymbol{\beta})^t (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})] \quad (31)$$

Assim como anteriormente, deriva-se a função em relação à matriz $\boldsymbol{\beta}$ e a iguala a zero para obter seu mínimo

$$\frac{\partial}{\partial \boldsymbol{\beta}} [(\mathbf{y} - \mathbf{X}\boldsymbol{\beta})^t (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})] = 0 \quad (32)$$

ou, igualmente,

$$\frac{\partial}{\partial \beta} [(y^t y - 2y^t X \beta + \beta^t X^t X \beta)] = 0 \quad (33)$$

Realizando a derivada parcial, obtêm-se a equação que representa o modelo de regressão linear múltipla

$$X^t X \beta = X^t y \quad (34)$$

Desde que a multiplicação $X^t X$ gere uma matriz não singular, pode-se reescrever a Equação (34) com a matriz β isolada, solução do sistema, conhecida por $\hat{\beta}$, como

$$\hat{\beta} = (X^t X)^{-1} X^t y \quad (35)$$

2.4.2 Métodos de regressão alternativos ao OLS

Existem maneiras de estender o método de regressão por mínimos quadrados (OLS) tentando melhorá-lo, através de alguns procedimentos de ajuste. Esses métodos podem melhorar algumas características como a precisão da previsão das variáveis do sistema, assim como a interpretação do modelo.

Em relação à precisão da previsão, sabendo que a relação entre as variáveis é linear, o método dos OLS terá um pequeno *bias* (desvio do valor real). Caso o número de amostras seja muito maior que o número de variáveis, o método por mínimos quadrados funcionará bem, tendo pouca variância. Caso contrário, com o número de variáveis muito superior ao número de amostras, pode haver instabilidade no ajuste da OLS, causando *overfitting* (ou sobreajuste), ou seja, adequando-se muito bem àquele conjunto de dados utilizado nos modelo, porém não conseguindo reconhecer novas observações e, conseqüentemente, aumentando a variância dos dados (JAMES *et al.*, 2013).

A interpretação do modelo diz respeito à relevância que as variáveis possuem em relação à resposta que se deseja do sistema. Podem existir variáveis que não influenciam significativamente o modelo, possuindo um papel desnecessário que prejudica a complexidade e resultado. Caso os coeficientes correspondentes a essas variáveis sejam próximos de zero ou nulos, é possível tornar o modelo mais eficiente.

Dentre as alternativas existentes ao OLS que ainda utilizam seu conceito, porém de forma estendida, destacam-se: modelos de seleção de subconjunto (*Subset selection*), em que se identifica um subconjunto do total de variáveis que se acredita serem as melhores relacionadas à resposta; modelos de encolhimento (*Shrinkage*), nos quais o objetivo é utilizar todo o conjunto de variáveis com a diferença de tentar aproximar do zero aquelas que são irrelevantes para o sistema; e modelos de redução da dimensão (*Dimension reduction*), que envolvem projetar as variáveis para um subespaço de menor dimensão, criando novas combinações lineares das variáveis (JAMES *et al.*, 2013).

Neste trabalho, além de implementar o método OLS, optou-se por utilizar dois métodos de encolhimento. Este encolhimento (também chamado de regularização) penaliza, como já citado, as variáveis definidas como irrelevantes para o sistema. Os métodos escolhidos para comparação são: a regressão Ridge e a regressão Lasso.

2.4.2.1 Regressão Ridge

A regressão Ridge (traduzido por ‘cume’) utiliza o princípio da regressão por mínimos quadrados com a diferença de utilizar uma parcela a mais em sua função de minimização e teve seu embasamento com a publicação do artigo “*Ridge Regression: Biased Estimation for Nonorthogonal Problems*” em 1970, por Hoerl e Kennard (HOERL; KENNARD, 1970).

Para o método dos mínimos quadrados, o objetivo era minimizar o erro da função linear, mantendo um pequeno desvio do valor real e, portanto, uma variância mínima. Essa estimacão é boa se a matriz $X^t X$ da Equação (35) – que é uma matriz de covariância, ou seja, que apresenta os valores de como cada variável independente correlaciona entre si – for próxima de uma matriz identidade, pois sua diagonal representará as covariâncias das variáveis com elas mesmas: as variâncias de X (HOERL; KENNARD, 1970). Caso contrário, o método da OLS apresentará inconsistências ou problemas numéricos, e poderá não ser eficaz para o problema em questão correlacionando altamente as variáveis, problema chamado de multicolinearidade.

Para resolver o problema da multicolinearidade, um termo é acrescentado à solução da regressão por mínimos quadrados, criando o estimador Ridge. A análise desse estimador pode ser feita, inicialmente, através do erro quadrático médio, MSE

(*Mean Squared Error*), dos parâmetros para o método dos mínimos quadrados (YAN; SU, 2009). O MSE é a média da diferença entre um parâmetro e um estimador ao quadrado que, aplicado aos parâmetros das regressões, tem a forma de

$$MSE(\mathbf{B}) = E \|\mathbf{B} - \boldsymbol{\beta}\|^2 \quad (36)$$

sendo $\mathbf{B}$ a matriz com os estimadores para os parâmetros ideais, e $\boldsymbol{\beta}$, da regressão. Este MSE pode ser subdividido em dois termos: o *bias* quadrático e a variância:

$$E\|\mathbf{B} - \boldsymbol{\beta}\|^2 = \sum_j [E(B_j - \beta_j)]^2 + \sum_j Var(B_j) \quad (37)$$

Conforme visto, a aproximação por mínimos quadrados resulta na menor variância para os estimadores. Porém, não necessariamente garante o menor erro quadrático médio. Considerando $\hat{\boldsymbol{\beta}}(ls)$ os estimadores para a OLS, conforme a Equação (35), sabe-se que $E(\hat{\boldsymbol{\beta}}(ls)) = \boldsymbol{\beta}$ e que a covariância é $Cov(\hat{\boldsymbol{\beta}}(ls)) = \sigma^2(\mathbf{X}^t \mathbf{X})^{-1}$. Assim, pode-se escrever o MSE como (YAN; SU, 2009)

$$\begin{aligned} MSE(\hat{\boldsymbol{\beta}}(ls)) &= E\|\hat{\boldsymbol{\beta}}(ls)\|^2 - \|\boldsymbol{\beta}\|^2 = \\ &tr[\sigma^2(\mathbf{X}^t \mathbf{X})^{-1}] = \sigma^2 tr[(\mathbf{X}^t \mathbf{X})^{-1}] \end{aligned} \quad (38)$$

e, portanto,

$$E\|\hat{\boldsymbol{\beta}}(ls)\|^2 = \|\boldsymbol{\beta}\|^2 + \sigma^2 tr[(\mathbf{X}^t \mathbf{X})^{-1}] \quad (39)$$

sendo a função ‘tr’ a soma dos valores da diagonal da matriz $(\mathbf{X}^t \mathbf{X})^{-1}$. Demonstra-se assim que, com uma matriz $(\mathbf{X}^t \mathbf{X})^{-1}$ mal condicionada, o método dos mínimos quadrados apresentaria erros de aproximação grandes em $\|\hat{\boldsymbol{\beta}}(ls)\|^2$, chamados também de erros inflados (HOERL; KENNARD, 1970), representando fracamente o modelo desejado.

Considerando $\mathbf{B}$ qualquer estimador de $\hat{\boldsymbol{\beta}}(ls)$, de acordo com a Equação (31), o critério para o método dos mínimos quadrados pode ser reescrito como

$$= (\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}}(ls))^t (\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}}(ls)) + (\mathbf{B} - \hat{\boldsymbol{\beta}}(ls))^t \mathbf{X}^t \mathbf{X} (\mathbf{B} - \hat{\boldsymbol{\beta}}(ls))$$

$$\begin{aligned}\phi &= (\mathbf{y} - \mathbf{XB})^t (\mathbf{y} - \mathbf{XB}) \\ &= \phi_{min} + \phi(\mathbf{B})\end{aligned}\quad (40)$$

O ponto principal para a regressão Ridge será minimizar $\|\beta\|^2$ sujeito a $(\mathbf{B} - \hat{\beta}(ls))^t \mathbf{X}^t \mathbf{X} (\mathbf{B} - \hat{\beta}(ls)) = \phi_0$, para uma constante ϕ_0 . Isso é equivalente a minimizar um problema de Lagrangian (HOERL; KENNARD, 1970) que é

$$F = \|\beta\|^2 + \frac{1}{k} [(\mathbf{B} - \hat{\beta}(ls))^t \mathbf{X}^t \mathbf{X} (\mathbf{B} - \hat{\beta}(ls)) - \phi_0] \quad (41)$$

em que $\frac{1}{k}$ é o multiplicador constante que satisfaz as restrições. Por fim, garantindo o mínimo da função da Equação (41) através da derivada $\frac{\partial F}{\partial \beta}$, obtém-se o estimador da regressão Ridge, que é

$$\beta = (\mathbf{X}^t \mathbf{X} + k\mathbf{I})^{-1} \mathbf{X}^t \mathbf{y} \quad (42)$$

Um modo equivalente de interpretar o problema da regressão Ridge é escrevê-lo da forma:

$$\text{Minimizar } \|\mathbf{y} - \mathbf{X}\beta\|^2, \text{ sujeito a } \|\beta\|^2 \leq s$$

para uma constante s , sendo $\|\beta\|^2 = \sum_{j=1}^p \beta_j^2$. Assim, o problema de Lagrangian será minimizar a função

$$\|\mathbf{y} - \mathbf{X}\beta\|^2 + \alpha \|\beta\|^2 \quad (43)$$

O parâmetro α (alfa), ou λ dependendo da literatura, é chamado de parâmetro de penalização, que deve ser maior ou igual a zero, e controla o encolhimento (*shrinkage*) da segunda parcela da Equação (43). Quanto maior seu valor, maior será a penalização. O termo $\alpha \|\beta\|^2$ também é chamado de regularização L2 (ou norma L2) e, apesar de penalizar os coeficientes menos relevantes ao modelo, apenas os aproxima de zero, não os anulando e mantendo a quantidade inicial de variáveis (ou parâmetros). Por esse motivo, o outro método que tenta aprimorar a penalização dos coeficientes relacionados às variáveis menos significativas é o Lasso.

2.4.2.2 Regressão Lasso

A regressão Lasso (*“least absolute shrinkage and selection operator”*) é uma extensão do método dos mínimos quadrados e foi proposta em 1996 com o artigo *“Regression Shrinkage and Selection via the Lasso”*, por Robert Tibshirani, e busca “encolher” alguns coeficientes para próximo de zero, muitas vezes anulando-os, com o objetivo de manter os melhores parâmetros do modelo (TIBSHIRANI, 1996).

Como comentado, pode haver uma desvantagem ao se usar a regressão Ridge: por não anular nenhum coeficiente do sistema, possíveis variáveis não relevantes continuarão presentes ao final do modelo. Portanto, a regressão atua em todas as variáveis iniciais e não realiza nenhum tipo de “seleção” de parâmetros, sendo a quantidade final de dados sempre igual a inicial.

O método Lasso, buscando resolver essa desvantagem, define o vetor de estimadores β , da forma:

$$\text{Minimizar } \|y - X\beta\|^2, \text{ sujeito a } \|\beta\| \leq s$$

para uma constante s , com $\|\beta\| = \sum_{j=1}^p |\beta_j|$ Ou, da forma a minimizar:

$$\|y - X\beta\|^2 + \alpha \|\beta\| \quad (44)$$

Fazendo a comparação entre a Equação (43) e a Equação (44) nota-se que a diferença entre as duas regressões está presente apenas na segunda parcela da função a ser minimizada que, agora, chama-se de regularização L1 (ou norma L1) (JAMES *et al.*, 2013). O que acontece é que a penalidade da Lasso força coeficientes do modelo a se anularem caso a constante de penalização (alfa) seja suficientemente grande, ou seja, a Lasso realiza uma seleção de variáveis do sistema.

2.5 VALIDAÇÃO CRUZADA

Dos três métodos de regressão linear mostrados, dois deles (Ridge e Lasso) necessitam da escolha de um valor de coeficiente de penalização, definido como alfa para ambos. O problema é que esses coeficientes devem ser definidos antes do modelo ser efetivamente analisado pelas regressões. Essa etapa anterior ao treinamento do


modelo, que envolve a escolha de seus parâmetros, é conhecida como seleção do modelo, que pode ser analisada através de métodos de reamostragem. Esses métodos buscam utilizar erros de testes ou precisão de parâmetros para que se otimize o modelo para treinamento.

Um desses métodos é a validação cruzada, que pode ser realizada analisando erros de testes de subconjuntos de dados ou erros de treinamento em relação ao conjunto completo de dados. O fato é que a validação cruzada é utilizada para definir os parâmetros de cada modelo que possibilitam melhorar o desempenho no treinamento. Também pode ser implementada caso já exista um modelo definido e se queira prever uma nova observação (JAMES *et al.*, 2013).

Ainda para a validação cruzada, existem duas principais formas de ser implementada: por *k-fold*, que envolve subdividir o conjunto de dados de forma aleatória em *k* grupos (*folds*) que tenham aproximadamente o mesmo tamanho, alternando testes para cada subconjunto; e o *leave-one-out*, que é um caso específico do anterior, porém, com *k* igual ao número de dados, gerando um teste e erro associado para cada dado. O problema do *leave-one-out* é que exige um custo computacional muito maior em relação ao *k-fold*, sendo utilizado preferivelmente para casos em que o conjunto de dados é pequeno. Por esse motivo, optou-se por utilizar neste trabalho como método de seleção de modelo a validação cruzada por *k-fold*.

O *k-fold*, portanto, separa o conjunto de dados em *k* grupos. Cada grupo é submetido a testes em relação ao subconjunto restante ajustado à regressão ou método de treinamento, gerando um erro baseado em MSE. Por exemplo, se um conjunto de dados for subdividido em 3 grupos (ou 3 *folds*), cada grupo terá um erro de teste em relação aos 2 grupos restantes ajustados à regressão. Desse modo, serão gerados três erros associados a cada grupo: MSE_1 , MSE_2 e MSE_3 . O erro total da validação cruzada será a média dos erros individuais. A Figura 8 ilustra este exemplo em que são definidos 3 subconjuntos de um conjunto com número de dados n . A cor laranja indica os subconjuntos submetidos ao testes em relação aos dados restantes, em marrom, ajustados ao modelo.

Figura 8 – Exemplo de utilização de k-fold para separar um conjunto de dados em 3 subgrupos de teste.



Fonte: Autoria própria (2020)

Assim, o cálculo do *k-fold* é definido por

$$VC_k = \frac{1}{k} \sum_{i=1}^k MSE_i \quad (45)$$

Para as regressões citadas, definindo-se aleatoriamente um valor de alfa antes do treinamento, utiliza-se o *k-fold* e verifica-se qual erro gerado. Na sequência, troca-se o valor de alfa e realiza-se o mesmo processo da validação para verificar o erro. Ou seja, a validação cruzada é utilizada nas regressões até que se obtenha o menor erro para diferentes valores de alfa. Uma vez escolhido o valor de alfa que resulta no menor MSE, pode-se partir para o treinamento efetivo das regressões.

2.6 ERRO ABSOLUTO MÉDIO

O erro absoluto médio (ou MAE – *Mean Absolute Error*) é a média da diferença entre o valor previsto e o valor real de algum sistema (TESFAMARIAM; LIU, 2013). Pode ser calculado através da fórmula:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (46)$$

com y_i , o valor real, e $\hat{y}_i$, o valor previsto.

Este erro foi definido para caracterizar o desempenho do presente trabalho, pois apresenta o erro absoluto do que se quer observar em termos da própria unidade da variável. Outras alternativas poderiam ser utilizadas, como o RSME, que é a raiz quadrada do MSE, porém é mais utilizado quando se quer definir sensibilidade de sistemas (CHAI; DRAXLER, 2014).

3 METODOLOGIA E RESULTADOS

Este capítulo tem por objetivo descrever os arranjos experimentais, os equipamentos, a produção dos dispositivos utilizados para a realização do trabalho e os resultados associados a cada etapa. A sequência apresenta a produção dos sensores individuais e sua caracterização, a produção da matriz tátil e suas análises relacionadas à multiplexação e resposta acoplada dos sensores.


3.1 SENSOR DE MACROCURVATURA

O funcionamento do sistema tátil deste trabalho baseia-se na detecção da modulação de intensidade dependente do comprimento de onda resultante da ativação de um ou mais sensores de macrocurvatura que compõem a matriz de sensores multiplexados. Primeiramente, foram produzidos e avaliados individualmente os elementos sensores de macrocurvatura, usados para produzir a matriz. O processo para a produção dos elementos sensores individuais envolve três etapas: a confecção dos laços de fibra ótica para se produzir a macrocurvatura, o encapsulamento do laço, criando um pequeno cilindro de silicone que fornece sustentação ao laço e mantém sua forma, e a produção do elemento sensor, também de aspecto cilíndrico e encapsulado em elastômero de silicone.

3.1.1 Produção do elemento sensor

Na primeira etapa de produção, a macrocurvatura é obtida curvando-se a fibra ótica (SMF, G-652, Draktel), que possui diâmetro da casca de $(125,0 \pm 1,0)$ nm e comprimento de corte ≤ 1260 nm, comportando-se como multimodo para valores de comprimento de onda abaixo deste. Tal curvatura é produzida com o auxílio de um molde em acrílico até se obter laços com aproximadamente 5,0 mm de diâmetro, como mostra a Figura 9. Tal diâmetro de laço garante a integridade do sensor evitando o rompimento da fibra ao longo da sua utilização, além de resultar num sensor com sensibilidade adequada para a aplicação proposta.


Figura 9 – Desenho esquemático do laço na fibra ótica utilizado para criação dos sensores de macrocurvatura.



Fonte: Autoria própria (2020)

Para conceder resistência mecânica aos laços criados, na segunda etapa da produção, os mesmos são fixados em moldes cilíndricos e posteriormente preenchidos com elastômero de silicone líquido (Dow Corning BX3 – 8001). Após a cura por meio de um catalisador, obtém-se um pequeno cilindro com $(7,00 \pm 0,05)$ mm de diâmetro e $(10,00 \pm 0,05)$ mm de altura, conforme esquema da Figura 10. Esse processo é necessário para facilitar o alinhamento e a fixação dos laços de fibra no decorrer da fabricação dos elementos sensores. A escolha deste elastômero de silicone foi decorrente do fato do mesmo já ter sido usado em trabalhos anteriores para encapsulamento de sensores baseados em FBGs, nos quais a histerese e as características de sensibilidade foram estudadas (KAMIZI *et al.*, 2017; PEDROSO *et al.*, 2018).


Figura 10 – Aspecto do encapsulamento do laço em pequeno cilindro, referente à segunda etapa da produção dos sensores.



Fonte: Autoria própria (2020)


Na terceira etapa de fabricação, o pequeno cilindro é posicionado em um novo molde e preenchido novamente com o mesmo elastômero gerando, finalmente, o elemento sensor cilíndrico baseado em macrocurvatura com $(7,00 \pm 0,05)$ mm de altura e $(20,00 \pm 0,05)$ mm de diâmetro. A Figura 11 apresenta um diagrama esquemático do elemento sensor e a Figura 12 mostra o sensor produzido.

Figura 11 – Diagrama esquemático do sensor final indicando: (a) visão geral do sensor e (b) um corte transversal.



Fonte: Autoria própria (2020)

Figura 12 – Sensor de macrocurvatura produzido.




Fonte: Autoria própria (2019)

3.1.2 Caracterização do elemento sensor

Uma vez definidos os métodos de produção dos sensores, fez-se necessário avaliar o comportamento de cada elemento em relação às grandezas a serem medidas e avaliadas. Dessa forma, foi adotada uma metodologia de caracterização na qual o elemento sensor foi submetido a experimentos para avaliar sua resposta a cargas aplicadas sobre uma das bases do cilindro. Para tanto, utilizou-se como sinal de entrada uma fonte de luz no visível (LS-1 Tungsten halogen lamp, Ocean Optics, 360 a 2000 nm) e um espectrômetro (HR4000, Ocean Optics) para coletar o espectro de transmissão do sensor. Para a adequada aplicação de cargas sobre o sensor, foi montada uma estrutura de madeira (MDF) em forma retangular possuindo duas bases: uma inferior para posicionamento dos sensores e uma superior perfurada para posicionamento das hastes cilíndricas de aplicação de carga. Para os experimentos, os sensores individuais foram posicionados exatamente no centro da base inferior, alinhados com a haste de aplicação de carga. Estas hastes foram confeccionadas com tubos de policloreto de vinila (PVC), sendo colocado na extremidade inferior material metálico maciço, possuindo diâmetro de 20 mm (o mesmo diâmetro do sensor). Na extremidade superior do tubo foi fixada uma placa de acrílico de diâmetro maior para facilitar o posicionamento de corpos com diferentes massas. A imagem da Figura 13 exemplifica a estrutura real montada de aplicação usada em todo o presente trabalho. A parte superior da estrutura possuía orifícios para as hastes de posicionamento das massas

feitos exatamente na posição das regiões (futuramente) definidas para todos os testes e para os elementos sensores mostrados. As hastes possuíam tamanhos distintos para melhor diferenciá-las e evitar choques durante os testes, tendo uma base de acrílico na parte superior para estabilizar o posicionamento das cargas. As saídas de fibra da matriz eram conectadas à fonte de luz (saída da direita) e ao espectrômetro (saída da esquerda).


Figura 13 – Detalhamento da estrutura utilizada para aplicação de cargas: (a) detalhe da estrutura inteira e (b) com as hastes de aplicação.



Fonte: Autoria própria (2020)

O sistema experimental de caracterização completo, portanto, pode ser visto na Figura 14.

Figura 14 – Diagrama esquemático do sistema experimental usado na caracterização dos elementos sensores.




Fonte: Autoria própria (2020)

Os primeiros testes consistiram em verificar a capacidade do elemento desenvolvido de responder a diferentes forças aplicadas diretamente sobre a superfície plana

do sensor (base do cilindro). O sensor foi submetido a pressões exercidas por massas de 0,0 kg a 5,0 kg aplicadas sobre a haste em ordem crescente com passos de 0,5 kg. Os espectros de transmissão foram medidos após um tempo de estabilização mecânica do sistema de 20 segundos, sendo o sinal de referência do sistema equivalente a não aplicação de carga sobre a haste posicionada sobre o sensor. A Figura 15 apresenta os espectros de transmissão do sensor submetido as pressões exercidas pelas diferentes massas.

Figura 15 – Espectros de transmissão do elemento sensor sujeito a cargas de 0,0 a 5,0 kg.



Fonte: Autoria própria (2019)

Estes resultados foram obtidos pelos acréscimos consecutivos de massas de 0,5 kg sobre o sensor, ou seja, cada massa aplicada corresponde a um acréscimo de 0,5 kg à massa anterior, sem que esta fosse removida.


Observa-se a clara diferenciação entre os espectros obtidos com o sensor sob ação das diferentes cargas; no entanto, as respostas dos sensores mostram uma relação complexa entre a carga aplicada e o espectro transmitido. Este fato pode ser justificado através de algumas comparações, como no caso do espectro de transmissão da aplicação de 1,0 kg (em bordô) e o espectro de 2,0 kg (em amarelo), mostrando que cada comprimento de onda da curva responde de forma diferente para cada carga aferida (ou seja, as perdas de intensidade são dependentes do comprimento de onda e não variam linearmente com a carga aplicada).

As perdas por curvatura são mais significativas para maiores comprimentos de onda, o que resulta no perfil geral de intensidade observado nos espectros. Para os espectros correspondentes às massas de 0,5 kg e 1,0 kg, ocorre uma alta atenuação do sinal transmitido na região espectral acima de 800 nm, apesar da atenuação do sinal ser pequena entre aproximadamente 400 nm e 600 nm. Porém, com o acréscimo da carga aplicada, a intensidade transmitida na região de maiores comprimentos de onda volta a aumentar enquanto na região de menores comprimentos de onda ocorre uma diminuição. Apesar de não haver um padrão simples de dependência, observa-se, para cargas acima de 3,5 kg, uma tendência de diminuição da intensidade transmitida em toda a faixa espectral com o aumento da carga. Este comportamento complexo é resultante tanto das mudanças de forma do anel que influenciam as perdas por curvatura e acoplamentos dos modos associados aos os WGM, quanto das propriedades mecânicas do material encapsulante.

O próximo passo foi verificar a resposta do sensor submetido a pressões exercidas por massas de 0,0 kg a 3,0 kg aplicadas sobre a haste em ordem crescente com passos de 0,3 kg. Neste ensaio os espectros de transmissão também foram medidos após um tempo de estabilização mecânica do sistema de 20 segundos, ressaltando que o sinal de referência do sistema equivale a não aplicação de carga sobre a haste posicionada. Os resultados são apresentados na Figura 16a.

Outro diferencial para este teste foi a medição das respostas do sensor quando da diminuição da carga aplicada, a fim de verificar a possível influência da histerese – uma vez comprovada sua existência em trabalho anterior (KAMIZI *et al.*, 2017) – do material na resposta do sensor. Para tanto, após atingida a carga máxima de 3,0 kg, as cargas adicionais de 0,3 kg foram consecutivamente removidas. Novamente foi adotado um intervalo de tempo de 20 segundos entre cada medição. Os espectros de transmissão obtidos são apresentados na Figura 16b.

Figura 16 – Espectros de transmissão do elemento sensor sujeito a cargas entre 0,0 e 3,0 kg, aplicadas com passo de 0,3 kg em ordem crescente (a) e em ordem decrescente (b)




Fonte: Autoria própria (2019)

Pela comparação dos espectros (a) e (b) na Figura 16, observa-se que o procedimento de aplicação de cargas influencia os espectros de transmissão, fazendo com que espectros obtidos sob a ação de uma mesma carga sejam diferentes. Tal observação sugere que o elemento sensor, quando submetido a cargas, sofre alterações em sua estrutura mecânica, mudando suas condições elásticas, efeito também conhecido como Payne, apresentando a histerese (BEZERRA *et al.*, 2013; PLAGGE *et al.*, 2020).

É possível exemplificar com mais nitidez este fato através da comparação individual dos espectros do sensor obtidos com a aplicação de determinadas cargas nos dois testes distintos realizados. A Figura 17 compara, para algumas situações, os espectros de transmissão do sensor sujeito a mesma carga nos testes de aumento e diminuição de carga. As curvas em azul representam o sinal de referência do sistema (apenas para comparação, uma vez que as medições foram feitas em sequência, com a presença constante de aplicação de carga), as curvas em vermelho identificam as medições feitas no teste com aplicação crescente de carga. E as em preto, as medições feitas no teste com aplicação decrescente de cargas.

Figura 17 – Comparação entre medições de cargas iguais para pressão constante sobre o elemento sensor, sendo as em vermelho medidas no sentido crescente de aplicação e as em preto no sentido decrescente de aplicação.




Fonte: Autoria própria (2019)

Nota-se a diferença dos espectros quando se compara a medição da mesma carga, indicando um possível problema em relação à elasticidade do material. Cargas maiores apresentam estabilidade maior quando comparadas com as de menor valor. Este resultado indicaria um possível problema para futuras medições na matriz de sensoriamento final e, portanto, foi feito um outro teste para avaliar se o posicionamento das mesmas cargas consecutivamente apresentaria a mesma resposta em espectro.

Assim, o teste seguinte foi repetir o teste de cargas de 0,0 a 3,0 kg por três vezes consecutivas. As cargas variaram com passo de 0,3 kg, aferidas a cada 10 segundos. Quando atingido o valor máximo de carga, a aplicação era interrompida e o sistema retornava ao patamar inicial de repouso por 20 segundos. Iniciava-se, então, novamente o teste. Os resultados destes testes são apresentados na Figura 18.

Figura 18 – Espectros de transmissão do sensor obtidos em 3 testes consecutivos de aplicação de cargas de 0,0 a 3,0 kg.



Fonte: Autoria própria (2020)

Repetindo-se o teste de carga por três vezes consecutivas, promovendo o retorno do sensor ao estado inicial (sem carga) entre as medições, as curvas se sobrepõem quase que completamente indicando a repetibilidade do elemento sensor desenvolvido.

Nos testes anteriores, o elemento sensor produzido mostrou-se capaz de detectar cargas diferentes aplicadas, porém apresentava resultados diferentes quando sob ação de uma mesma carga em medições consecutivas devido a efeitos de histerese. Este problema foi resolvido ao se notar que tal situação só ocorria quando o material do encapsulamento era submetido à aplicação de cargas por um tempo relativamente longo, pois no teste de acréscimo seguido de decréscimo de aplicação de cargas não houve a retirada de cargas em nenhum momento. Portanto, os mesmos testes foram realizados retirando-se totalmente a carga entre as medições, garantindo o retorno do sensor ao seu estado inicial de repouso.


3.2 MATRIZ DE SENSORIAMENTO TÁTIL

Uma vez testado o sensor individual, e comprovada sua utilização para medição de cargas, o passo seguinte foi confeccionar a matriz de sensoriamento tátil. O desenvolvimento da matriz se deu pela produção inicial dos sensores individuais em série num mesmo segmento de fibra ótica e posterior encapsulamento com o formato final do sistema tátil. Os itens subsequentes descrevem em detalhes as etapas de produção dessa matriz, as caracterizações dos sensores presentes e as caracterizações das regiões do sistema.

3.2.1 Produção da matriz de sensoriamento tátil

A produção da matriz foi toda desenvolvida com base na escolha do tamanho final do sistema de sensoriamento tátil, que foi estabelecido como sendo uma placa quadrada com 10,0 cm de lado e 0,8 cm de espessura. Estas dimensões foram escolhidas para que fosse possível testar a capacidade do sistema de realizar o sensoriamento de pressões aplicadas sobre diferentes posições da sua superfície usando a resposta acoplada dos elementos sensores. Uma matriz muito maior poderia não favorecer a resposta acoplada dos elementos sensores pela distância entre os mesmos, assim como dimensões muito pequenas dificultariam o posicionamento de cargas em regiões da placa onde não existem elementos sensores. Dessa forma, com as dimensões definidas, foi produzida uma placa de silicone contendo 4 elementos sensores. Assim, a etapa inicial foi desenvolver os 4 sensores em série para depois distribuí-los no molde definido. A produção dos elementos sensores utilizou o mesmo processo descrito no item 3.1.1 até a segunda etapa. Os sensores foram produzidos em série num mesmo segmento de fibra, sendo mantido um espaçamento de, aproximadamente, 7,0 cm entre dois sensores consecutivos, conforme esquema da Figura 19. Nota-se que não há o encapsulamento do último cilindro descrito anteriormente como terceira etapa de produção dos elementos sensores pelo motivo do encapsulamento final ser a própria matriz e, portanto, cada elemento possuía o aspecto definido na Figura 10.


Figura 19 – Sensores individuais em série para produção da matriz.



Fonte: Autoria própria (2020)


Os 4 sensores em série foram distribuídos em um molde de acrílico no formato de uma caixa com dimensões de $(100,00 \pm 0,05)$ mm x $(100,00 \pm 0,05)$ mm x $(8,00 \pm 0,05)$ mm (largura, comprimento e altura). Os cilindros foram posicionados de forma simétrica um em relação aos outros dentro da caixa e (apoiados pela sua superfície lateral, de maneira a garantir o posicionamento perpendicular do plano do anel em relação as superfícies superior e inferior da placa). O molde então foi preenchido com o elastômero de silicone e, após a cura da borracha, formou-se a matriz de sensoramento. Foi garantido que os sensores ficassem completamente submersos na matriz, criando uma superfície plana, sem que nenhuma das superfícies dos laços (superior ou inferior) ficasse exposta e comprometesse o funcionamento do sistema. O posicionamento dos sensores pode ser visto na Figura 20, em que as pequenas faixas pretas indicam a vista superior do local dos sensores, assim como pode-se observar a posição das extremidades da fibra conectadas a fonte de luz e espectrômetro. A Figura 21, portanto, mostra as vistas superior e em perspectiva da matriz fabricada.

Figura 20 – Esquema completo da matriz do sistema com indicação das posições dos sensores óticos em série distribuídos.



Fonte: Autoria própria (2020)

Figura 21 – Matriz produzida com (a) vista superior e (b) vista em perspectiva.




Fonte: Autoria própria (2020)

3.2.2 Caracterização dos sensores da matriz

Com o sistema produzido, houve necessidade de garantir que todos os elementos sensores presentes fossem sensíveis e capazes de detectar cargas aplicadas. Para tal, testes foram realizados exatamente sobre o posicionamento de cada elemento. As regiões sobrepondo os sensores utilizadas para a aplicação de cargas neste teste podem ser visualizadas na Figura 22.

Nota-se que o formato da região para aplicação de carga tem por objetivo replicar a área do sensor único testado anteriormente, com área de aplicação referente

Figura 22 – Regiões de aplicação de cargas para testes dos sensores da matriz.




Fonte: Autoria própria (2020)

ao círculo de 20,0 mm de diâmetro.

Para os testes, as cargas variaram de 0,0 a 3,0 kg, com passo de 0,3 kg, com 10 s de estabilização sobre a região, aplicadas através da mesma estrutura e equipamentos descritos na caracterização do elemento sensor (seção 3.1.2). Esse processo foi feito para as 4 regiões dos elementos sensores da mesma maneira e os resultados contendo os espectros de transmissão para cada uma das regiões dos sensores são indicados na Figura 23.

Figura 23 – Espectros referentes às medições de cargas aplicadas para as caracterizações dos elementos sensores presentes na matriz.



Fonte: Autoria própria (2019)


Os espectros de transmissão obtidos indicam alterações significativas na res-

posta da matriz para uma mesma carga aplicada sobre diferentes sensores, ressaltando que os elementos estão conectados em série e os espectros obtidos são o resultado do sinal transmitido pelos 4 dispositivos. Esse fato demonstra que, apesar do método de produção dos sensores ser sempre o mesmo, podem haver sensores com pequenas diferenças construtivas que modificam a resposta da matriz. Ao contrário do que possa parecer, isto representa um ponto a favor do sistema, pois pontos simétricos apresentarão diferentes respostas. Além dessas pequenas diferenças construtivas, as respostas distintas podem ser devido a alguns fatores como o posicionamento da haste de aplicação e consequente aplicação da carga, justamente pelos sensores estarem imersos e poder haver pequenas variações de posição; pequenas inclinações enquanto havia a cura do silicone, pelo fato dos elementos estarem em meio líquido; e variações pequenas de profundidade pelo mesmo motivo. Ainda, como os sensores estão em série, já fixos e encapsulados na matriz, há possibilidade de já haver acoplamento entre os mesmos e a resposta de aplicação de uma carga sobre a região de um sensor ser reconhecida por outros, assim como, por estarem em série, mesmo considerando apenas que um sensor seja afetado pela aplicação de carga, a resposta de um sensor é transmitida aos outros sequencialmente, também podendo afetar a resposta da matriz.

Para ficar mais clara essa diferença de resposta da matriz, a Figura 24 apresenta a comparação entre espectros de transmissão da matriz quando da aplicação de cargas para valores de 1,0 kg, 1,5 kg, 2,0 kg e 3,0 kg em cada um dos 4 sensores. Os sensores 1, 2, 3 e 4 são representados pelas cores vermelha, azul, rosa e verde, respectivamente, e a cor preta indica o sinal de referência do sistema, o qual ocorre quando não há carga aplicada sobre a haste posicionada no respectivo sensor.

É importante comentar que no trabalho desenvolvido multiplexando os sensores de macrocurvatura não acoplados, os elementos já foram avaliados individualmente mesmo estando em série (KAMIZI *et al.*, 2019). Por esse motivo, no presente trabalho, a análise dos sensores da matriz foi feita após encapsulamento da matriz.

Figura 24 – Comparação entre os espectros de transmissão da matriz quando da aplicação individual de cargas de 1,0 kg, 1,5 kg, 2,0 kg e 3,0 kg em cada sensor.




Fonte: Autoria própria (2019)

3.2.3 Caracterização das regiões do sistema

Com o intuito de produzir um sistema de sensoriamento tátil no qual o número de sensores é menor do que o número de áreas de sensoriamento, os 4 elementos sensores foram distribuídos simetricamente na placa, como na Figura 20, e foram estabelecidas as 5 áreas circulares de sensoriamento com diâmetro de 20,0 mm, apresentadas na Figura 25.

Figura 25 – Diagrama representando as 5 áreas de sensoriamento estabelecidas para testar a capacidade de sensoriamento da matriz.




Fonte: Autoria própria (2020)

Como já dito, o objetivo é avaliar a capacidade do sistema em reconhecer diferentes cargas aplicadas em diferentes regiões que não são necessariamente coincidentes com as posições dos sensores. Assim, foram aplicadas cargas de 0,5 kg, 1,0 kg, 1,5 kg, 2,0 kg, 2,5 kg e 3,0 kg sobre uma dada região de sensoriamento, adotando um tempo de estabilização de 10 segundos por carga aplicada. O experimento foi realizado para cada uma das 5 regiões. Foram avaliadas as respostas do sistema para uma dada região de sensoriamento e posteriormente foram comparadas as respostas para regiões diferentes. Como em todos os testes, a aplicação das cargas seguiu o mesmo procedimento de aplicação, com a estrutura em MDF e as hastes de aplicação em PVC, descrito na seção 3.2.1.

Para cada região de sensoriamento, os testes foram repetidos 10 vezes totalizando um conjunto de 300 medições. Os espectros de transmissão resultantes da aplicação de carga por região são mostrados na Figura 26. Cada espectro representa a média das medições por carga, por região.

Figura 26 – Espectros de transmissão da matriz de sensores resultantes da aplicação individual de cargas de 0,0 a 3,0 kg nas regiões de sensoriamento.




Fonte: Autoria própria (2019)

Os resultados são reapresentados na Figura 27, onde são agrupados num

mesmo gráfico os espectros de transmissão da matriz obtidos para uma mesma carga aplicada nas 5 diferentes regiões.

Figura 27 – Espectros de transmissão referentes a cada carga aplicada, comparando as cinco regiões do sistema.



Fonte: Autoria própria (2019)

Uma mesma carga aplicada em diferentes regiões de sensoriamento resulta em respostas diferentes da matriz. Este comportamento indica a possibilidade de extrair informações espaciais sobre a perturbação do sistema a partir do sinal aferido. Além disso, diferentes cargas agindo na mesma posição alteram o sinal de transmissão, tornando possível obter a magnitude da carga por meio do espectro. Dependendo da carga e da região de aplicação, alterações de intensidade positivas e negativas são observadas nos espectros. Comparando as respostas da matriz, observa-se que as maiores perdas de intensidade são obtidas quando as cargas são aplicadas na região 5. Esse fato ocorre, provavelmente, por essa região, localizada no centro da matriz,

influenciar simultaneamente os 4 elementos sensores. Por outro lado, a aplicação de cargas na região 3 produz as maiores alterações de intensidade positivas, provavelmente resultantes das alterações geométricas dos sensores. Apesar da disposição de regiões e sensores ser simétrica, as respostas da matriz são diferentes. É o caso, por exemplo, das respostas resultantes da aplicação de uma mesma carga nas regiões diagonalmente simétricas e opostas 1-4 e 2-3. Como já discutido anteriormente, cargas aplicadas em regiões de sensoriamento simétricas resultam em diferentes respostas da matriz. O fato do sistema responder a cargas aplicadas em regiões de sensoriamento não coincidentes com as posições dos sensores é um forte indicativo de que o sistema utiliza a resposta acoplada dos sensores.

3.3 TESTES COM A MATRIZ DE SENSORIAMENTO TÁTIL

A capacidade de discriminação da carga e sua localização em um sistema contendo sensores de macrocurvatura em fibras óticas multiplexados não acoplados foi relatado na literatura (KAMIZI *et al.*, 2019).

Na matriz de sensoriamento tátil desenvolvida, os 4 sensores de macrocurvatura multiplexados em série são encapsulados em uma única placa de silicone, o que favorece a sua resposta acoplada. Testes foram realizados com a matriz de sensoriamento contendo 4 sensores e 5 áreas pré-definidas de sensoriamento, a fim de avaliar a capacidade do sistema de fornecer as cargas aplicadas sobre a matriz e suas localizações.

3.3.1 Metodologia adotada para a realização dos testes

O sistema dispunha de 5 regiões (definidas na seção 3.2.3) a serem monitoradas por 4 sensores multiplexados em série. Para este e os testes subsequentes, utilizou-se a matriz posicionada no centro da estrutura em MDF, já detalhada na seção 3.1.2. A matriz foi testada com 155 diferentes configurações de carga correspondendo a aplicação simultânea de 4 cargas sobre a sua superfície. Foram utilizadas cargas de 0,5 kg, 1,0 kg, 1,5 kg e 2,0 kg posicionadas nas 5 regiões de sensoriamento. Um algoritmo foi utilizado para gerar aleatoriamente as 155 configurações dentre as 1024 possíveis combinações, correspondentes a 15,1 % do espaço amostral. A Tabela 1


exemplifica a representação de 10 dessas configurações geradas aleatoriamente para os testes, com todas as unidades em kg, sendo as configurações 1, 2, 3 e 4 ilustradas na matriz na Figura 28 por (a), (b), (c) e (d), respectivamente. Os valores nulos das configurações indicam a não aplicação de carga sobre as hastes posicionadas.

Tabela 1 – Exemplo de configurações geradas aleatoriamente para teste de multiplexação, indicando os valores em kg das cargas aplicadas em cada região.

Configurações	Regiões				
	1	2	3	4	5
1	0,5	0,5	0,0	0,0	0,0
2	0,0	1,0	0,0	0,5	1,0
3	0,5	1,5	1,0	2,0	0,0
4	0,0	0,0	0,5	0,0	1,0
5	0,0	0,5	0,5	0,0	0,0
6	1,5	0,5	1,0	1,0	0,0
7	2,0	1,0	0,0	0,5	0,0
8	0,5	1,0	0,0	0,0	0,5
9	0,0	0,0	1,0	0,0	1,5
10	2,0	0,5	0,5	1,0	0,0

Fonte: Autoria própria (2020)

Figura 28 – Representação na matriz das 4 primeiras configurações da Tabela 1.




Fonte: Autoria própria (2020)

É importante comentar que, a maior carga aplicada por região foi de 2,0 kg, e

simultaneamente aplicada à matriz por configuração, a maior carga foi de 6,0 kg. As 155 configurações geradas de forma aleatória, foram aplicadas ao sistema na mesma ordem em que foram geradas. O espectro de transmissão para cada configuração de cargas foi adquirido após um tempo de estabilização do sistema de 10 segundos. Os 155 espectros obtidos são apresentados na Figura 29.

Figura 29 – Espectros de transmissão obtidos com as 155 configurações de carga aplicadas em sequência aleatória sobre a matriz..




Fonte: Autoria própria (2019)

As maiores modificações nos valores de intensidade ocorrem para comprimentos de onda superiores a 600 nm, podendo chegar a 300% de variação em relação ao espectro de referência. Entretanto, para menores comprimentos de onda também são observadas alterações espectrais, em detalhe na Figura 29, com variação máxima de intensidade de aproximadamente 15% em relação ao valor de referência. Os WGM são os principais responsáveis pelas alterações de intensidade observadas nesta região espectral, pela grande quantidade de ondulações presente. Conforme feito nos testes com o sensor individual, todas as medições foram aferidas a partir do estado de repouso do material (retiram-se todas as massas da matriz entre uma configuração e outra) para minimizar o efeito da histerese. Contudo, foi estabelecido realizar o mesmo teste com as 155 configurações, porém de forma ordenada, estabelecendo uma comparação para verificar se ainda existia algum efeito da histerese do material de encapsulamento

sobre a resposta do sistema. As configurações de carga foram ordenadas inicialmente na ordem crescente de carga aplicada na região de sensoriamento 1. Em seguida, para o conjunto de configurações que apresentam a mesma carga aplicada na região de sensoriamento 1, as cargas aplicadas na região 2 também foram ordenadas de maneira crescente. Este mesmo procedimento foi adotado para as outras 3 regiões de sensoriamento, ou seja, cargas crescentes na região para as configurações com mesma carga na região anterior. Os espectros de transmissão gerados para este caso podem ser vistos na Figura 30.

Figura 30 – Espectros de transmissão obtidos com as 155 configurações ordenadas aplicadas sobre a matriz.



Fonte: Autoria própria (2019)

Assim como no teste com aplicação de cargas aleatórias, as maiores mudanças de maior valor de intensidade estão presentes nos maiores comprimentos de onda a partir de 650 nm, com variação de até 200% em relação ao valor de referência do sistema. As menores variações, também presentes nos menores comprimentos de onda, variam em cerca de 5% em relação à referência. Somente com essa comparação espectral, nota-se a maior variação para o caso em que as configurações de carga são aplicadas aleatoriamente sobre a matriz.

3.3.2 Método de tratamento dos dados do teste da matriz

Possuindo os espectros dos testes descritos, faz-se necessário analisar os dados para verificar se o sistema é capaz de reconhecer massas e posição a partir da aplicação das regressões lineares.

Cada espectro representa a resposta do sistema a uma configuração de cargas específica. De acordo com as especificações do espectrômetro HR4000 (Ocean Optics), sua resolução pode ser calculada através da dispersão multiplicada pela resolução do espectrômetro, 14 pixels. A dispersão, que é a faixa espectral (aqui 850 nm) dividido pelo número de elementos detectores (que desse aparelho é 3648), resulta em 0,233 nm/pixel. Assim, a resolução do dispositivo é de 3,26 nm. Observou-se, também, que os dados de intensidade do espectrômetro são coletados a cada 0,26 nm. Portanto, cada espectro possui 1743 pontos, para a faixa espectral de 400 a 850 nm. Como são 155 configurações de cargas, a matriz de entrada do sistema de análise tem dimensões de 155x1743 (linhas e colunas) totalizando 270165 dados de entrada, sendo cada dado um valor específico de intensidade para a configuração e comprimento de onda.

Por se tratar de uma quantidade grande de dados (número de características muito maior em relação ao número de amostras) optou-se por utilizar modelos de regressão lineares para evitar o sobreajuste (*overfitting*), ou seja, evitar que o sistema memorize as configurações de treinamento e não seja capaz de prever novos resultados. Este efeito de sobreajuste pode ser evitado ao se usar métodos com regularização baseados na regressão por mínimos quadrados, como é o caso da regressão linear Lasso e da Ridge. Dessa forma, métodos de regressões lineares foram escolhidos para fins de comparação e eficiência, sendo eles: método dos mínimos quadrados, a regressão Ridge, que também possui método de regularização, e a regressão Lasso.

Primeiramente, definem-se duas matrizes de entrada do sistema: uma com os dados obtidos dos espectros possuindo dimensões de 155x1743, indicando os valores de intensidade de cada um dos 1743 comprimentos de onda para cada configuração, e a outra de dimensões de 155x5, indicando os alvos do sistema, que são as configurações de massas definidas e aplicadas nos testes. A Figura 31 ilustra esquematicamente estas duas matrizes de entrada.

Figura 31 – Matrizes de entrada de dados: valores de intensidade dos espectros e alvos (valores em kg), respectivamente.

		Comprimentos de onda (nm)							Regiões				
		400	400,26	400,52	...	850			1	2	3	4	5
Configurações	1	$I_{1 \times 400}$	$I_{1 \times 400.26}$	$I_{1 \times 400.52}$	...	$I_{1 \times 850}$	Configurações	1	0,0	0,0	0,5	1,5	0,0
	2	$I_{2 \times 400}$	$I_{2 \times 400.26}$	$I_{2 \times 400.52}$	...	$I_{2 \times 850}$		2	1,0	0,0	2,0	1,5	1,0
	3	$I_{3 \times 400}$	$I_{3 \times 400.26}$	$I_{3 \times 400.52}$	...	$I_{3 \times 850}$		3	0,5	0,5	2,0	1,0	0,0
	.	.	.	.	.	.		.	.	.	.	.	.
	.	.	.	.	.	.		.	.	.	.	.	.
	.	.	.	.	.	.		.	.	.	.	.	.
	.	.	.	.	.	.		.	.	.	.	.	.
	.	.	.	.	.	.		.	.	.	.	.	.
	.	.	.	.	.	.		.	.	.	.	.	.
	.	.	.	.	.	.		.	.	.	.	.	.
	.	.	.	.	.	.		.	.	.	.	.	.
	.	.	.	.	.	.		.	.	.	.	.	.
	.	.	.	.	.	.		.	.	.	.	.	.
	.	.	.	.	.	.		.	.	.	.	.	.
	155	$I_{155 \times 400}$	$I_{155 \times 400.26}$	$I_{155 \times 400.52}$	...	$I_{155 \times 850}$		155	0,0	0,0	0,0	0,0	0,0

Matriz de entrada de dados com valores de intensidade

Matriz representando as configurações (alvos)

Fonte: Autoria própria (2020)

Após definição das matrizes de entrada do sistema, criou-se um algoritmo em Python, utilizando a biblioteca *Scikit-learn*, para gerar as regressões lineares e fazer o treinamento do sistema (PEDREGOSA *et al.*, 2011). O primeiro passo realizado no algoritmo foi encontrar o melhor modelo de treinamento para cada regressão. Assim como comentado anteriormente, o objetivo de usar as regressões lineares é se evitar o *overfitting* pela quantidade grande de dados. Porém, para garantir que isso não ocorra é necessário se utilizar, inicialmente, a validação cruzada, com k igual a 5 neste caso, para definir os parâmetros corretos de cada modelo. Primeiramente, definiu-se que, em todos os casos que serão apresentados de regressão, 70% dos dados de entrada são para treinamento e os 30% restantes para testes, ou seja, das 155 configurações, 108 para treinamento e 47 para testes. Essa escolha é feita com base na definição do *Random State* (estado aleatório). O estado aleatório é um fator que define em qual posição das configurações o modelo será subdividido para aplicar a validação cruzada ou treinamento. Por exemplo, se definido como 30, será na configuração de número 30 (das 47 selecionadas) o início da separação do conjunto de dados. Esse estado deve ser definido para garantir a reprodutibilidade, pois se deixado no modo aleatório, toda vez que o algoritmo for utilizado, gerará um novo modelo. Portanto, foi escolhido um valor de estado aleatório para cada conjunto de dados (configurações aleatórias e ordenadas) fixo ao longo das análises. Uma vez estabelecido o *Random State*, a validação cruzada visou encontrar o melhor valor de alfa para as regressões Ridge e Lasso. O parâmetro foi definido de forma a minimizar o erro absoluto médio

na validação cruzada. Lembrando que, como mostrado na seção anterior, os testes foram realizados de duas formas: com a aplicação aleatória das configurações e com a aplicação ordenada. Portanto, os tratamentos de dados envolvem a análise para os dois casos.

Em relação ao *Random State*, o valor ficou definido como 39 para o conjunto de dados das configurações aleatórias e 10 para as configurações ordenadas para todas as regressões.

Já para o Alfa, no caso dos dados das configurações aplicadas de forma aleatória, após a validação cruzada, os valores ótimos desse parâmetro ficaram definidos como 0,3 e 0,0011 para a Ridge e Lasso, respectivamente. Para as configurações ordenadas, os valores obtidos foram de 0,586 para a Ridge e também 0,0011 para a Lasso.

A Tabela 2 resume os dados e valores descritos e que foram usados em todas as análises subsequentes, incluindo o número máximo de iterações, que ficou definido como 60000 para garantir a convergência dos modelos.

Tabela 2 – Parâmetros definidos para os modelos de regressão a partir da validação cruzada antes do treinamento dos mesmos.

Regressão	Parâmetros dos modelos				Número máximo de iterações
	Alfa (Configurações aleatórias)	Alfa (Configurações ordenadas)	<i>Random State</i> (Configurações aleatórias)	<i>Random State</i> (Configurações ordenadas)	
Mín. Quadrados	–	–	39	10	60000
Ridge	0,3	0,586	39	10	60000
Lasso	0,0011	0,0011	39	10	60000

Fonte: Autoria própria (2020)

Como método de avaliação de eficiência do sistema, os erros absolutos médios entre os testes e os alvos foram analisados. Os itens a seguir mostram os erros associados à validação cruzada, assim como os erros associados ao treinamento e testes para as regressões.

3.3.3 Resultados obtidos com a regressão por mínimos quadrados usando os dados da faixa espectral entre 400 e 850 nm


A regressão por mínimos quadrados não possui parâmetro de regularização em sua função e, portanto, não necessita da validação cruzada, sendo analisada diretamente após o treinamento do conjunto de dados. Desse modo, após o treinamento, as configurações para teste apresentaram um erro absoluto médio total de 0,272 kg. Como a maior massa aplicada ao sistema é de 2,0 kg, o erro representa 13,60 % desse valor. Se for levada em consideração a maior massa aplicada simultaneamente no sistema, 6,0 kg, tem-se 4,53 % de erro. Considerando os testes isoladamente, o menor erro de configuração encontrado foi de 0,089 kg e o maior erro de 0,711 kg. A Tabela 3 exemplifica 3 configurações das 47 usadas como teste, indicando as cargas aplicadas em cada região juntamente com o valor obtido pelo modelo de regressão. A configuração de número 17 apresenta o menor erro individual entre todas, assim como a configuração de número 40 representa a com maior erro individual. A configuração de número 25, foi escolhida aleatoriamente para comparação. Os erros associados apresentados na última coluna, que estão explicitados em função da maior carga que pode ser aplicada por região (2 kg), mostram disparidade entre resultados fornecidos por este modelo para diferentes configurações, quando as cargas são aplicadas aleatoriamente sobre a matriz. A imagem da Figura 32 representa as configurações 17, 25 e 40, respectivamente em (a), (b) e (c), em escala de cores na matriz.

Tabela 3 – Exemplo de três configurações aplicadas à matriz na regressão por mínimos quadrados para as configurações aleatórias, indicando o erro individual, incluindo os dois extremos: configuração de menor erro (17) e configuração de maior erro (40).

Configurações		Regiões					Erros	
		1	2	3	4	5	MAE(kg)	MAE(%)
17	Alvo	0,00	1,50	1,00	0,50	0,00	0,089	4,45
	Resultado	0,02	1,35	1,04	0,54	0,18		
25	Alvo	2,00	0,00	0,00	0,50	1,00	0,304	15,20
	Resultado	1,87	0,00	0,09	0,30	-0,10		
40	Alvo	0,50	1,50	0,00	0,00	2,00	0,711	35,55
	Resultado	0,52	0,25	-0,08	1,33	1,14		

Fonte: Autoria própria (2020)

Figura 32 – Resultado da regressão por mínimos quadrados para as aplicações aleatórias, das 3 configurações de testes apresentadas na Tabela 3, que incluem a de menor erro (a), uma aleatória (b) e a de maior erro (c).



Fonte: Autoria própria (2020)

Utilizando a mesma análise da regressão para o caso da aplicação ordenada das configurações de cargas sobre a matriz, o erro absoluto médio total de testes no modelo treinado foi de 0,235 kg, representando 11,75 % em relação ao maior valor de massa individual (2,0 kg) e 3,92 % em relação ao maior de massa aplicada à matriz simultaneamente (6,0 kg). Quanto aos valores de configurações individuais de menor e maior erro absoluto médio, obteve-se, das 47 utilizadas para teste, 0,058 kg, para a configuração de número 20, e 0,512 kg para a configuração de número 38. A

Tabela 4 explicita os valores de massas utilizados para as configurações de número 13 (escolhido aleatoriamente apenas para comparação), 20 e 38, assim como seus erros associados em relação ao maior valor de massa aplicado individualmente por região (2,0 kg). A representação destas configurações em escala de cores é a apresentada na Figura 33, sendo (a), (b) e (c) as configurações 20, 13 e 38, respectivamente.

Tabela 4 – Exemplo de três configurações aplicadas à matriz na regressão por mínimos quadrados para as configurações ordenadas, indicando o erro individual, incluindo os dois extremos: configuração de maior erro (38) e configuração de menor erro (20).


Configurações		Regiões					Erros	
		1	2	3	4	5	MAE(kg)	MAE(%)
20	Alvo	1,00	1,00	0,00	0,50	0,50	0,058	2,90
	Resultado	1,06	1,15	-0,01	0,50	0,54		
13	Alvo	0,50	0,00	1,50	2,00	1,00	0,120	6,00
	Resultado	0,47	0,01	1,52	1,77	1,31		
38	Alvo	0,50	2,00	0,00	0,00	0,00	0,512	25,60
	Resultado	0,71	1,55	0,25	-0,21	1,43		

Fonte: Autoria própria (2020)

De acordo com a análise de regressão por mínimos quadrados, nota-se que houve melhora quanto aos erros absolutos médios tanto para treinamento, quanto para as configurações individuais, no caso da aplicação de cargas com as configurações ordenadas. Tal fato associado, provavelmente, à redução de efeitos indesejados de histerese do elastômero utilizado para encapsulamento ao ordenar a aplicação de cargas.

Após a análise por mínimos quadrados, espera-se que as regressões lineares com parâmetros de regularização no treinamento tenham melhor desempenho. Portanto, o próximo item indica a mesma análise descrita para o caso da Regressão Ridge.

Figura 33 – Resultado da regressão por mínimos quadrados para as aplicações ordenadas, das 3 configurações de testes apresentadas Tabela 4, que incluem a de menor erro (a), uma aleatória (b) e a de maior erro (c).



Fonte: Autoria própria (2020)

3.3.4 Resultados obtidos com a regressão Ridge usando os dados da faixa espectral entre 400 e 850 nm

Seguindo os mesmos passos da avaliação anterior, iniciou-se a análise através das configurações aplicadas de forma aleatória. O erro obtido para o processo da obtenção do modelo e o parâmetro de regularização por meio da validação cruzada foi de 0,222 kg. Após o treinamento, os 30 % das configurações separadas foram aplicadas e o erro absoluto médio total de testes dessa etapa foi de 0,241 kg. Tal valor

representa 12,05 % em relação ao maior valor de carga possível por região, 2,0 kg, e 4,02 % em relação ao maior valor de carga aplicado simultaneamente representado por uma das configurações, o qual foi de 6,0 kg. Individualmente, a configuração que apresentou menor erro absoluto médio foi a identificada pelo número 7, com valor de 0,075 kg. A que apresentou maior erro foi a de número 40, entre as 47 testadas, com valor de 0,677 kg. A Tabela 5 resume as informações descritas, indicando três configurações (de menor erro, aleatoriamente escolhida para comparação e de maior erro) com os erros associados ao valor de 2,0 kg.


Tabela 5 – Exemplo de três configurações aplicadas à matriz na regressão Ridge para as configurações em ordem aleatória, indicando o erro individual, incluindo os dois extremos: configuração de maior erro (40) e configuração de menor erro (7).

Configurações		Regiões					Erros	
		1	2	3	4	5	MAE(kg)	MAE(%)
7	Alvo	0,00	1,00	0,50	0,50	0,00	0,075	3,75
	Resultado	-0,06	1,10	0,52	0,41	0,10		
14	Alvo	0,00	0,00	1,00	0,50	1,50	0,246	12,30
	Resultado	0,37	-0,26	1,35	0,53	1,27		
40	Alvo	0,50	1,50	0,00	0,00	2,00	0,677	33,85
	Resultado	0,53	0,18	-0,08	1,42	1,46		

Fonte: Autoria própria (2020)

As representações em gráficos de cores das configurações citadas estão presentes na Figura 34, sendo (a), (b) e (c) referentes aos números 7, 14 e 40, respectivamente.

Figura 34 – Resultado da regressão Ridge para as aplicações em ordem aleatória, das 3 configurações de testes apresentadas na Tabela 5, que incluem a de menor erro (a), uma aleatória (b) e a de maior erro (c).



Fonte: Autoria própria (2020)

Para as configurações de forma ordenada, o erro mínimo obtido na validação cruzada foi de 0,206 kg. Após treinamento com os parâmetros definidos, ao aplicar as 47 configurações de teste, o erro absoluto médio foi de 0,208 kg, representando 10,40 % em relação ao valor máximo de massa de 2,0 kg, e 3,47 % em relação ao maior valor de carga aplicado simultaneamente na matriz, 6,0 kg. Analisando as configurações de teste individualmente, o menor erro ocorreu para a identificada pelo número 26,


com valor de 0,057 kg. A configuração identificada pelo número 38 apresentou o maior erro, com valor de 0,475 kg. A Tabela 6 identifica esses dois extremos, assim como apresenta uma configuração a mais para fins de comparação. A Figura 35 representa estas configurações em forma de escala de cores na matriz, sendo (a), (b) e (c) correspondentes as configurações 26, 29, e 38, respectivamente.

Tabela 6 – Exemplo de três configurações aplicadas à matriz na regressão Ridge para as configurações ordenadas, indicando o erro individual, incluindo os dois extremos: configuração de maior erro (38) e configuração de menor erro (26).

Configurações		Regiões					Erros	
		1	2	3	4	5	MAE(kg)	MAE(%)
26	Alvo	0,00	0,50	0,00	1,00	0,00	0,057	2,85
	Resultado	0,07	0,60	0,04	0,97	-0,05		
29	Alvo	0,00	1,00	0,00	1,00	0,00	0,191	9,55
	Resultado	0,02	0,80	0,18	1,09	0,47		
38	Alvo	0,50	2,00	0,00	0,00	0,00	0,475	23,75
	Resultado	0,78	1,31	0,27	0,00	1,13		

Fonte: Autoria própria (2020)

Figura 35 – Resultado da regressão Ridge para as aplicações ordenadas, das 3 configurações de testes apresentadas na Tabela 6, que incluem a de menor erro (a), uma aleatória (b) e a de maior erro (c).



Fonte: Autoria própria (2020)

3.3.5 Resultados obtidos com a regressão Lasso usando os dados da faixa espectral entre 400 e 850 nm

Por último, utilizou-se a regressão Lasso para avaliar o comportamento do sistema. Por apresentar um recurso de penalidade maior do que a regressão Ridge, anulando as variáveis não relevantes para o sistema e, portanto, selecionando as

informações, espera-se que aqui o desempenho da matriz neste modelo seja um pouco melhor.

O primeiro erro avaliado é o correspondente à seleção do parâmetro de penalização do modelo por meio da validação cruzada, que nesse caso foi de 0,251 kg. Com o modelo treinado, as 47 configurações selecionadas para teste foram aplicadas e o erro absoluto médio total de teste foi de 0,272 kg, que em porcentagem representa 13,60 % em relação à maior massa aplicada por região (2,0 kg) e 4,53 % em relação ao maior valor de carga aplicada simultaneamente na matriz (6,0 kg).

Quanto aos valores individuais das configurações aplicadas no teste do modelo, a de menor erro apresentou valor de 0,039 kg (configuração de número 43) e a de maior erro apresentou valor de 0,679 kg (configuração de número 40). A Tabela 7 indica essas configurações com os erros associados, assim como as massas aplicadas por região, incluindo a configuração de número 24, aleatoriamente escolhida para fins de comparação.


Tabela 7 – Exemplo de três configurações aplicadas à matriz na regressão Lasso para as configurações em ordem aleatória, indicando o erro individual, incluindo os dois extremos: configuração de maior erro (40) e configuração de menor erro (43).

Configurações		Regiões					Erros	
		1	2	3	4	5	MAE(kg)	MAE(%)
43	Alvo	0,00	0,50	0,00	1,00	1,50	0,039	1,95
	Resultado	-0,04	0,59	-0,04	1,03	1,50		
24	Alvo	1,50	0,00	1,00	0,00	0,50	0,122	6,10
	Resultado	1,60	-0,15	0,97	0,05	0,21		
40	Alvo	0,50	1,50	0,00	0,00	2,00	0,679	33,95
	Resultado	0,43	0,19	-0,06	1,45	1,50		

Fonte: Autoria própria (2020)

A representação das configurações em escalas de cores na matriz pode ser vista na Figura 36, onde (a), (b) e (c) equivalem às configurações de testes 43, 24 e 40, respectivamente.

Figura 36 – Resultado da regressão Lasso para as aplicações em ordem aleatória, das 3 configurações de testes apresentadas na Tabela 7, que incluem a de menor erro (a), uma aleatória (b) e a de maior erro (c).




Fonte: Autoria própria (2020)

As regressões geram funções lineares para cada região da matriz de sensoriamento. Ou seja, são cinco funções lineares com seus determinados coeficientes associados a cada variável (comprimento de onda). Como a regressão Lasso, na presente análise, anula os parâmetros não relevantes para o sistema, é interessante verificar quais variáveis a regressão manteve. Considerando que o total de comprimentos de onda entre 400 e 850 nm é de 1743, para a região 1, a regressão manteve apenas 34 comprimentos de onda, sendo 33 entre 400 e 606 nm e o outro em 844,45 nm. A

função para a região 2 manteve 37 comprimentos de onda, com 36 valores até 626 nm e o último em 847,97 nm. 44 comprimentos foram mantidos em relação a região 3, todos contidos entre 400 e 624 nm. Para a região 4, 32 foram mantidos, com 31 até 622 nm e um em 844,45 nm. Por fim, a região 5 foi obtida considerando 52 comprimentos, com 49 entre 400 e 654 nm e os outros 3 próximos de 844 nm. Como se nota, a regressão reduziu muito a quantidade inicial de variáveis e as manteve quase que completamente entre 400 e 630 nm para todas as regiões. Os coeficientes associados aos comprimentos de onda em torno de 840 nm são muito pequenos, cerca de 3 a 4 ordens de grandeza menores em relação aos coeficientes dos menores comprimentos. Estas informações indicam que a regressão considerou os maiores comprimentos de onda irrelevantes para o sistema. O gráfico da Figura 37 mostra uma visão geral sobrepondo os coeficientes associados a cada comprimento de onda que a regressão considerou para cada região, sendo o menor gráfico a representação dos coeficientes relacionados aos maiores comprimentos de onda.

Figura 37 – Coeficientes associados aos comprimentos de onda não anulados pela regressão Lasso para as configurações aleatórias.



Fonte: Autoria própria (2020)

Usando a mesma interpretação da regressão Lasso para avaliar as configurações ordenadas, obteve-se um erro na validação cruzada de 0,235 kg. Após treinado,


as 47 configurações para teste foram aplicadas e o erro absoluto médio de teste foi de 0,227 kg e, portanto, 11,35 % em relação ao maior valor de carga individual (2,0 kg) e 3,78 % em relação ao maior valor aplicado simultaneamente no sistema (6,0 kg). Foi encontrado o valor de 0,035 kg para a configuração de menor erro individual (número 26) e 0,532 kg para o maior erro individual (número 38) das configurações para teste. Esses dados, juntamente com a configuração de número 30 para comparação, estão presentes na Tabela 8. A matriz representada em escalas de cores referentes às configurações citadas está presente na Figura 38, com (a), (b) e (c) indicando 26, 30 e 38, respectivamente.

Tabela 8 – Exemplo de três configurações aplicadas à matriz na regressão Lasso para as configurações ordenadas, indicando o erro individual, incluindo os dois extremos: configuração de maior erro (38) e configuração de menor erro (26)

Configurações		Regiões					Erros	
		1	2	3	4	5	MAE(kg)	MAE(%)
26	Alvo	0,00	0,50	0,00	1,00	0,00	0,035	1,75
	Resultado	0,11	0,48	-0,03	1,01	0,01		
30	Alvo	0,00	0,50	0,00	1,00	1,50	0,157	7,85
	Resultado	-0,09	0,41	-0,14	0,94	1,09		
38	Alvo	0,50	2,00	0,00	0,00	0,00	0,532	26,60
	Resultado	0,85	1,35	0,35	0,05	1,26		

Fonte: Autoria própria (2020)

Figura 38 – Resultado da regressão Lasso para as aplicações ordenadas, das 3 configurações de testes apresentadas na Tabela 8, que incluem a de menor erro (a), uma aleatória (b) e a de maior erro (c).




Fonte: Autoria própria (2020)

Em relação aos coeficientes e variáveis anuladas pela regressão Lasso para as configurações ordenadas, para a região 1, dos 1743 presentes no espectro completo entre 400 e 850 nm, 39 comprimentos de onda foram considerados, distribuídos entre 400 e 647 nm. A função da região 2 estabeleceu 52 comprimentos restantes, com todos presentes até 640 nm. 40 comprimentos restaram para a região 3, com 37 para a faixa até 625 nm e 3 para comprimentos de onda em torno de 845 nm. Para a região 4, 47

variáveis selecionadas, 1 para 844,7 nm e 46 entre 400 e 615 nm. Por último, os valores relevantes para a região 5 foram 57, sendo 56 presentes entre 400 e 630 nm e o último para 849,73. Assim como ocorreu para as configurações aleatórias, aqui os coeficientes associados ao comprimentos de onda próximos de 840 nm são muito pequenos em relação aos menores comprimentos, de 3 a 5 ordens de grandeza menores, indicando novamente que a regressão considerou mais relevantes os menores comprimentos de onda. Todos esses coeficientes estão presentes no gráfico da Figura 39, onde foram sobrepostos para comparação, ressaltando que o gráfico menor representa os coeficientes presentes nos maiores comprimentos de onda.

Figura 39 – Coeficientes associados aos comprimentos de onda não anulados pela regressão Lasso para as configurações ordenadas.



Fonte: Autoria própria (2020)

3.3.6 Comparativo do desempenho da matriz usando as 3 regressões e a faixa espectral entre 400 e 850 nm

A Tabela 9 exibe os erros associados a cada regressão para os dois casos: configurações sem ordenação e configurações ordenadas. Todos os valores são de erro absoluto médio. Para os erros de testes no modelo de treinamento (segunda linha

da tabela), os valores de porcentagem estão associados ao valor de maior massa individual (2,0 kg) e ao valor de maior massa aplicada à matriz simultaneamente (6,0 kg), respectivamente.

Tabela 9 – Comparação das regressões lineares aplicadas ao sistema usando os espectros entre 400 e 850 nm, indicando os valores associados a cada erro analisado

Erros	Regressões					
	Mín. Quadrados		Ridge		Lasso	
	Config. aleatória	Config. ordenada	Config. aleatória	Config. ordenada	Config. aleatória	Config. ordenada
Validação cruzada	–	–	0,222 kg	0,206 kg	0,251 kg	0,235 kg
Teste	0,272 kg (13,60% e 4,53%)	0,235 kg (11,75% e 3,92%)	0,241 kg (12,05% e 4,02%)	0,208 kg (10,40% e 3,47%)	0,272 kg (13,60% e 4,53%)	0,227 kg (11,35% e 3,78%)
Menor erro de configuração individual	0,089 kg	0,058 kg	0,075 kg	0,057 kg	0,039 kg	0,035 kg
Maior erro de configuração individual	0,711 kg	0,512 kg	0,677 kg	0,475 kg	0,679 kg	0,532 kg

Fonte: Autoria própria (2020)

A primeira diferença que se pode notar é o fato de que, em todas as regressões, o resultado com o teste com as configurações ordenadas é melhor para o erro absoluto médio total quando comparado com as configurações aplicadas de forma aleatória.

Em relação ao desempenho dos modelos, a matriz de sensoriamento apresentou os maiores erros de teste para as regressões por mínimos quadrados e Lasso tanto para o experimento realizado com a aplicação aleatória das configurações de carga quanto para o experimento no qual as configurações de carga foram ordenadas. A regressão Ridge apresentou melhor desempenho para o experimento com a aplicação ordenada de cargas com erro absoluto total de 0,208 kg. Em seguida a Lasso, com 0,227 kg de erro e, por último, a por mínimos quadrados com 0,235 kg de erro de teste. A regressão Lasso forneceu o menor erro de configuração individual (0,035 kg), enquanto que, comparando os maiores erros de configuração, individual a regressão Ridge teve melhor desempenho.

Até o momento, utilizaram-se os espectros de transmissão entre 400 e 850 nm de todas as 155 configurações para avaliar o desempenho da matriz de sensoriamento usando 3 diferentes métodos de regressão para o tratamento de dados. Entretanto, os

resultados obtidos com a regressão Lasso e apresentados nas figuras 37 e 39 indicam que o desempenho dos métodos de regressão podem ser influenciados pela região espectral avaliada. Para isso, optou-se por criar novas análises usando diferentes faixas dos espectros originais, tanto das configurações ordenadas, quanto das configurações aleatórias, totalizando 4 análises adicionais. As opções de novas regiões escolhidas para novas análises são: faixa espectral entre 400 e 800 nm, entre 400 e 750 nm, entre 400 e 650 nm e entre 650 e 850 nm. As duas primeiras escolhas de faixas visam eliminar regiões com alto nível de ruído, a terceira delimitar a região onde as maiores alterações espectrais são devido aos WGM e a última delimitar a região onde ocorrem predominantemente perdas por curvatura.


Assim como ocorreu com a faixa espectral entre 400 e 850 nm, a análise dos modelos para as novas faixas espectrais seguiu o mesmo roteiro: avaliou-se o erro da validação cruzada, definindo novamente os valores ótimos do alfa para as regressões Ridge e Lasso, o erro dos testes aplicados aos modelos e os erros associados às configurações individuais, indicando o maior e o menor.

3.3.7 Comparativo do desempenho da matriz usando as 3 regressões e a faixa espectral entre 400 e 800 nm

Realizando o processo de validação cruzada, os valores do parâmetro de penalização (alfa) ficaram definidos como 0,294 e 0,736 para a Regressão Ridge para os dados das configurações aleatórias e ordenadas, respectivamente, e 0,0011 e 0,0021 para a regressão Lasso na análise das configurações aleatórias e ordenadas, respectivamente.

A Figura 40 mostra os espectros na faixa espectral entre 400 e 800 nm, com (a) representando as configurações aleatórias e (b) as configurações ordenadas.

Figura 40 – Espectros utilizados para as regressões para os comprimentos de onda entre 400 e 800 nm, com (a) configurações aleatórias e (b) configurações ordenadas.



Fonte: Autoria própria (2020)

Os resultados das regressões lineares são apresentados na Tabela 10, ressaltando que, para o erro de testes no treinamento, os valores em porcentagem são em relação ao maior valor individual de massa (2,0 kg) e ao maior valor aplicado simultaneamente no sistema (6,0 kg).

Tabela 10 – Comparação das regressões lineares aplicadas ao sistema usando os espectros entre 400 e 800 nm, indicando os valores associados a cada erro analisado

Erros	Regressões					
	Mín. Quadrados		Ridge		Lasso	
	Config. aleatória	Config. ordenada	Config. aleatória	Config. ordenada	Config. aleatória	Config. ordenada
Validação cruzada	–	–	0,221 kg	0,207 kg	0,249 kg	0,235 kg
Teste	0,278 kg (13,90% e 4,63%)	0,244 kg (12,20% e 4,06%)	0,243 kg (12,15% e 4,05%)	0,211 kg (10,55% e 3,52%)	0,271 kg (13,55% e 4,52%)	0,229 kg (11,45% e 3,82%)
Menor erro de configuração individual	0,080 kg	0,078 kg	0,049 kg	0,051 kg	0,046 kg	0,049 kg
Maior erro de configuração individual	0,709 kg	0,520 kg	0,678 kg	0,495 kg	0,677 kg	0,571 kg


Fonte: Autoria própria (2020)

De acordo com os resultados, e analisando em relação ao anterior (faixa entre 400 e 850 nm), houve uma pequena piora para o desempenho da regressão por mínimos quadrados. Para as regressões com penalização, houve estabilidade nos valores de erro de teste, para ambas as configurações, com pequena variação na ordem de unidades de gramas. Ainda para as duas últimas regressões, há praticamente o mesmo menor erro individual. Para esta faixa espectral, portanto, o melhor desempenho se mantém para a regressão Ridge para as configurações aplicadas de forma ordenada, com erro de teste de 0,211 kg. Essas diferenças ao se reduzir uma faixa de 50 nm devem-se ao fato de que há poucos comprimentos de onda relevantes para o sistema na faixa retirada, visto que houve uma ligeira piora para as regressões no geral em paralelo com o observado nas Figuras 37 e 39, em que a regressão Lasso selecionou como relevantes os comprimentos de onda entre 400 e 650 nm. Apesar das outras duas regressões não anularem os maiores comprimentos de onda, o valor dos coeficientes associados provavelmente é muito pequeno, tornando-os quase irrelevantes para o modelo.

3.3.8 Comparativo do desempenho da matriz usando as 3 regressões e a faixa espectral entre 400 e 750 nm

Os espectros utilizados para esta análise estão presentes na Figura 41, com (a) o espectro das configurações aleatórias e (b) das configurações ordenadas.

Figura 41 – Espectros utilizados para as regressões para os comprimentos de onda entre 400 e 750 nm, com (a) configurações aleatórias e (b) configurações ordenadas.



Fonte: Autoria própria (2020)

A Tabela 11 apresenta os principais resultados associados às regressões aplicadas aos espectros de transmissão entre 400 e 750 nm. Os valores obtidos de alfa

para a regressão Ridge após a validação cruzada para a presente faixa espectral foram de 0,365, para as configurações aleatórias, e 0,739 para as configurações ordenadas. Para a regressão Lasso, os valores encontrados foram os mesmos da faixa anterior (0,0011 e 0,0021).

Tabela 11 – Comparação das regressões lineares aplicadas ao sistema usando os espectros entre 400 e 750 nm, indicando os valores associados a cada erro analisado.

Erros	Regressões					
	Mín. Quadrados		Ridge		Lasso	
	Config. aleatória	Config. ordenada	Config. aleatória	Config. ordenada	Config. aleatória	Config. ordenada
Validação cruzada	–	–	0,222 kg	0,208 kg	0,249 kg	0,235 kg
Teste	0,283 kg (14,15% e 4,72%)	0,245 kg (12,25% e 4,08%)	0,243 kg (12,15% e 4,05%)	0,211 kg (10,55% e 3,52%)	0,271 kg (13,55% e 4,52%)	0,229 kg (11,45% e 3,82%)
Menor erro de configuração individual	0,078 kg	0,082 kg	0,053 kg	0,050 kg	0,046 kg	0,049 kg
Maior erro de configuração individual	0,705 kg	0,521 kg	0,676 kg	0,0,496 kg	0,677 kg 0,571 kg	


Fonte: Autoria própria (2020)

Para a essa faixa, as regressões apresentam os mesmos resultados da faixa anterior (400 e 800 nm) e, portanto, piores em relação à análise para o espectro entre 400 e 850 nm. Esta análise indica novamente que os comprimentos de onda presentes entre 750 e 800 nm não influenciam no resultado das regressões, pelo mesmo motivo da análise anterior: de acordo com a interpretação dos coeficientes para a regressão Lasso, não houve nenhum comprimento de onda considerado como relevante para a região entre 750 e 800 nm, tornando o resultado de teste da presente faixa idêntico ao anterior para as regressões com penalização.

3.3.9 Comparativo do desempenho da matriz usando as 3 regressões e a faixa espectral entre 400 e 650 nm

Os espectros utilizados para esta análise estão presentes na Figura 42, com (a) o espectro das configurações aleatórias e (b) das configurações ordenadas.

Figura 42 – Espectros utilizados para as regressões para os comprimentos de onda entre 400 e 650 nm, com (a) configurações aleatórias e (b) configurações ordenadas.



Fonte: Autoria própria (2020)

A Tabela 12 apresenta os principais resultados associados às regressões aplicadas aos espectros de transmissão entre 400 e 650 nm. Os valores de alfa

encontrados após a validação cruzada para a regressão Lasso foram os mesmos da última análise. Para a Ridge, os valores foram de 0,384 e 0,858 (configurações aleatórias e ordenadas).

Tabela 12 – Comparação das regressões lineares aplicadas ao sistema usando os espectros entre 400 e 650 nm, indicando os valores associados a cada erro analisado

Erros	Regressões					
	Mín. Quadrados		Ridge		Lasso	
	Config. aleatória	Config. ordenada	Config. aleatória	Config. ordenada	Config. aleatória	Config. ordenada
Validação cruzada	–	–	0,224 kg	0,212 kg	0,249 kg	0,235 kg
Teste	0,289 kg (14,45% e 4,82%)	0,247 kg (12,35% e 4,12%)	0,245 kg (12,25% e 4,08%)	0,213 kg (10,65% e 3,55%)	0,274 kg (13,70% e 4,57%)	0,229 kg (11,45% e 3,82%)
Menor erro de configuração individual	0,072 kg	0,082 kg	0,044 kg	0,058 kg	0,046 kg	0,049 kg
Maior erro de configuração individual	0,700 kg	0,531 kg	0,677 kg	0,0,499 kg	0,677 kg	0,571 kg

Fonte: Autoria própria (2020)

Em comparação com a última análise, houve uma pequena piora em unidades de gramas para as duas primeiras regressões, tanto para as configurações aleatórias quanto para as ordenadas. No caso da regressão Lasso, o resultado para as configurações ordenadas se manteve. Mesmo assim, o melhor resultado desta análise é novamente para a regressão Ridge, com erro de 0,213 kg. Apesar das pequenas pioras, pode-se dizer que as regressões mantêm os resultados estáveis. Sabe-se que a Lasso mostrou que os comprimentos de onda relevantes estão presentes entre 400 e 650 nm, o que justifica a estabilidade no resultado dessa regressão em relação ao anterior. Para a Ridge, por não anular os coeficientes conforme a Lasso faz, houve uma ligeira piora em unidades de gramas em relação ao espectro de 400 a 750 nm.


A presente faixa espectral é a região em que as informações estão relacionadas principalmente aos WGM, fenômeno que viabilizou a aplicação da matriz desenvolvida com os sensores multiplexados. No trabalho desenvolvido em 2019 com o sistema de sensores de macrocurvatura em série não acoplados (KAMIZI *et al.*, 2019), foi sugerido que os WGM permitiam a multiplexação destes dispositivos. No presente trabalho, comprovou-se tal fato ao verificar-se que os comprimentos de onda mais influentes

para o sistema estão presentes na faixa espectral onde o fenômeno é predominante.

3.3.10 Comparativo do desempenho da matriz usando as 3 regressões e a faixa espectral entre 650 e 800 nm

A fim de verificar o papel dos maiores comprimentos de onda no desempenho das regressões, reduziu-se a faixa espectral para os comprimentos de onda entre 650 e 800 nm, espectros presentes na Figura 43.

Figura 43 – Espectros utilizados para as regressões para os comprimentos de onda entre 650 e 800 nm, com (a) configurações aleatórias e (b) configurações ordenadas.



Fonte: Autoria própria (2020)

Para os valores de alfa, após a validação cruzada, a regressão Lasso obteve o valor de 0,001 para ambos tipos de aplicações de carga, e a Ridge obteve valores de 0,004 também para os dois casos.

A Tabela 13 mostra os resultados das regressões para os espectros em questão.

Tabela 13 – Comparação das regressões lineares aplicadas ao sistema usando os espectros entre 650 e 800 nm, indicando os valores associados a cada erro analisado

Erros	Regressões					
	Mín. Quadrados		Ridge		Lasso	
	Config. aleatória	Config. ordenada	Config. aleatória	Config. ordenada	Config. aleatória	Config. ordenada
Validação cruzada	–	–	0,316 kg	0,231 kg	0,402 kg	0,357 kg
Teste	0,412 kg (20,60% e 6,87%)	0,300 kg (15,00% e 5,00%)	0,328 kg (16,40% e 5,47%)	0,246 kg (12,30% e 4,10%)	0,439 kg (21,95% e 7,32%)	0,344 kg (17,20% e 5,73%)
Menor erro de configuração individual	0,129 kg	0,117 kg	0,110 kg	0,071 kg	0,207 kg	0,094 kg
Maior erro de configuração individual	0,929 kg	0,690 kg	0,817 kg	0,501 kg	0,809 kg	0,571 kg

Fonte: Autoria própria (2020)

Há uma piora significativa do desempenho das regressão ao considerar apenas os espectros referentes ao comprimentos de onda acima de 650 nm, região onde são predominantes as variações de intensidade decorrentes de perdas simples por curvatura. Tal fato comprova o citado para as análises anteriores: os menores comprimentos de onda são de alta relevância para o sistema. Mesmo com o aumento do erro, a regressão Ridge se mantém como melhor regressão, com erro absoluto médio de teste de 0,245 kg para as configurações ordenadas.

3.3.11 Comparativo do desempenho da matriz usando as 3 regressões e diferentes faixas espectrais

Na primeira análise, com o espectro completo entre 400 e 850 nm, o melhor resultado foi obtido para a regressão Ridge para as configurações ordenadas com erro

de 0,208 kg. O previsto, teoricamente, era que a regressão Lasso pudesse penalizar anulando os valores menos relevantes de comprimento de onda para o sistema, mas a regressão Ridge conseguiu um melhor desempenho. A regressão Ridge também penaliza as variáveis menos relevantes para o sistema, aproximando-as do zero. É muito provável que essas variáveis penalizadas sejam muito próximas para as duas regressões, mas a Ridge conseguiu obter menores erros absolutos de teste. Ainda para esta análise, notou-se que as configurações ordenadas possuem menores erros absolutos quando comparadas com as aleatórias para todas as regressões. Como citado, provavelmente a ordem sequencial das cargas permitiu que as regiões sofressem pressão da mesma carga por mais tempo, mesmo que retiradas a cada medição.

Comparando os resultados para as diferentes regiões espectrais, a regressão Ridge, para as configurações em ordem crescente, apresentou o melhor desempenho em todos os casos. A regularização durante o treinamento das regressões Ridge e Lasso tem o intuito de penalizar aqueles comprimentos de onda que não contribuem para a identificação da massa e região, ou seja, os menos relevantes para o modelo. A Ridge penaliza estes valores reduzindo-os ao mínimo possível, enquanto a Lasso os reduz a zero. Este é o motivo que permitiu essas duas regressões manterem praticamente constantes os resultados: sempre reduziam a zero (ou aproximavam) os valores indiferentes para os modelos, repetindo sempre o mesmo erro. Como para os comprimentos acima de 650 nm houve os piores resultados, é nessa região que se encontram os valores de intensidade que tem menor relevância para o sistema, conforme visto para as análises individuais da Lasso para o espectro entre 400 e 850 nm, indicando que os valores de comprimento de onda abaixo de 650 nm são cruciais para as análises.

Portanto, considerando todas as análises espectrais, verifica-se que, para este trabalho, a regressão Ridge obteve os melhores desempenhos, com o menor erro absoluto médio para a faixa entre 400 e 850 nm no valor de 0,208 kg. Porém, considerando que a regressão Lasso reduziu em cerca de 98 % o conjunto de dados, obtendo menos de 20 g de diferença em relação ao melhor desempenho da Ridge, talvez seja vantajoso considerar essa regressão como melhor utilização para o sistema em termos de exigência computacional e redução do conjunto de dados inicial, uma vez que se observou qual faixa é mais relevante para o sistema, segundo tal regressão.

3.3.12 Validação com conjunto de testes adicional externo

Um último teste visou utilizar um conjunto de configurações adicional para testar o modelo treinado com as 155 configurações de teste, para a faixa espectral de 400 a 850 nm. Para isso, foi realizado um novo ensaio, no qual o sistema foi submetido a um conjunto de 32 configurações geradas por algoritmo aleatoriamente, todas diferentes das 155 iniciais.

Neste caso, como o treinamento é feito com todo o conjunto de dados (das 155 configurações), não foi necessário definir o *Random State* por não precisar separar o conjunto entre dados de treinamento e teste, apenas mantendo o alfa com valores iguais ao da primeira análise. A validação foi realizada para as três regressões já conhecidas, totalizando 6 regressões, o que inclui o treinamento com as configurações ordenadas e aleatórias.

A Tabela 14 apresenta os erros associados aos testes realizados.

Tabela 14 – Valores associados aos erros obtidos usando as 155 configurações como treinamento e 32 duas configurações externas aferidas para teste

Erros	Regressões					
	Mín. Quadrados		Ridge		Lasso	
	Config. aleatória	Config. ordenada	Config. aleatória	Config. ordenada	Config. aleatória	Config. ordenada
Teste	0,880 kg (44,00% e 14,67%)	1,017 kg (50,85% e 16,95%)	0,695 kg (34,75% e 11,58%)	0,836 kg (41,80% e 13,93%)	0,638 kg (31,90% e 10,68%)	0,900 kg (45,00% e 15,00%)
Menor erro de configuração individual	0,360 kg	0,301 kg	0,217 kg	0,146 kg	0,158 kg	0,159 kg
Maior erro de configuração individual	1,387 kg	1,689 kg	1,096 kg	1,511 kg	1,072 kg	1,628 kg

Fonte: Autoria própria (2020)

Como se pode notar, os erros absolutos médios associados aos testes são muito grandes em relação aos anteriores. As configurações individuais apresentaram erros de até 2,168 kg. Apesar do desempenho ruim para os modelos em comparação com os testes anteriores, a regressão Lasso apresentou o melhor resultado entre todas, com os menores erros associados.

O que ocorre é que o sistema é montado sempre que se faz medições, modificando alguns fatores externos que podem comprometer o reconhecimento dos

tratamentos de dados. Conexões das fibras com pequenas diferenças, variações de intensidade de luz causadas e outros fatores associados aos componentes do sistema podem influenciar no desempenho. É por esse motivo que o resultado foi muito distinto. Nos testes anteriores, as 155 configurações foram subdivididas em treinamento e teste e, portanto, o modelo criado para as regressões foi testado com valores aferidos nas mesmas condições, resultando em melhores resultados. Apesar deste resultado negativo para o sistema experimental de bancada utilizado, os problemas citados podem ser minimizados em sistemas comerciais garantindo conexões e condições do sistema sempre iguais. Desse modo, todas as medições apresentariam resultados equivalentes ao mesmo sistema, melhorando a resposta como um todo.

4 CONCLUSÕES

Este trabalho utilizou sensores óticos multiplexados, baseados em macrocurvatura em fibras óticas em um sistema tátil acoplado com o intuito de identificar cargas e posicionamento através da reconstrução do sinal por regressões lineares.

A análise individual dos sensores desenvolvidos confirmou a capacidade do elemento de diferenciar cargas aplicadas por meio de seus espectros. Testes consecutivos mostraram que os dispositivos respondem bem e estavelmente para cargas até 3,0 kg, espaçadas de 0,3 kg. Os 4 elementos sensores presentes na matriz principal caracterizados indicaram o acoplamento presente, assim como as caracterizações das regiões definidas para análise na matriz demonstraram as diferentes respostas, não tornando a simetria do sistema um problema. Tal fato, além do acoplamento, também associado a pequenas diferenças na produção e construção de cada elemento sensor.

Por principal, a matriz de sensoriamento tátil desenvolvida mostrou-se capaz de realizar um sensoriamento determinando cargas aplicadas e suas localizações para 5 regiões associadas a respostas de 4 sensores. O menor erro obtido foi para a regressão Ridge com valor de 0,208 kg para a faixa espectral entre 400 e 850 nm, para as configurações de teste aplicadas de forma ordenada. Este erro representa 10,40% e 3,47% em relação ao maior valor de carga aplicada por região (2,0 kg) e ao maior valor de carga aplicada simultaneamente na matriz (6,0 kg), respectivamente.

Para as outras faixas espectrais de análise, as regressões mantiveram pequenos aumentos em relação ao espectro completo, verificando certa estabilidade. Ainda assim, em todos os casos, a regressão Ridge obteve os menores valores de erro absoluto médio. Em termos de exigência computacional e redução do conjunto de dados inicial, talvez seja viável considerar a utilização da regressão Lasso para o sistema, já que esta considerou em média apenas 2 % do total de comprimentos de onda como relevantes e sua diferença de erro em relação à regressão Ridge é de poucos gramas. Percebeu-se que as regressões obtiveram uma piora significativa ao utilizar a faixa de análise entre 650 e 800 nm, indicando que os comprimentos de onda abaixo de 650 nm são relevantes para o sistema, fato comprovado com a análise dos coeficientes obtidos pela Lasso. Como a faixa entre 400 e 650 nm é a região onde as variações de intensidade são predominantemente devido aos WGM, e é o local que

possui os comprimentos mais relevantes, mostrou-se que tal fenômeno é essencial e possibilita o funcionamento do sistema.

Ainda, notou-se que a ordenação das configurações impactou no desempenho das regressões, que sempre foram melhores em relação às configurações aleatórias. Um teste externo indicou que o sistema é passível de erros associados à montagem, contendo uma configuração diferente daquela para treinamento.

Como trabalhos futuros, pode-se criar um ambiente em tempo real e aumentar o número de regiões a serem monitoradas, assim como alterar os valores de cargas para análise do desempenho da matriz.

5 PUBLICAÇÕES ASSOCIADAS COM O TRABALHO

Os artigos seguintes foram publicados (ou aceitos para publicação) durante o mestrado em periódicos e congressos.

5.1 PUBLICAÇÕES

LUGARINI, Diogo; CARVALHO, Vinicius; KAMIZI, Marcos Aleksandro; FABRIS, José L; MULLER, Marcia. Fabrication of a flexible tactile sensing system with macro-bend optical fiber sensors. *In*: FABRIS, : José Luís; MARTINEZ, Maria Aparecida Gonçalves; GIRALDI., Maria Thereza Miranda Rocco (Ed.). **Proceedings of Latin America Workshop on Optical Fiber Sensors (LAWOFS), SBMO**. Rio de Janeiro: [s.n.], 2019. p. 73–77.

5.2 PUBLICAÇÕES EM COAUTORIA

KAMIZI, Marcos A.; LUGARINI, Diogo; FUSER, Ruahn; NEGRI, Lucas H.; FABRIS, José L.; MULLER, Marcia. Multiplexing optical fiber macro-bend load sensors. **Journal of Lightwave Technology**, v. 37, n. 18, p. 6858–6863, Sep. 2019.

REFERÊNCIAS

AGRAWAL, Govind P. **Fiber-Optic Communication Systems: Fundamentals and applications**. [S.l.]: John Wiley & Sons, Inc., 2010.

ALTMAN, Naomi; KRZYWINSKI, Martin. Simple linear regression. **Nature Methods**, Springer Science and Business Media LLC, v. 12, n. 11, p. 999–1000, Oct. 2015.

BEZERRA, Fernando de O.; NUNES, Regina C. R.; GOMES, Ailton S.; OLIVEIRA, Márcia G.; ITO, Edson N. Efeito payne em nanocompósitos de NBR com montmorilonita organofílica. **Polímeros**, FapUNIFESP (SciELO), 2013.

BINGHAM, N. H.; FRY, John M. **Regression: Linear models in statistics**. [S.l.]: Springer-Verlag London, 2010. XIII, 284 p.

BROWN, Tom G. Optical fibers and fiber-optic communications. *In*: BASS, Eric W. Van Stryland Michael (Ed.). **Fiber Optics Handbook: Fiber, Devices, and Systems for Optical Communications**. [S.l.]: McGraw-Hill Education, 2002.

CHAI, T.; DRAXLER, R. R. Root mean square error rmse or mean absolute error mae? **Geoscientific Model Development Discussions**, Copernicus GmbH, v. 7, n. 1, p. 1525–1534, Feb, 2014.

CHEN, Weirong; ZHANG, Yanxin; ZHANG, Weigang; CHEN, Qiang; ZHANG, Yunxiao; LI, Mengxia; ZHAO, Wei; ZHANG, Yunshan; YAN, Tieyi. High-sensitive tilt sensor based on macro-bending loss of single mode fiber. **Optical Fiber Technology**, Elsevier BV, v. 50, p. 1–7, Jul. 2019.

CHIANG, Chia-Chin; CHAO, Jian-Cin. Whispering gallery mode based optical fiber sensor for measuring concentration of salt solution. **Journal of Nanomaterials**, Hindawi Limited, v. 32, p. 1–4, May. 2013.

CONNELLY, Michael J. Detection | fiber sensors. *In*: GUENTHER, Robert D. (Ed.). **Encyclopedia of Modern Optics**. [S.l.]: Elsevier, 2005. p. 191–200.

CRANCH, Geoffrey A. Fiber-optic sensor multiplexing principles. *In*: SANTOS, Faramarz Farahi José Luís (Ed.). **Handbook of Optical Sensors**. [S.l.]: CRC Press, 2014. p. 377–456.

DAKIN, J P. Multiplexed and distributed optical fibre sensor systems. **Journal of Physics E: Scientific Instruments**, IOP Publishing, v. 20, n. 8, p. 954–967, Aug. 1987.

DENISOV, I. V.; SEDOV, V. A.; RYBAL'CHENKO, N. A. A fiber-optic microbending temperature sensor. **Instruments and Experimental Techniques**, Springer Science and Business Media LLC, v. 48, n. 5, p. 683–685, Sep. 2005.

FIDANBOYLU K; EFENDIOGLU, H. S. Fiber optic sensors and their applications. *In: IATS'09*. Karabuk, Turkey: [s.n.], 2009.

GIOZZA, William Ferreira; CONFORTI, Evandro; WALDMAN, Hélio. **Fibras Ópticas: Tecnologia e projeto de sistemas**. [S.l.]: Makron Books, 1991. 734 p.

GIRÃO, Pedro Silva; RAMOS, Pedro Miguel Pinto; POSTOLACHE, Octavian; PEREIRA, José Miguel Dias. Tactile sensors for robotic applications. **Measurement**, Elsevier BV, v. 46, n. 3, p. 1257–1271, Apr. 2013.

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**, v. 4, n. 1, p. 34–40, 1986.

HOERL, Arthur E.; KENNARD, Robert W. Ridge regression: Biased estimation for nonorthogonal problems. **Technometrics**, Informa UK Limited, v. 12, n. 1, p. 55–67, Feb. 1970.

JAMES, Gareth; WITTEN, Daniela; HASTIE, Trevor; TIBSHIRANI, Robert. **An Introduction to Statistical Learning**: with applications in r. [S.l.]: Springer, New York, NY, 2013.

JUNG, Sung-Hoon; LEE, Dong-Ho; KWON, Kwang-Hee; SONG, Jae-Won. Water sensor using macrobending-sensitive fiber for real-time submersion monitoring. **Optics Communications**, v. 260, n. 1, p. 105–108, 2006.

KAMIZI, Marcos A.; LUGARINI, Diogo; FUSER, Ruahn; NEGRI, Lucas H.; FABRIS, José L.; MULLER, Marcia. Multiplexing optical fiber macro-bend load sensors. **Journal of Lightwave Technology**, v. 37, n. 18, p. 6858–6863, Sep. 2019.

KAMIZI, Marcos A.; PEDROSO, Marcelo A.; FABRIS, Jose L.; MULLER, Marcia. Fabrication and characterization of fiber bragg grating based sensors for force measurements. *In: 2017 SBMO/IEEE MTT-S International Microwave and Optoelectronics Conference (IMOC)*. [S.l.]: IEEE, 2017.

KAMIZI, Marcos A.; PEDROSO, Marcelo A.; FABRIS, José L.; MULLER, Marcia. Smartphone technology applied in an approach for multiplexing of fibre optic intensity-modulated macro-bend based sensors. *In: 26th International Conference on Optical Fiber Sensors*. [S.l.]: Optical Society of America, 2018. p. TuE82.

KROHN, David A.; MACDOUGALL, Trevor W.; MENDEZ, Alexis. **Fiber Optic Sensors: Fundamentals and applications**. [S.l.]: Society of Photo-Optical Instrumentation Engineers (SPIE), 2014.

LUGARINI, Diogo; CARVALHO, Vinicius; KAMIZI, Marcos Aleksandro; FABRIS, José L; MULLER, Marcia. Fabrication of a flexible tactile sensing system with macro-bend optical fiber sensors. *In: FABRIS, : José Luís; MARTINEZ, Maria Aparecida Gonçalves; GIRALDI., Maria Thereza Miranda Rocco (Ed.). Proceedings of Latin America Workshop on Optical Fiber Sensors (LAWOFS), SBMO*. Rio de Janeiro: [s.n.], 2019. p. 73–77.

MARCUSE, Dietrich. Curvature loss formula for optical fibers. **J. Opt. Soc. Am.**, OSA, v. 66, n. 3, p. 216–220, Mar. 1976.

MITSCHKE, Fedor. **Fiber Optics: Physics an technology**. [S.l.]: Springer-Verlag Berlin Heidelberg, 2010. 288 p.

MORGAN, R.; BARTON, J. S.; HARPER, P. G.; JONES, J. D. C. Wavelength dependence of bending loss in monomode optical fibers: effect of the fiber buffer coating. **Optics Letters**, The Optical Society, v. 15, n. 17, p. 947–949, Sep. 1990.

NEGRI, Lucas H. **Inteligência computacional no sensoriamento a fibra ótica**. Fev. 2017. 113 p. Tese (Doutorado) — Universidade Tecnológica Federal do Paraná, Curitiba, Fev. 2017.

ORAEVSKY, Anatolii N. Whispering-gallery waves. **Quantum Electronics**, IOP Publishing, v. 32, n. 5, p. 377–400, May. 2002.

PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; BLONDEL, M.; PRETTENHOFER, P.; WEISS, R.; DUBOURG, V.; VANDERPLAS, J.; PASSOS, A.; COURNAPEAU, D.; BRUCHER, M.; PERROT, M.; DUCHESNAY, E. Scikit-learn: Machine learning in Python. **Journal of Machine Learning Research**, v. 12, p. 2825–2830, 2011.

PEDROSO, Marcelo. **Sensoriamento *quasi*-distribuído de forças com transdutores de rede de Bragg em fibras óticas**. Fev. 2018. 98 p. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, Curitiba, Fev. 2018.

PEDROSO, Marcelo A.; NEGRI, Lucas H.; KAMIZI, Marcos A.; FABRIS, José L.; MULLER, Marcia. Tactile sensor array with fiber bragg gratings in quasi-distributed sensing. **Journal of Sensors**, Hindawi Limited, v. 2018, p. 1–8, 2018.

PLAGGE, J.; RICKER, A.; KRÖGER, N.H.; WRIGGERS, P.; KLÜPPEL, M. Efficient modeling of filled rubber assuming stress-induced microscopic restructurization. **International Journal of Engineering Sciences**, Elsevier BV, v. 151, p. 103291, Jun. 2020.

QIU, Jianchun; ZHENG, Dongjian; ZHU, Kai; FANG, Bin; CHENG, Lin. Optical fiber sensor experimental research based on the theory of bending loss applied to monitoring differential settlement at the earth-rock junction. **Journal of Sensors**, Hindawi Limited, v. 2015, p. 1–13, 2015.

RAYLEIGH, Lord. CXII. the problem of the whispering gallery. **The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science**, Informa UK Limited, v. 20, n. 120, p. 1001–1004, Dec. 1910.

SAKAI, Jun ichi. Simplified bending loss formula for single-mode optical fibers. **Appl. Opt.**, OSA, v. 18, n. 7, p. 951–952, Apr. 1979.

SHARMA, A. B.; AL-ANI, A.-H.; HALME, S. J. Constant-curvature loss in monomode fibers: an experimental investigation. **Appl. Opt.**, OSA, v. 23, n. 19, p. 3297–3001, Oct. 1984.

TESFAMARIAM, S.; LIU, Z. Seismic risk analysis using bayesian belief networks. *In: Handbook of Seismic Risk Analysis and Management of Civil Infrastructure Systems*. [S.l.]: Elsevier, 2013. p. 175–208.

TIBSHIRANI, Robert. Regression shrinkage and selection via the lasso. **Journal of the Royal Statistical Society. Series B (Methodological)**, [Royal Statistical Society, Wiley], v. 58, n. 1, p. 267–288, 1996.

UDD, Eric. The emergence of fiber optic sensor technology: An introduction for engineers and scientists. *In: SPILLMAN, Eric Udd ; William B. (Ed.). Fiber Optic Sensors*. [S.l.]: John Wiley & Sons, Inc., 2011. p. 377–456.

WANG, Pengfei; SEMENOVA, Yuliya; WU, Qiang; FARRELL, Gerald; TI, Yunqiang; ZHENG, Jie. Macrobending single-mode fiber-based refractometer. **Appl. Opt.**, OSA, v. 48, n. 31, p. 6044–6049, Nov. 2009.

WANG, Pengfei; SEMENOVA, Yuliya; WU, Qiang; FARELL, Gerald. A fiber-optic voltage sensor based on macrobending structure. **Optics & Laser Technology**, v. 43, n. 5, p. 922–925, 2011.

WEISBERG, Sanford. **Applied Linear Regression**. [S.l.]: John Wiley & Sons, Inc., 2013. 368 p.

YAN, Xin; SU, Xiao Gang. **Linear Regression Analysis**: Theory and computing. [S.l.]: WORLD SCIENTIFIC, 2009.

YIN, Guolu; ZHANG, Fengchan; XU, Baijie; HE, Jun; WANG, Yiping. Intensity-modulated bend sensor by using a twin core fiber: theoretical and experimental studies. **Optics Express**, The Optical Society, v. 28, n. 10, May. 2020.