



**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ  
CAMPUS CURITIBA**

**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E  
INFORMÁTICA INDUSTRIAL - CPGEI**

**LUCAS HERMANN NEGRI**

**INTELIGÊNCIA COMPUTACIONAL NO  
SENSORIAMENTO A FIBRA ÓTICA**

**TESE DE DOUTORADO**

**CURITIBA  
FEVEREIRO DE 2017**

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ**  
Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial

---

**TESE DE DOUTORADO**

apresentada à UTFPR  
como requisito parcial para obtenção do título de

**DOUTOR EM CIÊNCIAS**

por

**LUCAS HERMANN NEGRI**

---

**INTELIGÊNCIA COMPUTACIONAL NO  
SENSORIAMENTO A FIBRA ÓTICA**

---

Orientador:

PROF. DR. JOSÉ LUÍS FABRIS

UTFPR

Coorientador:

PROF. DR. ALEKSANDER SADE PATERNO

UDESC

Banca Examinadora:

PROF. DR. JOSÉ LUÍS FABRIS

UTFPR

PROF. DR. ALEXANDRE DE ALMEIDA PRADO POHL

UTFPR

PROF. DR. LÚCIA VALERIA RAMOS DE ARRUDA

UTFPR

PROF. DR. LEANDRO DOS SANTOS COELHO

UFPR/PUCPR

PROF. DR. PEDRO BERTEMES FILHO

UDESC

Curitiba, 20 de Fevereiro de 2017

**LUCAS HERMANN NEGRI**

**INTELIGÊNCIA COMPUTACIONAL NO SENSORIAMENTO A FIBRA  
ÓTICA**

Teste de doutorado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial da Universidade Tecnológica Federal do Paraná como requisito parcial para a obtenção do título de "Doutor em Ciências" - Área de Concentração: Fotônica em Engenharia.

Orientador: Prof. Dr. José Luís Fabris

Coorientador: Prof. Dr. Aleksander Sade Paterno

Curitiba

2017

Dados Internacionais de Catalogação na Publicação

---

N386i  
2017 Negri, Lucas Hermann  
Inteligência computacional no sensoriamento a fibra ótica /  
Lucas Hermann Negri.--  
112 f.: il.; 30 cm.

Texto em português com resumo em inglês

Disponível também via World Wide Web

Tese (Doutorado) – Universidade Tecnológica Federal do Paraná.  
Programa de Pós-graduação em Engenharia Elétrica e Informática  
Industrial, Curitiba, 2017

1. Inteligência artificial – Processamento de dados. 2. Sensoriamento remoto. 3. Redes de Bragg. 4. Redes neurais (Computação). 5. Simulação (Computadores digitais). 6. Compressão de dados (Computação). 7. Comunicações ópticas. 8. Engenharia elétrica – Teses. I. Fabris, José Luís. II. Paterno, Aleksander Sade. III. Universidade Tecnológica Federal do Paraná. Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial. IV. Título.

---

CDD: Ed. 22 – 621.3

Biblioteca Central da UTFPR, Câmpus Curitiba

Título da Tese Nº. \_\_\_\_\_

# **Inteligência Computacional no Sensoriamento a Fibra Ótica**

por

## **Lucas Hermann Negri**

**Orientador:** Prof. Dr. José Luís Fabris (UTFPR)

**Coorientador:** Prof. Dr. Aleksander Sade Paterno (UDESC)

Esta tese foi apresentada como requisito parcial à obtenção do grau de DOUTOR EM CIÊNCIAS – Área de Concentração: Fotônica em Engenharia pelo Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial – CPGEI – da Universidade Tecnológica Federal do Paraná – UTFPR, às 13h do dia 20 de fevereiro de 2016. O trabalho foi aprovado pela Banca Examinadora, composta pelos doutores:

---

Prof. Dr. José Luís Fabris  
(Presidente – UTFPR)

---

Prof. Dr. Leandro dos Santos Coelho  
(UFPR / PUC-PR)

---

Prof. Dr. Pedro Bertemes Filho  
(UDESC)

---

Prof. Dr. Alexandre de Almeida Prado Pohl  
(UTFPR)

---

Prof<sup>a</sup>. Dr<sup>a</sup>. Lucia Valeria Ramos de Arruda  
(UTFPR)

Visto da Coordenação:

---

Prof. Jean Carlos Cardozo da Silva, Dr.  
(Coordenador do CPGEI)

## AGRADECIMENTOS

Ao meu orientador, professor José Luís Fabris, pela oportunidade de realização do doutorado, pelos conhecimentos compartilhados na área de ótica e de física experimental e pela colaboração direta em todos os trabalhos publicados ao longo destes quatro anos. Ao meu coorientador, professor Aleksander Paterno, pelas ideias de trabalhos, visão otimista e incentivo à pesquisa. À professora Marcia Muller, orientadora extraoficial, pela revisão e colaboração técnica nos trabalhos realizados, além do incentivo moral. Agradeço conjuntamente aos professores do CPGEI, Valmir de Oliveira, Hypolito José Kalinowski, Alexandre de Almeida Prado Pohl, Jean Carlos Cardozo da Silva e Heitor Silvério pelo auxílio e colaboração em trabalhos e eventos realizados durante o doutorado.

Aos colegas integrantes ou ex-integrantes do Laboratório de Laser, Elberth Manfron Schiefer, Fernanda Mantuan Dala Rosa de Oliveira, Marcelo Antonio Pedroso, Marcos Aleksandro Kamizi, Marianne Sumie Kawano, Rafael Eleodoro de Goes e Rodrigo Ricetti. Aos colegas e do Laboratório de Fotônica, Camila Carvalho de Moura, Everaldo Ribeiro Brinhole, Jean Filipe Kuhne, Larissa Nunes da Costa e, em especial à colega e esposa Yujuan Wang. Agradeço também aos integrantes do Laboratório de Bioinformática e Inteligência Computacional pelo auxílio com os experimentos de evolução diferencial.

À Universidade Tecnológica Federal – Paraná e aos seus servidores, por fornecer um ambiente favorável à pesquisa.

Ao apoio financeiro fornecido aos órgãos de fomento CAPES, CNPq, Fundação Araucária e FINEP.

À minha família, brasileira e chinesa.

## SUMÁRIO

<b>CAPÍTULO 1 – INTRODUÇÃO.....</b>	<b>18</b>
1.1 MOTIVAÇÃO.....	18
1.2 ESTADO DA ARTE.....	19
1.2.1 Uso de FBGs no sensoriamento táctil distribuído.....	20
1.2.2 Espalhamento inverso em FBGs.....	21
1.3 OBJETIVOS.....	21
1.3.1 Objetivo geral.....	22
1.3.2 Objetivos específicos.....	22
1.3.3 Estrutura da tese.....	23
<b>CAPÍTULO 2 – FUNDAMENTAÇÃO TEÓRICA.....</b>	<b>24</b>
2.1 REDES NEURAIAS ARTIFICIAIS.....	24
2.1.1 Princípio de funcionamento.....	25
2.1.2 Métodos de treinamento.....	28
2.2 MÁQUINAS DE VETOR DE SUPORTE PARA REGRESSÃO.....	32
2.3 SENSORIAMENTO COMPRESSIVO.....	34
2.3.1 Princípio de funcionamento.....	34
2.3.2 Algoritmos para sensoriamento compressivo.....	37
2.4 EVOLUÇÃO DIFERENCIAL.....	40
2.4.1 Etapas do método.....	40
2.4.2 Exemplo do processo evolutivo.....	43
2.4.3 Escolha dos parâmetros e desempenho do método.....	45
2.5 REDES DE BRAGG EM FIBRA ÓTICA.....	45
2.5.1 Princípio de funcionamento.....	46
2.5.2 Métodos de interrogação.....	49
2.5.3 O método das matrizes de transferência.....	50
<b>CAPÍTULO 3 – ESTIMAÇÃO DA POSIÇÃO DE CARGAS EM SUPERFÍCIES UTILIZANDO FBGS.....</b>	<b>52</b>
3.1 Primeiro Sistema.....	52
3.1.1 Configuração experimental.....	52

3.1.2	Estimação da posição da carga.....	54
3.1.3	Resultados.....	55
3.2	Segundo Sistema.....	58
3.2.1	Configuração experimental.....	58
3.2.2	Estimação da posição da carga.....	60
3.2.3	Resultados.....	62

**CAPÍTULO 4 – SISTEMA DE MAPEAMENTO DE FORÇAS COM RESOLUÇÃO  
APERFEIÇOADA.....66**

4.1	Primeira Versão.....	66
4.1.1	Cabeças sensoras.....	66
4.1.2	Configuração do sistema de sensoriamento de forças.....	68
4.1.3	Método para o mapeamento de forças utilizando sensoriamento compressivo.....	70
4.1.4	Metodologia de avaliação.....	71
4.1.5	Resultados.....	72
4.2	Segunda Versão.....	78
4.2.1	Cabeças sensoras.....	79
4.2.2	Configuração do sistema de sensoriamento de forças.....	79
4.2.3	Novo método para o mapeamento de forças utilizando sensoriamento compressivo e evolução diferencial.....	80
4.2.4	Metodologia de avaliação.....	81
4.2.5	Resultados.....	82

**CAPÍTULO 5 – SOLUÇÃO DO PROBLEMA DO ESPALHAMENTO INVERSO EM  
FBGS POR MEIO DE EVOLUÇÃO DIFERENCIAL.....89**

5.1	Determinação do Perfil de Estiramento por Evolução Diferencial.....	89
5.1.1	Metodologia de avaliação.....	91
5.1.2	Resultados.....	92
5.2	Processamento Paralelo em GPU.....	93
5.2.1	Implementação em GPU.....	93
5.2.2	Metodologia de avaliação.....	94
5.2.3	Resultados.....	94
5.3	Verificação Experimental.....	96

5.3.1 Metodologia de avaliação.....	96
5.3.2 Resultados.....	98
<b>CAPÍTULO 6 – CONCLUSÕES.....</b>	<b>101</b>
<b>PUBLICAÇÕES.....</b>	<b>104</b>
<b>REFERÊNCIAS.....</b>	<b>106</b>

## LISTA DE FIGURAS

Figura 1: Modelo esquemático de um neurônio e seus componentes.....	25
Figura 2: Exemplo de MLP cuja camada de entrada C1, contém as entradas $x_1$ e $x_2$ , além da entrada de polarização com valor de -1, dois neurônios na camada escondida (C2) e dois neurônios na camada de saída (C3). As setas indicam as conexões sinápticas entre os neurônios, cada uma possuindo um peso sináptico.....	26
Figura 3: Exemplo de propagação dos sinais de entrada 2,0 e 1,0 em uma MLP com duas entradas, uma camada escondida com dois neurônios e camada de saída com um neurônio (sinal de saída igual a 0,4).....	27
Figura 4: Esquemático da placa de metal (vista de cima), mostrando sua divisão em 10 segmentos e o posicionamento dos sensores $s_1$ até $s_4$ .....	36
Figura 5: Valores de deformação medidos pelos sensores $s_1$ até $s_4$ .....	36
Figura 6: Comparação entre a recuperação do sinal original (a) por meio da minimização da norma $l_1$ (b) e da norma $l_2$ (c).....	37
Figura 7: Etapas do método de evolução diferencial.....	41
Figura 8: Exemplo de convergência da população de soluções durante o processo de otimização no método de DE. A população de soluções é mostrada para os instantes após: (a) estado inicial, (b) 30 iterações, (c) 60 iterações e (d) 90 iterações. O eixo horizontal corresponde à variável $x$ , e o vertical à variável $y$ .....	44
Figura 9: Esquemático simplificado de uma FBG, identificando o índice de refração do ambiente externo ( $n_0$ ), da casca ( $n_1$ ), do núcleo ( $n_2$ ) e dos planos da rede ( $n_3$ ), além do espaçamento entre os planos (período de modulação).....	46
Figura 10: Comparativo entre o espectro de reflexão de uma FBG sem apodização e de uma FBG apodizada por meio de um envelope Gaussiano na modulação do índice de refração do núcleo.....	48
Figura 11: Esquemático identificando o modo contra propagante (a) e o modo propagante (b) em um FBG, em um segmento identificado pela posição no eixo de propagação $z$ , que se estende de 0 até o comprimento $l$ .....	50

Figura 12: Esquemático da placa de PMMA, mostrando o posicionamento das FBGs A, B, C e D.....	53
Figura 13: Sistema de interrogação das FBGs.....	54
Figura 14: Estimativa do mapa do erro Euclidiano, calculado pela interpolação dos dados experimentais para a região central da placa.....	57
Figura 15: Deslocamento do comprimento de onda de pico das FBGs após a remoção da carga de teste no ponto $x = 15$ cm e $y = 15$ cm.....	57
Figura 16: (a) Esquemático da cabeça sensora, composta por uma FBG encapsulada em um bloco retangular de silicone e (b) foto da cabeça sensora. A aplicação transversal de uma força resulta na tração longitudinal da fibra na qual a rede foi gravada.....	59
Figura 17: Esquemático (visão superior) do sistema de sensoriamento distribuído. Os quadrados preenchidos representam as cabeças sensoras, identificadas por seu número.....	60
Figura 18: Diagrama dos pontos de aplicação de carga sobre a placa utilizados para obter a amostragem da resposta do sistema, onde cada círculo representa um ponto de medição.....	62
Figura 19: Resposta dos transdutores à remoção de uma carga de 500 g do centro da placa..	63
Figura 20: Estimativa do mapa do erro Euclidiano, calculada com a interpolação dos dados experimentais para a região central da placa.....	65
Figura 21: Cabeça sensora composta por um anel de ferro e uma FBG. O anel faz com que uma força aplicada perpendicularmente à FBG cause uma deformação no anel, que por sua vez realiza o estiramento uniforme da FBG.....	67
Figura 22: Representação da placa construída (vista do topo). As 9 regiões identificadas, de A até I, foram demarcadas uniformemente no quadrado com 15 cm de lado centralizado na placa. As posições aproximadas das cabeças sensoras e dos anéis de suporte são identificadas pelos círculos e triângulos.....	68
Figura 23: Vista lateral (parcial) da placa de aço com a colagem de cabeças sensoras. Uma carga posicionada na placa de aço resulta na alteração do estiramento prévio na FBG de cada cabeça sensora.....	69
Figura 24: Deslocamento do comprimento de onda de uma cabeça sensora em relação à força aplicada.....	73

Figura 25: Resultados do experimento de repetibilidade.....	73
Figura 26: Resultados do teste da propriedade de aditividade para cada cabeça sensora. Os círculos representam as respostas das cabeças sensoras às forças aplicadas simultaneamente, enquanto que as barras representam as respostas das cabeças sensoras às cargas aplicadas individualmente.....	74
Figura 27: Resultados do teste de homogeneidade para cada cabeça sensora. Forças de 0,05 kgf, 0,1 kgf e 0,2 kgf foram aplicadas, individualmente, no centro da placa.....	75
Figura 28: Resultados do experimento de reconstrução, comparando a qualidade das reconstruções obtidas utilizando o método de regularização de Tikhonov com as obtidas utilizando o método Lasso. Neste experimento foram utilizados 7 cabeças sensoras para 9 regiões.....	76
Figura 29: Exemplos de reconstrução do sinal. (a) Sinal original. (b) Reconstrução com SNR de 17 dB. (c) Reconstrução com SNR de 4 dB.....	78
Figura 30: Esquemático do sistema de medição. À esquerda, visualiza-se a placa com a área de sensoriamento dividida em 16 células identificadas de A até P. As posições das cabeças sensoras são indicadas pelos triângulos numerados de 1 até 8, enquanto que os pentágonos representam os blocos de suporte. À direita, o sistema de interrogação é visualizado com cabos óticos (linhas contínuas) e cabo elétrico (linha tracejada).....	80
Figura 31: Resultados do teste de repetibilidade, mostrando os deslocamentos do comprimento de onda de pico das oito cabeças sensoras, identificadas pelos números de 1 até 8.....	83
Figura 32: Resposta temporal do sistema imediatamente após a remoção da carga. Corresponde aos dados adquiridos durante o teste de repetibilidade, no intervalo de 80 s até 80,7 s.....	84
Figura 33: Resultados do teste de homogeneidade, mostrando a relação entre a massa da carga aplicada e o deslocamento do comprimento de onda de pico para cada cabeça sensora.....	84
Figura 34: Resultados do teste de aditividade, mostrando o deslocamento em comprimento de onda de cargas individuais (barras empilhadas) e das cargas aplicadas simultaneamente (círculos preenchidos).....	85

Figura 35: Exemplo de reconstrução no experimento com 3 cargas aplicadas: (a) configuração real das cargas; (b) sinal reconstruído, com SNR igual a 21,2 dB.....	87
Figura 36: Exemplo de progressão do valor normalizado da função objetivo durante o processo de otimização. Este exemplo corresponde à reconstrução vista na Figura 35.....	88
Figura 37: Perfis de estiramento utilizados nos experimentos E1, E2 e E3.....	91
Figura 38: Resultados das repetições dos experimentos E1, E2 e E3. Cada ponto no gráfico representa o resultado de uma execução.....	95
Figura 39: Esquemático do suporte de tracionamento de fibras: (a) visão superior e (b) visão lateral.....	97
Figura 40: Espectros de reflexão para a FBG na condição inicial e para os deslocamentos de 0,05 mm até 0,2 mm.....	99
Figura 41: Comparação entre o espectro de reflexão experimental e o obtido pela simulação com o perfil de estiramento e parâmetros recuperados.....	99

## LISTA DE TABELAS

Tabela 1: Relação de melhor solução por iteração para o exemplo de minimização visto na Figura 8.....	44
Tabela 2: Resultados experimentais para as três métricas de erro.....	56
Tabela 3: Resposta ao estiramento para as FBGs utilizadas durante os experimentos.....	56
Tabela 4: Resposta das cabeças sensoras utilizadas durante os experimentos.....	63
Tabela 5: Erros médios (e desvios padrão amostrais) obtidos com o conjunto de dados de teste.....	64
Tabela 6: Resultado da reconstrução das 30 configurações para os métodos de Regularização de Tikhonov e Lasso. A posição das cargas é mostrada nas colunas 2,3 e 4, enquanto que o SNR obtido por cada método é visto nas colunas 5 e 6 (melhor resultado grifado).....	77
Tabela 7: Sensibilidade média calculada durante o experimento de reconstrução.....	86
Tabela 8: Taxa de reconstrução (TR) para as três configurações de carga (com 1, 2 e 3 cargas aplicadas simultaneamente).....	86
Tabela 9: SNR média (em dB) e o correspondente desvio padrão para os experimento de reconstrução.....	87
Tabela 10: Resultados dos experimentos de determinação do perfil de estiramento, executados em CPU.....	92
Tabela 11: Resultados dos experimentos de determinação do perfil de estiramento, executados em GPU.....	95
Tabela 12: Comparativo entre o perfil de estiramento obtido (estiramento em cada uma das 10 seções) e o estiramento esperado para a região solta da FBG, para cada deslocamento da plataforma móvel.....	100

## LISTA DE ALGORITMOS

Algoritmo 1: Etapas do algoritmo s10.....	39
Algoritmo 2: Etapas do método OMP.....	39
Algoritmo 3: Etapas do método DE/rand/1/bin.....	43

## LISTA DE SIGLAS

CCD	<i>Charge-Coupled Device</i> – Dispositivo de carga acoplada
CMOS	<i>Complementary Metal-Oxide Semiconductor</i> – semicondutor metal-óxido complementar
CS	<i>Compressive Sensing</i> – Sensoriamento compressivo
CUDA	<i>Compute Unified Device Architecture</i>
DE	<i>Differential Evolution</i> – Evolução diferencial
EC	<i>Evolutionary Computation</i> – Computação evolutiva
FBG	<i>Fiber Bragg Grating</i> – Rede de Bragg em fibra ótica
FFP	<i>Fiber Fabry-Perot</i> – <i>Fabry-Perot</i> em fibra ótica
FWHM	<i>Full Width at Half Maximum</i> – Largura à meia altura
GPU	<i>Graphics Processing Unit</i> – Unidade de processamento gráfico
GA	<i>Genetic Algorithm</i> – Algoritmo genético
LASSO <sup>1</sup>	<i>Least Absolute Shrinkage and Selection Operator</i>
LED	<i>Light Emitting Diode</i> – Diodo Emissor de Luz
MAE	<i>Mean Absolute Error</i> – Erro médio absoluto
MLP	<i>MultiLayer Perceptron</i> – <i>Perceptron</i> de múltiplas camadas
MSE	<i>Mean Squared Error</i> – Erro quadrático médio
NBN	<i>Neuron by Neuron</i> – Neurônio a neurônio (algoritmo de treinamento)
OMP	<i>Orthogonal Matching Pursuit</i>
RBF	<i>Radial Basis Function</i> – Função de base radial
RNA	Rede Neural Artificial
SDE	<i>Sparse Differential Evolution</i> – Evolução diferencial esparsa
SNR	<i>Signal-to-Noise Ratio</i> – Relação sinal-ruído
SVR	<i>Support Vector Regression</i> – Máquinas de vetor de suporte para regressão

---

<sup>1</sup>Referido como Lasso no texto para manter o nome dado pelo seu autor.

## RESUMO

NEGRI, Lucas Hermann. Inteligência computacional no sensoriamento a fibra ótica. 2017. Tese de doutorado (Doutorado em Engenharia Elétrica e Informática Industrial) – Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial, Universidade Tecnológica Federal do Paraná. Curitiba, 2017.

Esta tese apresenta aplicações de inteligência computacional para o aprimoramento de sensoriamento ótico realizado com sensores em fibra ótica. Para tanto, redes neurais artificiais (*perceptron* de múltiplas camadas), máquinas de vetor de suporte para regressão, evolução diferencial e métodos de sensoriamento compressivo são empregados em conjunto com transdutores de redes de Bragg em fibras óticas. As redes neurais artificiais, máquinas de vetor de suporte para regressão e redes de Bragg são empregadas na localização de uma carga aplicada sobre uma placa de acrílico. É apresentado um novo método utilizando evolução diferencial para a solução do problema do espalhamento inverso em redes de Bragg em fibra ótica, propondo o uso de restrições para solucioná-lo na ausência de informação de fase do sinal refletido. Um método para a detecção de múltiplas cargas posicionadas acima de uma placa de metal é proposto. Neste método, a placa de metal é suportada por anéis de ferro contendo redes de Bragg em fibra ótica e a detecção das cargas é realizada com o uso de métodos de sensoriamento compressivo para a solução do problema inverso subdeterminado resultante. A troca dos anéis de ferro por blocos de silicone e um novo método baseado em sensoriamento compressivo e evolução diferencial são propostos. Os resultados experimentais mostram que os métodos computacionais propostos auxiliam o sensoriamento e podem permitir uma melhoria da resolução espacial do sistema sem a necessidade do aumento do número de elementos transdutores.

**Palavras-chave:** Sensor em Fibra Ótica. Inteligência Computacional. Sensoriamento Compressivo. Redes de Bragg em Fibra Ótica. Evolução Diferencial. Redes Neurais Artificiais. Regressão. Otimização.

## ***ABSTRACT***

NEGRI, Lucas Hermann. Computational intelligence applied to optical fiber sensing. 2017. Tese de doutorado (Doutorado em Engenharia Elétrica e Informática Industrial) – Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial, Universidade Tecnológica Federal do Paraná. Curitiba, 2017.

This thesis presents new optical fiber sensing methodologies employing computational intelligence approaches seeking for the improvement of the sensing performance. Particularly, artificial neural networks, support vector regression, differential evolution and compressive sensing methods were employed with fiber Bragg grating transducers. Artificial neural networks (multilayer perceptron) and fiber Bragg gratings were used to determine the location of a load applied to a polymethyl methacrylate sheet. A new method based on the application of differential evolution is proposed to solve the inverse scattering problem in fiber Bragg gratings, where constraints are imposed to solve the problem without the need of phase information. A method for detecting multiple loads on a metal sheet is also proposed. In this method, the metal sheet is supported by iron rings containing fiber Bragg gratings, and compressive sensing methods are employed to solve the resulting underdetermined inverse problem. Further developments of the method replaced the iron rings by silicon blocks and employed a new reconstruction method based on compressive sensing and differential evolution. Experimental results show that the proposed computational methods improve the optical fiber sensing and lead to an enhancement of the spatial resolution without increasing the number of transducers.

**Keywords:** Fiber Optical Sensor. Computational Intelligence. Compressive Sensing. Fiber Bragg Grating. Differential Evolution. Artificial Neural Network. Regression. Optimization.

## CAPÍTULO 1

### INTRODUÇÃO

#### 1.1 MOTIVAÇÃO

Os sensores baseados em fibra ótica são amplamente conhecidos e utilizados em laboratório e têm experimentado um crescente interesse comercial e industrial (MÉNDEZ, 2007; BOLOGNINI; HARTOG, 2013). As diversas configurações de sensores baseados em fibras óticas compartilham as propriedades de imunidade a campos eletromagnéticos externos, a facilidade de transmissão de dados em altas taxas e a capacidade de multiplexação intrínseca por comprimento de onda (dependendo do tipo de sensor). O sensoriamento se baseia na modulação das propriedades das ondas eletromagnéticas guiadas, sendo mais comum a modulação do comprimento de onda ou diretamente da intensidade do sinal. Entre as aplicações de sensores a fibra ótica, encontram-se o sensoriamento de temperatura, deformação mecânica e a medição de índice de refração (KERSEY et al., 1997; LIANG et al., 2005).

Nesta tese utilizam-se principalmente os sensores a rede de Bragg em fibra ótica (FBG), que são estruturas gravadas no núcleo de fibras óticas. Perturbações externas na estrutura de uma FBG fazem com que a banda de luz refletida seja alterada, possibilitando o sensoriamento. Apesar de serem usualmente tratadas como sensores pontuais, sabe-se que alterações específicas ao longo da estrutura da FBG podem ser exploradas para o desenvolvimento de sensores distribuídos e *quasi*-distribuídos. O uso de FBGs no sensoriamento distribuído e *quasi*-distribuído já foi tratado na literatura (COWIE et al., 2007; RAPP et al., 2009; HEO et al., 2009; KANELLOS et al., 2010); porém, a possibilidade de avanços ainda existe a partir de novas técnicas para o processamento dos dados. Esta tese é motivada pela oportunidade da aplicação de técnicas de inteligência computacional para o aperfeiçoamento do uso de FBGs no sensoriamento de forças e deformações mecânicas.

No contexto desta tese, define-se como inteligência computacional um conjunto de técnicas computacionais que trabalham com dados de baixo nível, exibindo as características de tolerância a erro e adaptabilidade computacional (KONAR, 2005), utilizadas aqui para as tarefas de aprendizado a partir de observações experimentais e de otimização sem o uso de informação de gradiente. Os trabalhos realizados nesta tese utilizam principalmente redes neurais artificiais (RNAs) e evolução diferencial (DE, do inglês *differential evolution*), porém outros métodos, como máquinas de vetor de suporte para regressão (SVR, do inglês *support vector regression*), também são avaliados.

O uso de inteligência computacional para processamento de dados permite que o sistema considere a presença de ruído nos sinais, bem como as não-linearidades no sistema de medição, que se fazem presentes nos arranjos experimentais e aplicações reais. Características que não seriam desejadas em sistemas comuns podem ser utilizadas como algo favorável com o uso de inteligência computacional (COWIE et al., 2007). Um exemplo está em um sistema cuja resposta dos transdutores é acoplada, dificultando a modelagem do sistema. Como demonstrado nesta tese, técnicas de inteligência computacional podem ser utilizadas para aprender o modelo a partir dos dados experimentais, ou ajustar os parâmetros de um modelo complexo, onde técnicas de otimização tradicionais não são adequadas.

Esta tese propõe o uso de métodos baseados em inteligência computacional, especificamente redes neurais artificiais e evolução diferencial aliada à teoria de sensoriamento compressivo, para a aplicação de FBGs como transdutores para o sensoriamento distribuído e *quasi*-distribuído da deformação em superfícies.

A nomenclatura utilizada nesta tese segue as recomendações do vocabulário internacional de metrologia (CLIFFORD, 1985) versão 200:2012.

## 1.2 ESTADO DA ARTE

Nesta seção é apresentado o estado da arte relacionado ao uso de FBGs no sensoriamento táctil distribuído e na solução do problema do espalhamento inverso em FBGs. Os mesmos tópicos são abordados pelas metodologias propostas nesta tese, contidas no Capítulo 3.

### 1.2.1 Uso de FBGs no sensoriamento táctil distribuído

Uma estratégia comum para o desenvolvimento de sistemas tácteis consiste no uso de um vetor de sensores, onde cada sensor é utilizado para monitorar uma posição discreta da área desejada, conforme publicado por Heo et al. (2006) e em maior escala, no sistema proposto por Childers et al. (2001). Esta estratégia de monitoramento ponto a ponto é capaz de realizar uma discriminação fina, mas também é custosa para aplicações em superfícies extensas devido ao grande número de sensores necessários. Nesta mesma estratégia, também é desejável que a resposta de cada sensor seja restrita à uma área limitada, com pouco ou nenhum cruzamento de sinal entre sensores vizinhos.

O sensoriamento distribuído é uma alternativa ao sensoriamento ponto a ponto. No sensoriamento táctil distribuído, é utilizado um elemento mecânico contínuo, como uma superfície que apresenta deformação elástica na presença de uma carga. Esta deformação elástica é amostrada por um conjunto de sensores posicionados na área de sensoriamento, cujos resultados são combinados para estimar as propriedades da carga aplicada. Esta ideia é apresentada por Davis et al. (1994) e por Song et al. (2015), onde sugere-se o uso de FBGs para a localização de uma carga aplicada em uma placa de alumínio, apesar de nenhum método inverso (detecção da posição de uma ou mais cargas a partir da resposta dos sensores) ser proposto. Outros exemplos de sistemas tácteis distribuídos se encontram na detecção da disposição de cargas em configurações 1D (cantiléver) e 2D (placa) (COWIE et al., 2007), para a determinação da deformação de uma placa (WANG et al., 2007) e no monitoramento da posição de uma carga móvel em uma placa (ELLIOTT et al., 2007)

A resposta acoplada dos sensores no sensoriamento distribuído é um fator necessário para o seu funcionamento, sendo que é necessário utilizar métodos computacionais para tratar os dados obtidos de forma a detectar a posição de uma ou mais cargas na superfície monitorada. Isto difere do método ponto a ponto, onde a saída de cada sensor e a carga na respectiva área do sensor são diretamente relacionadas. Para casos específicos, pode-se resolver analiticamente o problema inverso a partir das equações que governam a deformação mecânica na superfície monitorada (WANG et al., 2007). Um método mais geral consiste no uso de redes neurais artificiais (RNAs), que são ferramentas comumente utilizadas para o aprendizado de uma relação aproximada entre a saída de sensores e a propriedade que se quer medir (problema de aproximação de funções), como no exemplo da detecção da posição e

formato de uma carga (COWIE et al., 2007) e na detecção do movimento de uma carga em uma superfície (ELLIOTT et al., 2007). Outro exemplo de aplicação está no uso de FBGs em conjunto com RNAs para a localização de impactos em superfícies (RIBEIRO et al., 2013).

O sensoriamento da distribuição de forças aplicadas em estruturas é de interesse industrial e possui aplicações em diversas áreas. Entre as aplicações relatadas na literatura, pode-se citar a análise da integridade estrutural em pontes (CHAN et al., 2006; BAO et al., 2014), o sensoriamento de deformações em asas de aeronaves (CHILDERS et al., 2001) e o sensoriamento tátil (HO et al., 2008).

### 1.2.2 Espalhamento inverso em FBGs

Uma FBG sujeita a um estiramento, cujo perfil não é uniforme, apresenta alterações na forma do seu espectro de reflexão. Um método eficiente que resolve o problema do espalhamento inverso (SKAAR; FECED, 2002) em FBGs possibilitaria o uso desta como sensor distribuído em campo e em sistemas embarcados. Apesar do problema do espalhamento inverso já ter sido tratado na literatura, uma solução eficiente ainda é um problema a ser explorado, pois os métodos existentes trabalham com restrições específicas. Dentre os requisitos dos métodos atuais, pode-se citar a necessidade de trabalhar com FBGs com baixa refletividade (OHN et al., 1997), a obrigatoriedade do uso da informação de fase do espectro (MURIEL et al., 1998; SKAAR; FECED, 2002) ou a aplicação somente a espectros com perfil monotônico (LEBLANC et al., 1996). Cheng e Lo (2004) propuseram o uso de um algoritmo genético (GA) para a determinação do perfil do estiramento aplicado a uma FBG. No entanto, foi requerido o uso de duas FBGs simultaneamente para superar o problema de ambiguidade na determinação do espectro, além de requerer um tempo de processamento da ordem de horas em processadores de propósito geral, sem o uso de processamento paralelo.

## 1.3 OBJETIVOS

Esta seção apresenta os objetivos (geral e específicos) da tese.

### 1.3.1 Objetivo geral

Investigar diferentes métodos de inteligência computacional com o objetivo de simplificar e aperfeiçoar o uso de dados resultantes de sistemas de sensoriamento de deformação mecânica baseados em fibras óticas.

### 1.3.2 Objetivos específicos

Os objetivos específicos são os seguintes:

- Gravar FBGs em diferentes comprimentos de onda e as encapsular para a medição de deformação mecânica;
- Montar diferentes arranjos de sensores em fibra ótica para medição de deformação mecânica;
- Reduzir o número de sensores necessários para o mapeamento de deformações mecânicas em superfícies, pelo uso de métodos de inteligência computacional;
- Estudar e aplicar a teoria de sensoriamento compressivo para redução do número necessário de sensores para aplicação de detecção de cargas e deformação em superfícies;
- Desenvolver uma técnica, baseada na aplicação de inteligência computacional, para analisar os parâmetros estruturais (perfil de modulação do índice de refração) de uma FBG;
- Empregar FBGs como sensores *quasi*-distribuído e distribuído;
- Construir um protótipo para o mapeamento de forças aplicadas em superfícies utilizando uma ou mais técnicas desenvolvidas.

### 1.3.3 Estrutura da tese

Esta tese está dividida em seis capítulos. O primeiro capítulo introduziu o tema da tese, apresentando o seu objetivo principal, seus objetivos específicos, sua organização e motivação.

O segundo capítulo apresenta uma revisão da teoria sobre FBGs, incluindo o princípio de funcionamento e a simulação do espectro de reflexão pelo método das matrizes de transferência. O segundo capítulo também apresenta as teorias de RNAs e de sensoriamento compressivo (CS, do inglês *compressive sensing*) e as técnicas computacionais que são utilizadas nas metodologias propostas no terceiro capítulo.

As contribuições desta tese (os métodos propostos bem como as metodologias de avaliação e os resultados) são apresentadas no terceiro, quarto e quinto capítulos. O primeiro método (Capítulo 3) trata da estimação da posição de cargas em superfícies, por meio de FBGs, RNAs e SVRs, o segundo método (Capítulo 4) consiste no uso de CS para o desenvolvimento de um sistema de mapeamento de forças com resolução espacial otimizada, enquanto que o terceiro método (Capítulo 5) propõe o uso de evolução diferencial para a solução do problema do espalhamento inverso em FBGs.

As conclusões são apresentadas no sexto capítulo, que sumariza os resultados dos métodos propostos e identifica propostas futuras de trabalho.

## **CAPÍTULO 2**

### **FUNDAMENTAÇÃO TEÓRICA**

Neste capítulo são apresentados os conhecimentos fundamentais utilizados no desenvolvimento presente nos Capítulos 3, 4 e 5.

#### **2.1 REDES NEURAIS ARTIFICIAIS**

As redes neurais artificiais (RNAs) são modelos computacionais caracterizados pelo uso de unidades simples de processamento de forma interconectada. Estas unidades de processamento, denominadas neurônios, têm uma capacidade limitada de processamento quando consideradas individualmente: o poder computacional de uma RNA surge da interconexão dos neurônios e do seu agrupamento em camadas.

O modelo conexionista das RNAs foi inspirado no funcionamento de redes neurais biológicas, que são compostas por neurônios massivamente conectados (HAYKIN, 2001). Apesar disto, as RNAs utilizadas na área de aprendizado de máquina e processamento de sinais seguem uma abordagem computacional, se afastando do modelo biológico.

As RNAs são utilizadas em problemas de classificação, de regressão e de agrupamento, entre outros empregos, e podem trabalhar com diferentes tipos de conjuntos de dados. Além disto, diferentes organizações de neurônios (topologias) e algoritmos de treinamento são utilizados dependendo da aplicação. Esta seção apresenta a fundamentação teórica dos modelos e métodos de treinamento utilizados pelo presente trabalho, focando nas aplicações de classificação e regressão com treinamento supervisionado.

### 2.1.1 Princípio de funcionamento

O neurônio é a menor unidade de processamento de uma RNA, sendo que o funcionamento de uma RNA se baseia na propagação dos sinais em uma rede de neurônios interconectados. Um neurônio é composto por três elementos principais (SILVA et al., 2010):

- O conjunto de sinais de entrada e os seus respectivos pesos sinápticos;
- O acumulador das entradas ponderadas por seus pesos;
- A função de ativação que recebe a saída do acumulador e resulta na saída do neurônio.

A Figura 1 mostra o esquemático de um neurônio e seus componentes, onde  $x_1$  até  $x_m$  representam os  $m$  sinais de entrada, ponderados pelos seus respectivos pesos sinápticos  $w_1$  até  $w_m$ , sendo  $v$  a saída do acumulador e  $y$  a saída da função de ativação  $\phi$ .

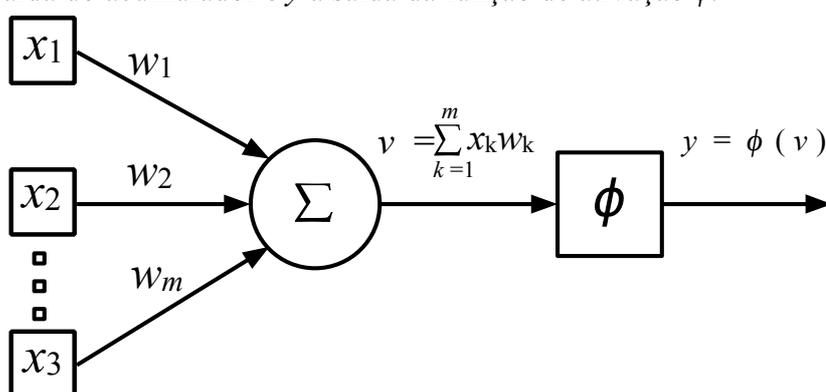


Figura 1: Modelo esquemático de um neurônio e seus componentes.

O cálculo realizado no neurônio é descrito pela Equação 1, tal que:

$$y = \phi \left( \sum_{k=1}^m x_k w_k \right). \quad (1)$$

Uma entrada denominada polarização, cujo valor é fixo e arbitrário (como o valor -1) é comumente adicionada a cada neurônio para possibilitar o deslocamento da entrada da função de ativação, de acordo com o seu peso sináptico.

No contexto dos problemas de classificação, tem-se que um neurônio por si só é um classificador linear, isto é trata somente de problemas que são linearmente separáveis (HAYKIN, 2001).

Com a adição de novas camadas de neurônios e o uso de funções de ativações adequadas, uma RNA pode ser treinada para problemas que não são linearmente separáveis (HAYKIN, 2001). A forma com que as camadas de neurônios e as conexões são realizadas (topologia), além da escolha da função de ativação, determina o poder computacional da RNA. Uma topologia comumente utilizada, é a denominada *perceptron* de múltiplas camadas (MLP, do inglês *multilayer perceptron*). Uma rede MLP é composta por um conjunto de entradas (camada de entrada), um conjunto de neurônios que formam uma ou mais camadas intermediárias e um conjunto de neurônios que compõem a camada de saída. Em uma MLP, os neurônios ou entradas de uma camada se conectam somente com os neurônios da camada imediatamente adiante (com exceção da entrada de polarização). Uma rede MLP é um aproximador universal, sendo capaz de aproximar funções com precisão arbitrária utilizando um número finito de neurônios em uma única camada escondida (HORNIK et al., 1989; HORNIK, 1991).

Um exemplo de rede MLP com uma camada intermediária pode ser observado na Figura 2.

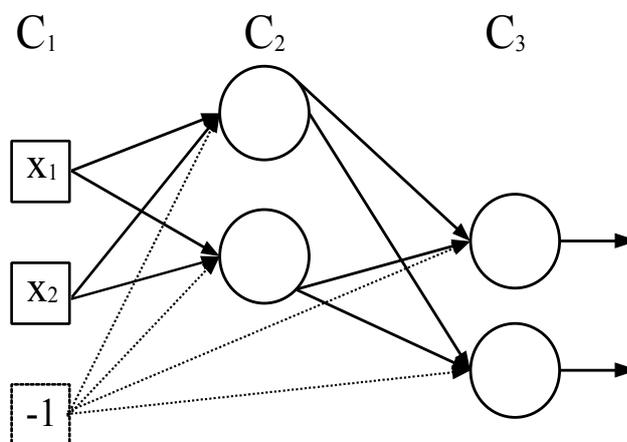


Figura 2: Exemplo de MLP cuja camada de entrada  $C_1$ , contém as entradas  $x_1$  e  $x_2$ , além da entrada de polarização com valor de -1, dois neurônios na camada escondida ( $C_2$ ) e dois neurônios na camada de saída ( $C_3$ ). As setas indicam as conexões sinápticas entre os neurônios, cada uma possuindo um peso sináptico.

A propagação de sinais em uma RNA alimentada adiante é realizada sequencialmente, iniciando da camada de entrada até a camada de saída. A saída de um neurônio pode ser utilizada como entrada para os neurônios da camada seguinte, logo a necessidade da propagação em camadas. Um exemplo da etapa de propagação de sinais pode ser visto na

Figura 3, onde todos os neurônios utilizaram uma função de ativação linear ( $\phi(x)=2x$ ), resultando na seguinte sequência de passos:

1. Configuração dos sinais na camada de entrada: valores 2,0 e 1,0);
2. Cálculo da saída dos neurônios na camada escondida:  $\phi(2,0 \times 0,25 + 1,0 \times 2,0) = 5,0$  e  $\phi(2,0 \times (-0,5) + 1,0 \times (-0,2)) = -2,4$  ;
3. Cálculo da saída no neurônio da camada de saída:  $\phi(5,0 \times 1,0 + (-2,4) \times 2,0) = 0,4$  .

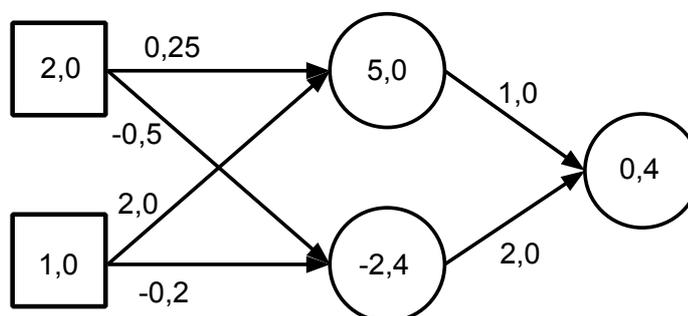


Figura 3: Exemplo de propagação dos sinais de entrada 2,0 e 1,0 em uma MLP com duas entradas, uma camada escondida com dois neurônios e camada de saída com um neurônio (sinal de saída igual a 0,4).

O uso de RNAs usualmente implica na necessidade de codificar os dados de entrada e saída para números do conjunto dos reais na faixa de trabalho das funções de ativação utilizadas, por meio da troca de escala dos dados. Assim, dados categóricos devem ser convertidos em valores numéricos.

O número de entradas da rede (ao ignorar a entrada de polarização) é igual ao número de variáveis de entrada presentes nos dados, enquanto que o número de neurônios de saída é escolhido de acordo com a aplicação. Para regressão numérica, tem-se um neurônio de saída para cada variável a ser estimado pela rede. Em aplicações de classificação, pode-se utilizar diferentes estratégias, sendo uma possibilidade o emprego de um neurônio para cada possível classe, onde o neurônio que possuir a maior saída após a etapa de propagação de sinais determina a classificação da rede (codificação *one-hot*) (SILVA et al., 2010). Enquanto isto, a determinação do número de camadas escondidas e do número de neurônios em cada uma delas depende da aplicação, podendo ser determinadas experimentalmente.

Diferentes funções de ativação podem ser utilizadas em uma rede MLP. Entre as possíveis escolhas encontram-se a função linear, a sigmoide e a tangente hiperbólica. A função linear está descrita na Equação 2, onde  $x$  é a entrada da função. A função sigmoide é representada na Equação 3, e a tangente hiperbólica na Equação 4.

$$\phi(x) = x \quad (2)$$

$$\phi(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

$$\phi(x) = \tanh(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (4)$$

A função de ativação linear não possui um intervalo de trabalho limitado, a função sigmoide tem sua saída limitada no intervalo  $[0, 1]$  e a tangente hiperbólica no intervalo  $[-1, 1]$ .

O poder computacional de uma RNA depende da escolha de funções de ativação adequadas. Em uma RNA que utilize somente funções de ativação lineares, a adição de camadas não aumenta o seu poder computacional e a mesma fica restrita a problemas linearmente separáveis (HAYKIN, 2001), enquanto que uma RNA com uma topologia adequada (com ao menos uma camada escondida com um número finito de neurônios) e utilizando como função de ativação a sigmoide consegue aproximar qualquer função contínua para valores reais finitos (HORNIK et al., 1989).

### 2.1.2 Métodos de treinamento

O processo de treinamento de uma RNA é realizado pelo ajuste dos pesos sinápticos dos neurônios, utilizando algoritmos de treinamento adequados. O treinamento de uma RNA pode ser realizado de forma supervisionada, utilizando um conjunto de dados de entrada e suas respectivas saídas. No treinamento supervisionado, a RNA é treinada de forma a aprender a relação entre os dados de entrada e saída, tornando-a capaz de replicar a saída para as entradas apresentadas. É desejável que a RNA apresente a característica de generalização, isto é, que possa operar com entradas que não foram apresentadas durante o processo de treinamento.

Além do treinamento supervisionado, também pode-se citar o treinamento não-supervisionado e métodos híbridos. Um exemplo está no treinamento de *auto-encoders* para a extração de características (*features*) a partir dos dados de entrada, técnica comumente utilizada para o treinamento de RNAs com um número elevado de camadas escondidas (*deep learning*) (MOHIMANI et al., 2009; SCHMIDHUBER, 2015; LIU et al., 2017) e para o treinamento de RNAs quando somente uma fração dos dados tem sua saída identificada.

O processo de treinamento em uma RNA pode ser realizado utilizando diferentes algoritmos de otimização, incluindo meta-heurísticas como algoritmos genéticos e otimização por enxame de partículas. No entanto, no treinamento supervisionado é mais comum utilizar métodos baseados em máximo declive (*steepest descent*). O treinamento por máximo declive, adaptado para MLPs com camadas escondidas recebeu o nome de algoritmo de retropropagação do erro (*backpropagation*), e serve como base para diferentes de métodos de treinamento, como o *Resilient Backpropagation* (RIEDMILLER; BRAUN, 1993) e o uso dos métodos tradicionais de otimização como Levenberg-Marquardt e *Quasi-Newton*.

O treinamento por retropropagação do erro ocorre por uma sequência de *épocas*. Uma *época* corresponde a apresentação do todo o conjunto de dados de treinamento, e é descrita pelas seguintes etapas (HAYKIN, 2001):

- Apresentação dos dados de entrada para a RNA, que realiza a propagação do sinal até o cálculo dos sinais de saída da rede;
- Cálculo do erro, dado pela diferença entre as saídas da rede e as saídas esperadas;
- Cálculo do gradiente do erro, calculado a partir do erro na camada de saída e propagado para as camadas anteriores utilizando a regra da cadeia. Para este cálculo, é necessário que a função de ativação seja diferenciável;
- Ajuste dos pesos sinápticos na direção indicada pelo gradiente do erro, buscando a redução do erro.

Diferentes critérios de parada podem ser utilizados para determinar quando o treinamento deve encerrar. Exemplos incluem treinar a RNA por um número fixo de épocas ou treinar até que alguma métrica de erro alcance um valor predeterminado. A escolha de um critério de parada adequado é importante, pois o treinamento excessivo pode levar ao problema de sobre-treinamento (*overfitting*), onde pode-se perder a capacidade de

generalização da rede, enquanto que o treinamento insuficiente pode fazer com que a rede não aprenda a relação entre os dados de entrada e saída. Além da especificação do critério de parada, o sobre-treinamento também pode ser controlado por meio da estratégia de *dropout* (SRIVASTAVA et al., 2014), por métodos de regularização como a regularização de Tikhonov ou decaimento de pesos (*weight decay*), e pela adição de ruído durante o treinamento (BISHOP, 1995).

O treinamento pode ser realizado em passos únicos (*on-line*) ou em batelada (*batch*). No treinamento *on-line*, o ajuste dos pesos sinápticos é realizado para cada padrão apresentado para a RNA, enquanto que no treinamento *batch* o ajuste dos pesos é realizado de uma vez só no final de cada época.

Em detalhes, o treinamento de um MLP com camadas escondidas é realizado pela seguinte sequência de etapas, tendo como objetivo minimizar o quadrado do erro em cada neurônio de saída (HAYKIN, 2001; SILVA et al., 2010):

1. Cálculo do erro  $e_k$  do  $k$ -ésimo neurônio da camada de saída, correspondente a diferença entre a saída esperada  $d_k$  e a saída obtida  $y_k$ , como descrito na Equação 5:

$$e_k = d_k - y_k . \quad (5)$$

2. Cálculo do  $\delta_k$  para a última camada, dado pela Equação 6:

$$\delta_k = e_k g'(y_k) , \quad (6)$$

onde  $g'$  é a derivada da função de ativação. O valor  $\delta_k$  é utilizado para calcular o ajuste dos pesos sinápticos da camada atual e para determinar cada valor  $\delta_j$ , referente ao  $j$ -ésimo neurônio da camada precedente.

3. Cálculo do  $\delta_j$  para cada camada precedente (camada a camada), realizando a retropropagação do error pela regra delta generalizada, como descrito na Equação 7:

$$\delta_j = g'(y_j) \sum_{k=1}^K \delta_k w_{jk} , \quad (7)$$

onde  $K$  é o número de neurônios na camada atual.

4. Ajuste do peso sináptico que conecta o neurônio  $j$  da camada anterior para o neurônio  $k$  da camada atual utilizando o valor  $\Delta w_{jk}$ , dado pela Equação 8:

$$\Delta w_{jk} = \eta \delta_j y_k, \quad (8)$$

onde  $\eta$  é a taxa de aprendizado.

As etapas apresentadas do método de retropropagação de erro tem como objetivo minimizar o erro quadrático em cada neurônio na camada de saída ( $e_k^2$ ), tendo como consequência a minimização do erro quadrático médio (MSE, do inglês *mean squared error*) dado pela Equação 9, sendo  $q$  o número de neurônios na camada de saída:

$$MSE = \frac{1}{q} \sum_{k=1}^q e_k^2. \quad (9)$$

A taxa de aprendizado  $\eta$  tem um papel importante na convergência durante o treinamento por retropropagação de erro. Se o valor de  $\eta$  for elevado, o treinamento pode ficar instável e não convergir, enquanto que um valor reduzido pode fazer com que muitas épocas sejam necessárias para a convergência. Uma alternativa está em variar automaticamente o valor de  $\eta$  durante o treinamento, como é realizado por métodos mais avançados como o iRPROP. O aumento do número de camadas escondidas também pode fazer com que o treinamento utilize um número elevado de épocas para convergir, pois o gradiente do erro tende a diminuir quando é retropropagado de uma camada para a anterior, problema que motivou o desenvolvimento de algoritmos como o iRPROP (IGEL; HUSKEN, 2000) e *Neuron by Neuron* (NBN) (WILAMOWSKI; YU, 2010), além dos métodos para o treinamento de redes neurais profundas (HINTON et al., 2006).

Os valores iniciais dos pesos sinápticos são usualmente iniciados como valores pseudo-aleatórios com valores pequenos em comparação a faixa de operação das funções de ativação. Como o treinamento de uma RNA com funções de ativação não-lineares não é convexo, o resultado do treinamento depende da inicialização dos pesos sinápticos. Em estudos recentes (GLOROT; BENGIO, 2010), identificou-se que a escolha dos pesos sinápticos tem importante influência no processo de treinamento, sendo que a inicialização puramente aleatória pode tornar o treinamento lento para redes com múltiplas camadas escondidas e utilizando funções de ativação sigmoidais. Neste caso, o treinamento pode ser beneficiado por métodos alternativos de inicialização.

## 2.2 MÁQUINAS DE VETOR DE SUPORTE PARA REGRESSÃO

Uma SVR é um modelo computacional que, associado à um algoritmo de treinamento, permite encontrar uma função que aproxime um determinado conjunto de dados (VAPNIK et al., 1997). As máquinas de vetor de suporte estão baseadas na teoria de aprendizagem estatística (teoria de Vapnik–Chervonenkis) (VAPNIK, 1999), possuindo a propriedade de boa generalização para dados que não estão presentes no processo de treinamento.

Considera-se um conjunto de dados  $\{(x_1, y_1), (x_2, y_2), \dots, (x_i, y_i)\}$ , onde  $x_i$  é um vetor de entrada e  $y_i$  é seu respectivo valor alvo. O objetivo de uma SVR está em encontrar a função  $f(x)$  que aproxime todos os valores alvo com uma diferença de no máximo  $\epsilon$  e que seja a mais simples dentre todas as funções possíveis (VAPNIK et al., 1997). A primeira parte deste objetivo pode ser descrita pela satisfação da Equação 10 para todos os pares  $(x_i, y_i)$ :

$$|f(x_i) - y_i| < \epsilon, \quad (10)$$

onde, assumindo um modelo linear,

$$f(x) = \langle w, x \rangle + b, \quad (11)$$

com  $\langle w, x \rangle$  denotando o produto escalar entre  $w$  (vetor a ser determinado) e  $x$  (padrão de entrada) e  $b$  sendo um parâmetro de polarização. Ao utilizar a norma Euclidiana de  $w$  como critério de simplicidade da função  $f(x)$ , encontra-se o problema de otimização descrito na Equação 12:

$$\begin{array}{ll} \text{minimizar} & \frac{1}{2} \|w\|^2 \\ \text{sujeito a} & \begin{cases} y_i - \langle w, x_i \rangle - b \leq \epsilon \\ \langle w, x_i \rangle + b - y_i \leq \epsilon \end{cases} \end{array} \quad (12)$$

O problema descrito na Equação 12 assume que existe uma solução viável. No entanto, podem existir casos onde não é possível encontrar tal solução. Nestes casos, uma solução pode ser determinada com a adição das variáveis de folga  $\xi_i, \epsilon \xi_i^*$  (SMOLA; SCHÖLKOPF, 2004):

$$\begin{aligned}
& \text{minimizar} && \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \\
& \text{sujeito a} && \begin{cases} y_i - \langle w, x_i \rangle - b \leq \epsilon + \xi_i, \\ \langle w, x_i \rangle + b - y_i \leq \epsilon + \xi_i^*, \\ \xi_i, \xi_i^* \geq 0 \end{cases}
\end{aligned} \tag{13}$$

onde  $C$  é uma constante que determina o equilíbrio entre a simplicidade da solução e a qualidade de aproximação da função ao conjunto de dados de treinamento.

O problema de otimização descrito na Figura 13 pode ser descrito na sua forma dual, por meio do uso de multiplicadores Lagrangianos  $(\alpha_i, \alpha_i^*)$ , resultando em uma nova descrição da função  $f(x)$  pela Equação 14 (SMOLA; SCHÖLKOPF, 2004):

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) \langle x_i, x \rangle + b. \tag{14}$$

Os multiplicadores  $\alpha_i, \alpha_i^*$  serão nulos para os casos  $(x_i, y_i)$  onde a Equação 10 é satisfeita. Tem-se assim que a expansão de  $f(x)$  em termos de  $x_i$  (Equação 14) é esparsa, sendo os vetores  $x_i$  efetivamente utilizados em  $f(x)$  denominados vetores de suporte (SMOLA; SCHÖLKOPF, 2004).

A formulação dual é vantajosa por resultar em um problema de programação quadrática com um único ótimo global, além de permitir a mudança da dimensionalidade no espaço de características do problema e a aproximação de funções não-lineares por meio da troca do produto escalar  $\langle x_i, x \rangle$  (Equação 14) por funções específicas, denominadas de *kernel* (SMOLA; SCHÖLKOPF, 2004). Um *kernel* comumente utilizado é o *kernel* RBF (função de base radial, do inglês *radial basis function*), apresentado na Equação 15:

$$\exp(-\gamma |x_1 - x_2|^2), \tag{15}$$

onde  $x_1$  e  $x_2$  são os vetores envolvidos na operação e  $\gamma$  é um coeficiente, maior do que zero, que configura a largura da função de base radial, ditando assim a influência de cada caso no treinamento.

## 2.3 SENSORIAMENTO COMPRESSIVO

O sensoriamento compressivo (CS) é um novo paradigma de sensoriamento que busca a redução do número de amostras necessárias para a recuperação de sinais, tendo como base a informação de que o sinal que se quer recuperar é esparso em alguma base conhecida. Entre as aplicações de CS, cita-se com destaque o seu uso na obtenção de imagens por ressonância magnética (LUSTIG et al., 2007) e na câmera de um pixel (DUARTE et al., 2008).

### 2.3.1 Princípio de funcionamento

Consideremos o problema de determinar os  $n$  valores do vetor  $x$  no sistema linear mostrado na Equação 16:

$$Ax = y, \quad (16)$$

onde  $y$  é o vetor com  $m$  observações e  $A$  é a matriz ( $m \times n$ ) de sensoriamento. Se  $m=n$  e a matriz  $A$  for linearmente independente, então o vetor  $x$  pode ser diretamente recuperado pela solução do sistema linear. No entanto, caso o número de observações  $m$  seja menor do que o número de valores  $n$ , o sistema resultante é subdeterminado e não possui uma solução única. Uma forma de obter uma solução única está em buscar a solução que tenha a menor norma Euclidiana (norma  $l_2$ ), solução que pode ser obtida por meio da pseudo-inversa de Moore-Penrose, como descrito na Equação 17:

$$x = A^+ y = A^T (A A^T)^{-1} y. \quad (17)$$

Apesar de ter uma conveniente solução fechada, a recuperação de  $x$  pela Equação 17 pode não ter resultados satisfatórios. Em aplicações onde se sabe que o vetor  $x$  é esparso (a maior parte dos elementos é igual a 0), melhores resultados podem ser obtidos aproveitando esta informação de esparsidade. Ao invés de determinar a solução que minimiza a norma  $l_2$ , pode-se determinar a que minimiza a norma  $l_0$ , resolvendo o problema de minimização dado na Equação 18:

$$\begin{array}{ll} \underset{x}{\text{minimizar}} & \|x\|_{l_0} \\ \text{sujeito a} & Ax = y \end{array}, \quad (18)$$

onde a norma  $l_p$  do vetor  $x$  é dada por  $\|x\|_{l_p} = \sum_{i=1}^n |x_i|^p$ , ou seja, a norma  $l_0$  corresponde a quantidade de elementos no vetor que não são nulos.

O problema de minimização da norma  $l_0$  mostrado na Equação 18 é computacionalmente intratável e suscetível a ruído. No entanto, avanços recentes mostraram que pode-se alcançar a reconstrução exata do sinal original com a troca da minimização da norma  $l_0$  pela norma  $l_1$  (Equação 19), isto é, a solução de menor norma  $l_1$  também é a solução de menor norma  $l_0$  (CANDES; TAO, 2005). Esta substituição faz com que o problema de otimização resultante seja tratável, pois este pode ser traduzido para um problema de programação linear (CHEN et al., 2001; CANDES; TAO, 2005).

$$\begin{array}{ll} \underset{x}{\text{minimizar}} & \|x\|_{l_1} \\ \text{sujeito a} & Ax = y \end{array} \quad (19)$$

A diferença entre as soluções obtidas nos problemas de otimização descritos pelas Equações 17 e 19 é ilustrada pelo seguinte exemplo (proposto aqui) fictício: uma placa de metal com superfície retangular de dimensões 10 x 1 cm (com 1 mm de espessura), teve sua superfície dividida em 10 segmentos quadrados (1 x 1 cm), como visto na Figura 4 (vista de cima). Quatro sensores de deformação foram instalados abaixo da placa, distribuídos de forma uniforme ao longo do maior lado da placa ( $s1$  a  $s4$ , vistos na Figura 4). A colocação de uma carga de teste em qualquer um dos 10 segmentos da placa faz com que a placa seja deformada no eixo normal a sua superfície, ocorrendo deformação tanto no segmento onde a carga foi posicionada como nos segmentos vizinhos (neste exemplo o perfil de deformação é imposto como uma Gaussiana). De posse da matriz de sensoriamento  $A$ , sabe-se que o problema de determinar as massas posicionadas acima de cada uma das 10 posições da placa (vetor  $x$ ) a partir do sinal adquirido pelos 4 sensores (vetor  $y$ ) é subdeterminado, pois se quer determinar o vetor  $x$  com 10 valores a partir do vetor de observações  $y$  com somente 4 valores além da relação linear  $Ax = y$ .

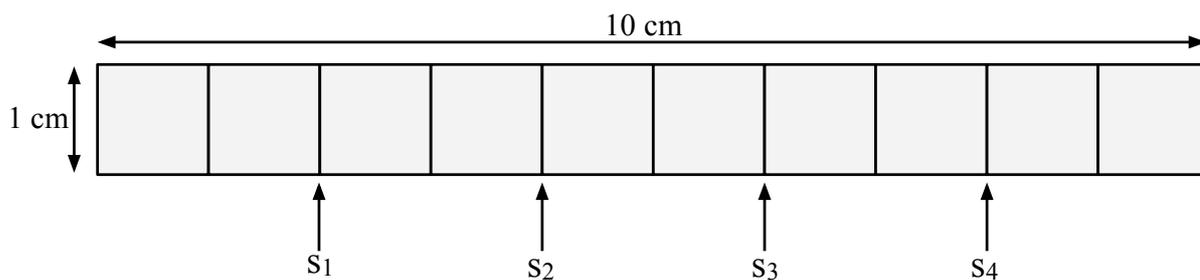


Figura 4: Esquemático da placa de metal (vista de cima), mostrando sua divisão em 10 segmentos e o posicionamento dos sensores  $s_1$  até  $s_4$ .

Para uma determinada colocação de cargas na placa, foi obtido o vetor  $y$  apresentado na Figura 5. Com base na matriz de sensoriamento  $A$  e do vetor de observações  $y$ , a recuperação do vetor  $x$  (configuração das cargas) foi realizada.

A Figura 6(a) indica o sinal original que corresponde à massa colocada acima de cada posição, além do sinal recuperado com a minimização da norma  $l_1$  (Figura 6(b)) e do sinal recuperado pela minimização da normal  $l_2$  (Figura 6(c)). Percebe-se que como o sinal era originalmente esparsa, a recuperação vista na Figura 6(b) foi exata, enquanto que a recuperação vista na Figura 6(c) difere do sinal original (solução não esparsa).

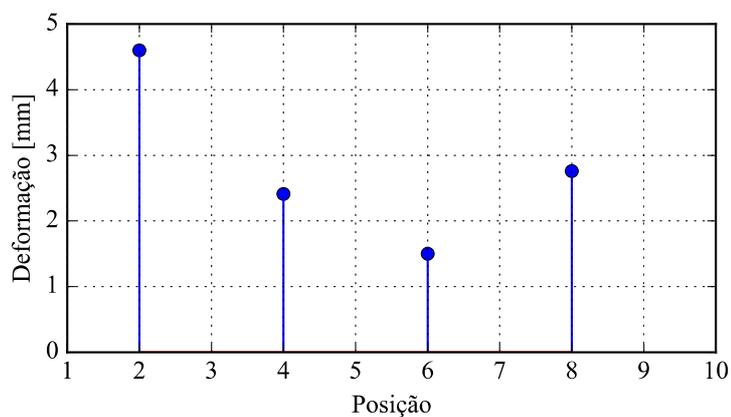


Figura 5: Valores de deformação medidos pelos sensores  $s_1$  até  $s_4$ .

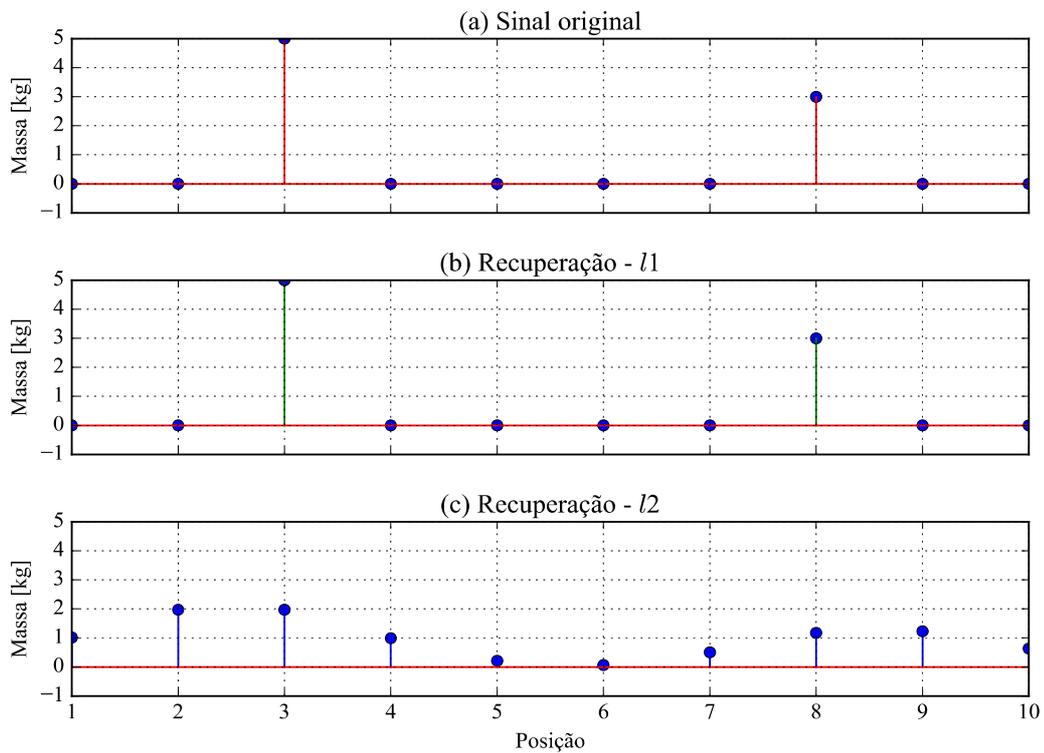


Figura 6: Comparação entre a recuperação do sinal original (a) por meio da minimização da norma  $l_1$  (b) e da norma  $l_2$  (c).

### 2.3.2 Algoritmos para sensoriamento compressivo

O problema de otimização visto na Equação 19, também chamado de *basis pursuit* (BP), pode ser traduzido para um problema de programação linear, cuja solução pode ser obtida pelo uso de pacotes computacionais especializados (CHEN et al., 2001; CANDÉS; TAO, 2005). Para tornar o método mais robusto quanto à presença de ruído, pode-se utilizar a variação do problema de otimização mostrada na Equação 20:

$$\underset{x}{\text{minimizar}} \frac{1}{2} \|Ax - y\|_{l_2}^2 + \alpha \|x\|_{l_1}, \quad (20)$$

onde  $\alpha$  é o parâmetro que determina o balanço entre a esparsidade da solução e o erro de reconstrução, obtido experimentalmente. O problema de otimização observado na Equação 20 recebe os nomes de *basis pursuit denoising* (CHEN et al., 2001) e de *Lasso* (*least absolute*

*shrinkage and selection operator*) (TIBSHIRANI, 1996), podendo também ser resolvido por meio de programação linear.

Uma dificuldade que pode ser encontrada na solução dos problemas de *basis pursuit* e *basis pursuit denoising* é a necessidade de solucionar os problemas de programação linear resultantes, que requerem implementações sofisticadas. Devido a isto, outros algoritmos foram propostos para a busca de soluções esparsas, como o *sl0* e o *OMP*.

No método *sl0* (*smoothed l0*), a norma  $l_0$  é aproximada com o uso da função contínua  $F_\sigma$ , o que permite o uso de métodos de otimização baseados na subida de gradiente para solução do problema de otimização resultante, além de tornar o problema mais robusto ao ruído (EFTEKHARI et al., 2009; MOHIMANI et al., 2010). A função  $F_\sigma$  é dada pela Equação 21:

$$F_\sigma(x) = \sum_{i=1}^n f_\sigma(x_i), \quad (21)$$

sendo:

$$f_\sigma(x_i) = \exp(-x_i^2 / 2\sigma^2), \quad (22)$$

e  $\sigma$  é o parâmetro de controle entre a exatidão da solução e a suavidade da aproximação (aumentando o valor de  $\sigma$  diminui-se a exatidão, mas aumenta-se a suavidade da função). Com base na função  $F_\sigma$ , a norma  $l_0$  pode ser aproximada pela Equação 23:

$$\|x\|_{l_0} \approx n - F_\sigma(x). \quad (23)$$

A ideia do método *sl0* é realizar a maximização da função  $F_\sigma$  com a restrição de que  $Ax = y$ , utilizando um valor inicial elevado para  $\sigma$ . O resultado da minimização é então utilizado como ponto de partida para o mesmo procedimento de otimização, repetido diminuindo o valor de  $\sigma$ . Este processo recursivo é repetido por um número fixo de iterações  $K$  (usualmente menor do que 10). Com isto, espera-se que a solução possa convergir para o máximo global. Os passos do algoritmo são descritos no Algoritmo 1.

1. Determinar a solução inicial para  $x$  por meio da pseudo-inversa;
2. Escolher uma sequência decrescente para  $\sigma : [\sigma_1 \dots \sigma_K]$ ;
3. Maximizar a função  $F_\sigma$  com  $\sigma = \sigma_k$ , para cada valor de  $k$  de 1 até  $K$ , utilizando um número fixo de iterações de subida de encosta e projetando a solução para o conjunto de soluções factíveis ( $Ax = y$ ).

Algoritmo 1: Etapas do algoritmo  $s/l0$ .

Outro método proposto para a solução da recuperação de sinais esparsos é o OMP (*orthogonal matching pursuit*). O objetivo do método OMP é escolher quais das colunas da matriz de sensoriamento  $A$  que participam da observação  $y$  por um processo guloso (*greedy*) de seleção (TROPP; GILBERT, 2007). O método é iterativo, sendo que a cada iteração escolhe-se a coluna de  $A$  que está mais correlacionada com o vetor  $y$ ; a coluna escolhida é subtraída de  $y$  e o resíduo é utilizado na próxima iteração. Espera-se que depois de  $m$  iterações, o algoritmo terá identificado o subconjunto correto de colunas, ou seja, determinado  $x$ . Os passos do método OMP são mostrados no Algoritmo 2.

1. Iniciar  $r_0 = y, x_0 = 0, \Lambda_0 = \emptyset, l = 0$ ;
2. Repetir de  $t = 1$  até  $m$  :
  1. Resolver  $\lambda_t = \arg \max_{j=1} |\langle r_{t-1}, \phi_j \rangle|$ , onde  $\phi_j$  é a  $j$ -ésima coluna da matriz  $A$ ;
  2. Aumentar os conjuntos:  $\Lambda_t = \Lambda_{t-1} \cup \{\lambda_t\}$  e  $\Phi_t = [\Phi_{t-1} \phi_{\lambda_t}]$ , sendo  $\Phi_0$  uma matriz vazia;
  3. Resolver o problema  $x_t = \arg \min_x \|y - \Phi_t x\|_{l_2}$ ;
  4. Calcular o novo residual  $r_t = y - \Phi_t x_t$ ;
3. A resposta é dada por  $x_m$ .

Algoritmo 2: Etapas do método OMP.

O método OMP tem a vantagem (ao ser comparado com o *basis pursuit*) de ser mais simples para implementar e ser potencialmente mais rápido. Porém, resultados mostram que o BP é mais estável e capaz de uma melhor recuperação de  $x$  quando  $A$  é uma matriz Gaussiana ou de Bernoulli (TROPP; GILBERT, 2007).

## 2.4 EVOLUÇÃO DIFERENCIAL

Evolução diferencial é um método de otimização estocástico, pertencente a família dos métodos de computação evolutiva (EC, do inglês *evolutionary computation*). O método opera com uma população de soluções candidatas (vetores), que é evoluída em um processo iterativo de forma a maximizar uma função de *fitness* arbitrária. O método não utiliza o gradiente da função de *fitness* e não realiza nenhuma suposição sobre o problema que está sendo otimizado, sendo assim um método meta-heurístico (STORN, 1997).

O método de DE recebe o seu nome por utilizar a diferença entre vetores (indivíduos da população de soluções) para guiar a busca. Esta característica faz com que o método seja auto-organizável, isto é, controle automaticamente a exploração do espaço de busca, diminuindo os passos conforme a convergência das soluções (STORN, 1997). Diferente da formulação original do método de algoritmo genético (GA), onde os indivíduos são codificados como cadeias de valores binários, o DE opera diretamente com vetores de números reais, o que simplifica a sua implementação e o torna mais eficiente em problemas que utilizam representações em números reais.

### 2.4.1 Etapas do método

Sendo um método de EC, a DE segue as etapas mostradas na Figura 7. O processo começa com a inicialização da população, e continua com o processo iterativo de mutação, recombinação e seleção que caracterizam os métodos de EC. Existem diferentes esquemas de mutação e recombinação, sendo que nesta subseção discute-se o método *DE/rand/1/bin* (STORN, 1997).

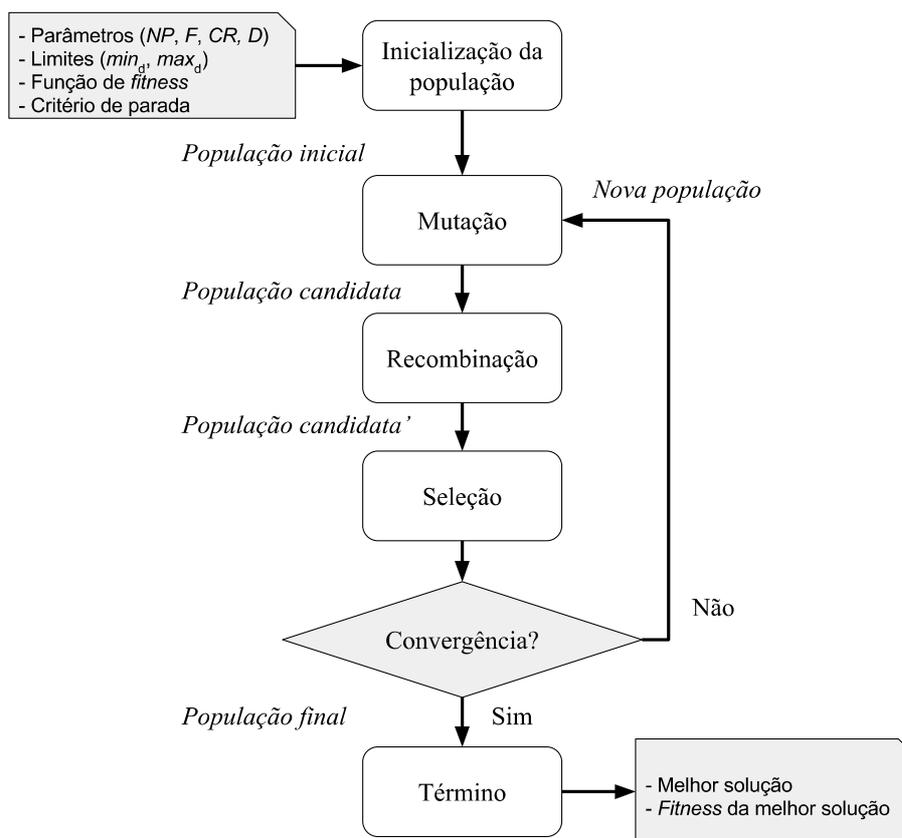


Figura 7: Etapas do método de evolução diferencial.

A população é composta por  $NP$  vetores de dimensão  $D$ , onde cada vetor é uma solução para o problema de otimização tratado. No processo de inicialização, cada vetor gerado é inicializado pela atribuição de valores pseudo-aleatórios distribuídos uniformemente no espaço de busca do problema. Detalhadamente, o valor para cada dimensão  $d$  ( $d = 1, 2, \dots, D$ ) do vetor  $P_i$  ( $i = 1, 2, \dots, NP$ ) pode ser determinado pela Equação 24:

$$P_{i,d} = \min_d + \text{rand}(0, 1) \cdot (\max_d - \min_d), \quad (24)$$

onde  $\text{rand}(0, 1)$  é uma função que retorna um número pseudo-aleatório no intervalo  $[0, 1]$  (distribuição uniforme) e  $\min_d$  e  $\max_d$  são os limites inferior e superior para a dimensão  $d$ .

O procedimento de mutação gera um *vetor doador* para cada vetor da população atual (*vetor alvo*). Cada *vetor doador*  $M_i$  ( $i = 1, 2, \dots, NP$ ) é resultado da combinação de três vetores distintos (de índices  $r_1, r_2$  e  $r_3$ ) escolhidos aleatoriamente da população, seguindo a Equação 25:

$$M_i = P_{r_1} + F \cdot (P_{r_2} - P_{r_3}), \quad (25)$$

onde o fator de mutação  $F$  é um parâmetro real, usualmente no intervalo  $[0,4, 1,0]$  que controla o passo da mutação.

Após a mutação, é realizado o procedimento de combinação. Na recombinação combina-se cada *vetor alvo*  $P_i$  e o seu respectivo *vetor doador*  $M_i$ , gerando o *vetor candidato*  $C_i$ . A Equação 26 mostra o esquema de combinação:

$$C_{i,d} = \begin{cases} M_{i,d}, & \text{se } \text{rand}(0,1) \leq CR \text{ ou } d=j, \\ P_{i,d}, & \text{caso contrário.} \end{cases} \quad (26)$$

onde a taxa de cruzamento  $CR$  é um parâmetro real no intervalo  $[0, 1]$  e  $j$  é uma dimensão escolhida aleatoriamente a cada processo de recombinação, garantindo que o valor de ao menos uma dimensão do *vetor doador* seja utilizado. Para respeitar os limites inferior e superior do problema, pode-se limitar que  $C_i^d$  fique na faixa  $[\min_d, \max_d]$ .

O procedimento de seleção é realizado após a recombinação, por meio da função de *fitness*. A função de *fitness* é a função utilizada para avaliar a qualidade das soluções, atribuindo a elas um valor numérico (o valor de *fitness*). Na sua forma original realiza-se a maximização do *fitness*, mas deve-se notar que qualquer problema de minimização pode ser convertido em um de maximização trivialmente (minimizar uma função é equivalente a maximizar o seu negativo).

De forma específica, na etapa de seleção avalia-se o *fitness* de cada *vetor candidato*  $C_i$ , e este valor é comparado com o *fitness* do seu respectivo *vetor alvo*  $P_i$ . Se o *fitness* de  $C_i$  for maior ou igual ao *fitness* de  $P_i$ , então  $P_i$  é substituído por  $C_i$  para a próxima iteração do método. Caso contrário,  $C_i$  é descartado.

O processo iterativo de mutação, recombinação e seleção ocorre até que uma condição de parada seja alcançada, como atingir um número pré-determinado de iterações ou até a população alcançar uma determinada métrica de convergência. Ao final do processo, a solução com maior *fitness* é selecionada e tida como resposta.

O algoritmo do método *DE/rand/1/bin* é mostrado no Algoritmo 3.

1. Iniciar a população com valores aleatórios distribuídos uniformemente, respeitando os limites de cada dimensão;
2. Enquanto o critério de parada não for satisfeito, faça:
  - 2.1. Para cada  $i = 1, 2, \dots, NP$ , faça:
    - 2.1.1. Escolher aleatoriamente (distribuição uniforme) os inteiros distintos  $r_1$ ,  $r_2$  e  $r_3$ , no intervalo  $[1, NP]$ . Todos devem ser diferentes de  $i$ ;
    - 2.1.2. Gerar o vetor doador  $M_i$  utilizando a Equação 25;
    - 2.1.3. Gerar o vetor candidato  $C_i$ , utilizando a Equação 26;
    - 2.1.4. Limitar os valores de  $C_i$  de forma a respeitar os limites de cada dimensão;
  - 2.2. Para cada  $i = 1, 2, \dots, NP$ , faça:
    - 2.2.1. Avaliar o *fitness* de  $C_i$ . Se for maior do que o *fitness* de  $P_i$ , então  $P_i = C_i$ ;
3. Retornar o vetor que tiver o maior valor de *fitness*.

Algoritmo 3: Etapas do método *DE/rand/1/bin*.

#### 2.4.2 Exemplo do processo evolutivo

Para exemplificar o processo evolutivo no método DE e visualizar a convergência da população de soluções, foi realizada aqui a minimização da função de *Rastrigin* (MÜHLENBEIN et al., 1991) para duas dimensões (Equação 27, mínimo global em  $x=0$  e  $y=0$ ) utilizando o método *DE/rand/1/bin*, com  $NP = 30$ ,  $CR = 0,95$  e  $F = 0,7$  por 90 iterações.

$$f(x, y) = 20 + (x^2 - 10 \cos(2\pi x)) + (y^2 - 10 \cos(2\pi y)). \quad (27)$$

A Figura 8 mostra a população de soluções nas iterações 0 (estado inicial), 30, 60 e 90. A Tabela 1 mostra a melhor solução e o seu valor de *fitness* para as iterações escolhidas.

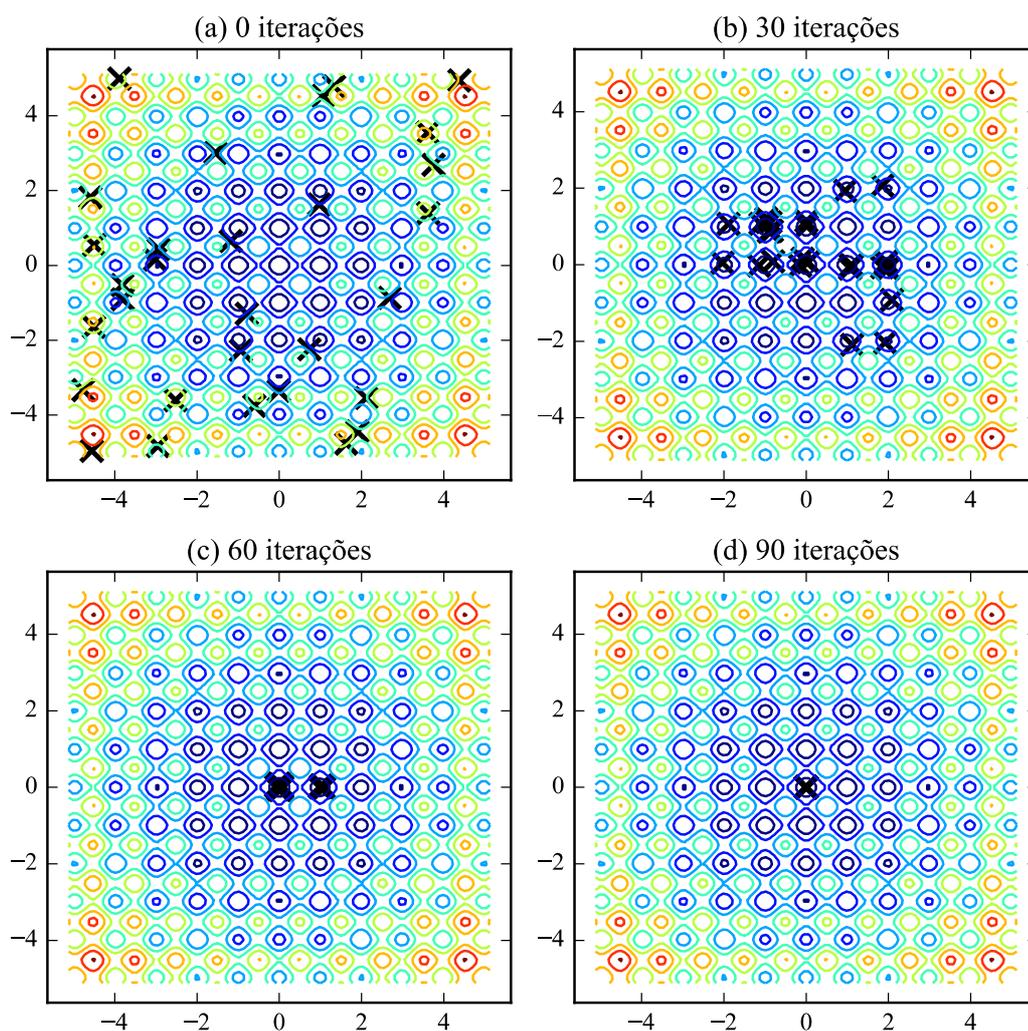


Figura 8: Exemplo de convergência da população de soluções durante o processo de otimização no método de DE. A população de soluções é mostrada para os instantes após: (a) estado inicial, (b) 30 iterações, (c) 60 iterações e (d) 90 iterações. O eixo horizontal corresponde à variável  $x$ , e o vertical à variável  $y$ .

Tabela 1: Relação de melhor solução por iteração para o exemplo de minimização visto na Figura 8.

Iteração	$x$	$y$	$fitness$
0	-3,018	0,157	-13,674
30	0,013	1,004	-1,044
60	-0,001	0,004	-0,004
90	0,000	0,000	0,000

### 2.4.3 Escolha dos parâmetros e desempenho do método

Na prática, o maior esforço computacional em DE está concentrado na função de *fitness*, que é avaliada  $NP$  vezes a cada iteração do método. Como o método trabalha com uma população de soluções independentes, pode-se paralelizar a avaliação de *fitness* de forma a aproveitar processadores com múltiplos núcleos. Esta capacidade de paralelização é explorada na Seção 5.2 desta tese.

A escolha dos parâmetros ( $NP$ ,  $F$  e  $CR$ ) influencia o desempenho do método. Por exemplo, o parâmetro  $F$  controla a exploração do espaço de busca, com valores elevados favorecendo a diversidade da população (DAS; SUGANTHAN, 2011; DAS et al., 2016). Sobre o parâmetro  $CR$ , valores reduzidos (como 0,1) favorecem a otimização de problemas separáveis, enquanto que valores maiores (como 0,9) são aconselhados para problemas acoplados (onde a solução depende da interação entre os parâmetros da solução). O aumento de  $CR$  tende a acelerar a convergência do método (STORN, 1997). A escolha de  $NP$  considera principalmente o número de dimensões do espaço de busca, sendo que problemas com maiores dimensões exigem uma maior população (STORN, 1997; CHEN et al., 2015).

Algoritmos tais como o *SaDE* (QIN et al., 2009) e *JADE* (JINGQIAO ZHANG; SANDERSON, 2009) são variantes do DE que realizam a escolha automática dos parâmetros  $CR$  e  $F$ . Nestes métodos, os parâmetros  $CR$  e  $F$  são adaptativos, isto é, são alterados a cada iteração de forma a beneficiar a convergência a partir do estado em que a população se encontra.

## 2.5 REDES DE BRAGG EM FIBRA ÓTICA

Uma rede de Bragg em fibra ótica (FBG) consiste em uma perturbação do índice de refração do núcleo de uma fibra ótica, usualmente monomodo (HILL et al., 1978). Uma FBG tem a característica de refletir luz em uma faixa específica de comprimentos de onda, transmitindo o restante. Esta reflexão seletiva permite o seu uso como filtro em sistemas de comunicação e também como sensores, quando sujeita a perturbações externas. A Figura 9 mostra o esquemático (simplificado) de uma FBG, onde são identificados alguns dos

parâmetros estruturais, sendo  $\Lambda$  o período da modulação, e  $n_0$ ,  $n_1$ ,  $n_2$  e  $n_3$  os índices de refração do meio externo ( $n_0$ ), da casca ( $n_1$ ), do núcleo ( $n_2$ ) e dos planos da rede ( $n_3$ ), respectivamente.

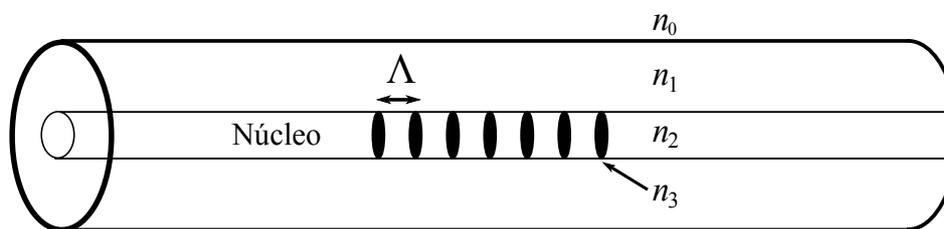


Figura 9: Esquemático simplificado de uma FBG, identificando o índice de refração do ambiente externo ( $n_0$ ), da casca ( $n_1$ ), do núcleo ( $n_2$ ) e dos planos da rede ( $n_3$ ), além do espaçamento entre os planos (período de modulação).

### 2.5.1 Princípio de funcionamento

Uma FBG é a própria modulação periódica do índice de refração do núcleo de uma fibra ótica, e sendo assim, uma parcela de luz é refletida (reflexão de Fresnel) a cada alteração de índice de refração ao longo da rede. Devido à interferência que ocorre nesta estrutura periódica, somente as ondas cujos comprimentos de onda se aproximem do comprimento de onda de ressonância serão efetivamente refletidas pela FBG, sendo o restante transmitido.

A banda espectral refletida por uma FBG depende dos seus parâmetros estruturais. Para uma FBG (em fibra monomodo) com modulação de índice uniforme, a banda refletida é centrada no comprimento de onda de Bragg ou de ressonância  $\lambda_b$ , dado pela Equação 28 (HILL et al., 1978):

$$\lambda_b = 2 n_{eff} \Lambda, \quad (28)$$

onde  $n_{eff}$  é o índice de refração efetivo do modo fundamental que se propaga no guia de onda (fibra).

Existem diferentes técnicas para a fabricação de FBGs. A primeira FBG foi observada por acaso em um experimento onde uma fibra ótica foi iluminada por um laser de argônio (HILL et al., 1978). Uma extremidade da fibra ótica foi clivada de forma a refletir parte do sinal e formar um padrão de interferência, resultando na gravação da FBG ao longo da fibra ótica, com periodicidade determinada pelo comprimento de onda do laser.

Uma maior flexibilidade na gravação de FBGs foi obtida com o desenvolvimento de técnicas de gravação com incidência do feixe do laser na lateral da fibra. Um exemplo está no uso da técnica de gravação por máscaras de fase (HILL et al., 1993), que possibilitou a gravação de FBGs cuja periodicidade é determinada pelo período da máscara, e não do laser.

Perturbações na estrutura de uma FBG, como as causadas por estiramento ou compressão e pela variação da temperatura, modificam a faixa espectral refletida pela FBG, tornando-a útil no sensoriamento de parâmetros físicos. A variação do  $\lambda_b$  causada pela alteração de temperatura  $\Delta T$  é dada pela Equação 29, sendo  $\alpha_\lambda$  o coeficiente de expansão térmica e  $\alpha_n$  o coeficiente termo-ótico da fibra.

$$\Delta \lambda_b = \lambda_b (\alpha_\lambda + \alpha_n) \Delta T \quad (29)$$

A variação causada em  $\lambda_b$  devido a um estiramento (ou compressão) uniforme  $\epsilon$  da fibra é dada pela Equação 30, tal que:

$$\Delta \lambda_b = \lambda_b (1 - p_e) \epsilon, \quad (30)$$

onde  $p_e$  é o coeficiente elasto-ótico da fibra.

As Equações 29 e 30 evidenciam a sensibilidade de FBGs quanto à variação de temperatura e a deformações mecânicas. Além disto, uma FBG pode ser sensível a outros parâmetros físicos por meio do preparo adequado da fibra. Um exemplo está na sensibilidade ao índice de refração do ambiente, que pode ser alcançada mediante a remoção parcial da casca da fibra (LADICICCO et al., 2004).

Devido à sua sensibilidade a parâmetros físicos e às suas características de imunidade a campos eletromagnéticos externos, facilidade de transmissão de sinais, capacidade inerente de multiplexação, dimensões reduzidas, entre outras, as FBGs foram extensivamente estudadas e aplicadas como sensores. Exemplos de aplicações são encontrados para o sensoriamento de temperatura e estiramento (YU et al., 2000; CHOJNOWSKI; JĘDRZEJEWSKI, 2006; LOURENÇO et al., 2010), sensoriamento de índice de refração (LIANG et al., 2005; CORADIN et al., 2010; NEGRI; ZILLI; et al., 2011; COROTTI JR et al., 2015) e sensoriamento táctil (HEO et al., 2006; COWIE et al., 2007; KAMIZI et al., 2015).

O fim abrupto da modulação do índice de refração em uma FBG resulta na presença de lóbulos laterais no espectro de reflexão. Este fenômeno é análogo ao alargamento espectral

causado por uma janela retangular em filtros digitais, onde a escolha de funções de janelamento adequadas podem atenuar o alargamento. A atenuação dos lóbulos laterais (apodização) do espectro refletido por uma FBG pode ser alcançada pelo uso de perfis suaves na alteração do índice de refração da fibra ótica. A função Gaussiana e o cosseno elevado (ERDOGAN, 1997) são exemplos de envelopes utilizados para a apodização.

Com finalidade ilustrativa, a Figura 10 compara a refletância de duas FBGs centradas em  $\lambda_b=1551$  nm, obtidas por simulação (implementação própria baseado no método das matrizes de transferência apresentado na Seção 2.5.3), para uma FBG sem apodização e outra FBG com envelope Gaussiano no perfil de modulação do índice de refração do núcleo, tendo o restante dos parâmetros semelhantes.

A variação da periodicidade ao longo do eixo de uma FBG (gorjeio ou *chirp*), tem como resultado o alargamento do espectro refletido. Além de sua aplicação na área de comunicação ótica (DONG et al., 1997), as redes com gorjeio também podem ser utilizadas no sensoriamento como transdutores (HUANG et al., 1995; NAND, 2007).

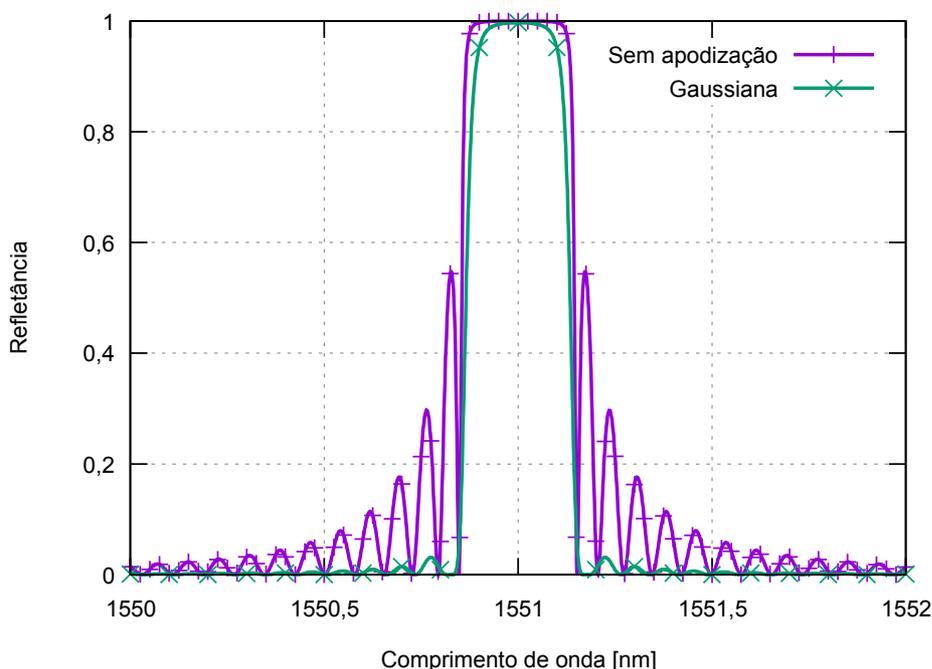


Figura 10: Comparativo entre o espectro de reflexão de uma FBG sem apodização e de uma FBG apodizada por meio de um envelope Gaussiano na modulação do índice de refração do núcleo.

### 2.5.2 Métodos de interrogação

O uso de FBGs para o sensoriamento requer a iluminação da FBG e a detecção do sinal refletido, sendo que o mensurando é determinado a partir das alterações apresentadas neste sinal refletido. Considerando o caso onde a alteração causada na FBG é uniforme, sabe-se, pelas Equações 29 e 30, que o espectro será simplesmente deslocado em comprimento de onda.

Este processo de interrogação de FBGs pode ser realizado com diferentes métodos. No método do filtro sintonizável, é utilizada uma fonte de luz banda larga em conjunto com um filtro sintonizável de Fabry-Perot de Fibra (FFP) para varrer (sequencialmente) a faixa de comprimentos de onda referentes à reflexão da FBG (KERSEY et al., 1993). Este método permite que somente uma faixa estreita de comprimentos de onda ilumine a fibra a um dado instante; com o uso de um fotodetector, pode-se reconstruir então uma aproximação do espectro de reflexão da FBG interrogada. Na literatura (PATERNO et al., 2005) encontram-se trabalhos que trocaram o uso de FFP por outra FBG, aproveitando o fato do  $\lambda_b$  de uma FBG ser sintonizável com o estiramento da FBG.

Outro método de interrogação (uso de um espectrômetro) consiste em iluminar a FBG com uma fonte de luz banda larga, e analisar o espectro do sinal refletido por meio de uma rede de difração em conjunto com um sensor de imagem baseado em CCD (*charge-coupled device*) ou CMOS (*complementary metal-oxide semiconductor*) (LENG; ASUNDI, 2003).

Independentemente do método utilizado para iluminar e adquirir o espectro do sinal refletido, alterações uniformes ao longo da estrutura de uma FBG podem ser determinadas pelo monitoramento do pico do sinal refletido, relacionado ao  $\lambda_b$  da FBG interrogada. A simples busca pelo comprimento de onda de maior refletividade pode resultar em uma precisão reduzida devido à presença de ruído no sinal refletido e à resolução limitada na fotodetecção (NEGRI; NIED; et al., 2011). Para a detecção do pico do sinal refletido, pode-se utilizar métodos como o ajuste de uma Gaussiana ao sinal, o ajuste polinomial, o cálculo do centroide e o uso de filtros digitais. Para casos onde o pico do sinal refletido apresenta bipartição ou outros tipos de deformação, também podem ser utilizados métodos baseados no ajuste por redes neurais artificiais (PATERNO et al., 2006).

### 2.5.3 O método das matrizes de transferência

O espectro de reflexão de uma FBG pode ser determinado teoricamente por meio do método das matrizes de transferência. O método permite determinar a relação entre a luz incidente e a refletida pela rede para um determinado comprimento de onda  $\lambda$ , sendo esta relação representada por uma matriz 2x2. A Figura 11 mostra um esquemático identificando o modo contra-propagante ( $a$ ) e o modo propagante ( $b$ ), cuja relação será determinada pelo método das matrizes de transferência.

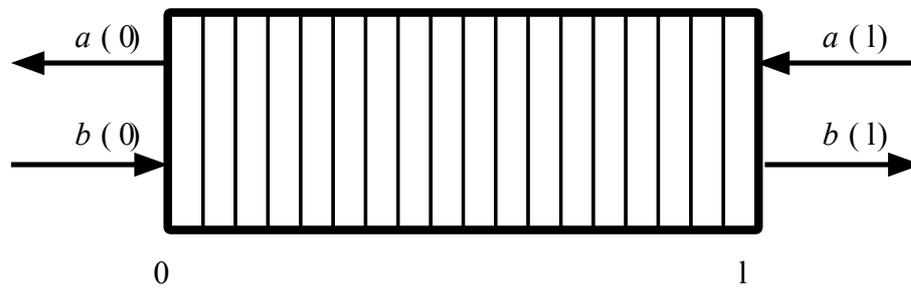


Figura 11: Esquemático identificando o modo contra propagante ( $a$ ) e o modo propagante ( $b$ ) em um FBG, em um segmento identificado pela posição no eixo de propagação  $z$ , que se estende de 0 até o comprimento  $l$ .

Algumas suposições são realizadas inicialmente sobre a estrutura da FBG analisada. Sendo  $l$  o comprimento da FBG analisada, e  $\bar{n}$  o valor médio do índice de refração do núcleo da fibra, assume-se que a modulação do índice de refração é senoidal, com amplitude  $\Delta n_0$  e periodicidade  $\Lambda$ . Portanto, a relação entre o modo contra-propagante e propagante é dada pela Equação 31 (YAMADA; SAKUDA, 1987):

$$\begin{bmatrix} a(0) \\ b(0) \end{bmatrix} = \begin{bmatrix} T_{11} & T_{12} \\ T_{21} & T_{22} \end{bmatrix} \begin{bmatrix} a(l) \\ b(l) \end{bmatrix}. \quad (31)$$

$T_{11}$  e  $T_{22}$  são dados pela Equação 32 e  $T_{12}$  e  $T_{21}$  pela Equação 33:

$$T_{11} = T_{22}^* = \frac{\Delta\beta \sinh(sl) + is \cosh(sl)}{is} \exp(-i\beta_0 l) \quad (32)$$

$$T_{12} = T_{21}^* = \frac{k \sinh(sl)}{is} \exp(i\beta l) \quad (33)$$

sendo  $k = \pi \Delta n_0 / \lambda$ ,  $s = (|k|^2 - (\Delta\beta)^2)^{1/2}$  e  $\Delta\beta = 2\bar{n}\pi/\lambda - \pi/\lambda$ .

Assumindo  $a(l)=0$  e  $b(l)=1$  (valor arbitrário diferente de zero) nas Equações 32 e 33, pode-se calcular o valor de  $a(0)$  e  $b(0)$ , com a refletância dada pela Equação 34:

$$R = \left| \frac{a(0)}{b(0)} \right|^2. \quad (34)$$

Uma FBG cuja estrutura não é uniforme, como no caso de FBGs com gorjeio, apodizadas e as sujeitas a deformações com perfil não uniforme, também pode ser simulada utilizando o método das matrizes de transferência (HUANG et al., 1995). Para isto, a FBG é seccionada em uma sequência de FBGs uniformes, onde cada segmento tem uma matriz de transferência correspondente. A resposta da FBG original é dada então pelo produto das matrizes de transferência das secções.

## CAPÍTULO 3

### ESTIMAÇÃO DA POSIÇÃO DE CARGAS EM SUPERFÍCIES UTILIZANDO FBGS

Neste capítulo é apresentado o desenvolvimento de um sistema de sensoriamento tátil distribuído (vide Seção 1.2.1), capaz de localizar uma carga cilíndrica colocada sobre uma placa retangular. Duas versões do sistema foram desenvolvida. A primeira versão utilizou FBGs como elementos transdutores instalados diretamente na placa e RNAs para determinar a posição da carga.

O segundo sistema se assemelha ao primeiro, porém utilizou um número maior de FBGs, que foram encapsuladas em blocos de silicone para a redução do tempo de resposta do sistema. Neste segundo sistema, SVRs foram utilizadas para a localização da carga.

#### 3.1 PRIMEIRO SISTEMA

Nesta seção é descrita a configuração experimental da primeira versão do sistema de estimação da posição de cargas, contendo também a metodologia de estimação e os resultados obtidos.

##### 3.1.1 Configuração experimental

Uma placa de PMMA (polimetil-metacrilato) de  $31,8 \times 30,7$  cm, com espessura de 0,5 cm, foi utilizada como superfície para o sensoriamento distribuído. A placa foi colocada sobre quatro hemisférios de silicone (raio de 0,3 cm), posicionados nos cantos da placa, como visto na Figura 12. Este posicionamento foi escolhido por permitir que a placa deforme sob forças transversais.

Quatro FBGs foram gravadas em seções diferentes de uma mesma fibra ótica e foram fixadas ao longo das diagonais da placa, como visto na Figura 12. A deformação da placa faz

com que ocorra o tracionamento ou compressão das FBGs. O posicionamento nas diagonais foi escolhido por maximizar a resposta das FBGs (RIBEIRO, 2014).

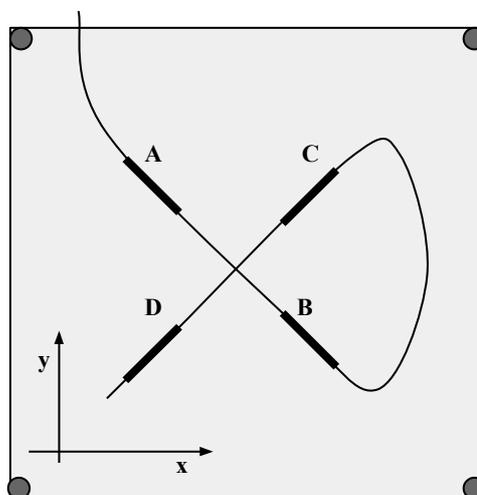


Figura 12: Esquemático da placa de PMMA, mostrando o posicionamento das FBGs A, B, C e D.

Ao fixar as FBGs na placa, estas foram primeiramente tracionadas (resultando em um deslocamento do  $\lambda_b$  de aproximadamente 50 pm) e presas utilizando fita adesiva. Utilizando cola de cianoacrilato, as extremidades das FBGs foram então coladas na placa, de forma a preservar o estiramento inicial. Uma folha de papel com graduação milimétrica foi colado acima da placa para auxiliar o posicionamento das cargas. O estiramento inicial evita folgas na FBG, fazendo com que esta possa ser tracionada mesmo por deformações mecânicas pequenas da placa, além de torná-las sensíveis à compressão.

As FBGs foram gravadas no Núcleo de Dispositivos Fotorrefrativos da UTFPR pela técnica de iluminação direta de uma máscara de fase com um laser de excímero KrF (Xantos XS-Coherent) em 248 nm. Foram utilizadas máscaras de fase com diferentes periodicidades, resultando em FBGs com  $\lambda_b$  distintos de forma a permitir a multiplexação por comprimento de onda. Os comprimentos de onda de pico verificados para as FBGs identificadas na Figura 12 são: A = 1539,402 nm, B = 1535,304 nm, C = 1530,964 nm e D = 1527,288 nm a 23 °C, valores medidos antes da fixação na placa e do estiramento inicial. As FBGs resultantes apresentaram um comprimento aproximadamente igual a 2,5 mm e baixa refletância (< 10%). Um LED (*light emitting diode*) de banda larga (Superlum PILOT 2 LED, centrado em 1558,2 nm com largura à meia altura de 73,8 nm), foi utilizado para a interrogação das FBGs. A luz refletida pelas FBGs é coletada por um interrogador ótico (Ibsen I-MON E512,

resolution  $< 0.5$  pm) utilizando uma taxa de interrogação de 20 Hz. A configuração do sistema de interrogação pode ser vista na Figura 13.

Os comprimentos de onda de pico do espectro de reflexão foram computados utilizando ajuste Gaussiano. A sala onde os experimentos foram realizados foi mantida a uma temperatura controlada de  $(23,0 \pm 0,5)$  °C.

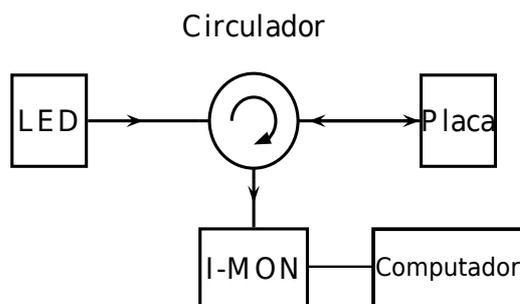


Figura 13: Sistema de interrogação das FBGs.

Uma carga cilíndrica com 0,5 kg de massa e 1 cm de raio foi utilizada nos experimentos. A carga foi centrada em pontos distintos da superfície, restrita a uma área de  $20 \times 20$  cm localizada na região central da placa (para evitar regiões próximas às bordas da placa). Dois espectros foram adquiridos para cada posicionamento da carga: um antes do posicionamento, para referência, e outro após o posicionamento. Isto foi realizado para compensar variações térmicas e histerese mecânica na placa. Para reduzir a flutuação nos sinais devido à histerese, os espectros foram adquiridos 5s após a colocação ou remoção da carga na placa. Os posicionamentos foram realizados em uma grade simétrica com pontos separados por passos de 5cm em ambos os eixos, totalizando 25 pontos. Estes 25 posicionamentos foram repetidos três vezes, resultando em 3 conjuntos de dados.

### 3.1.2 Estimação da posição da carga

O posicionamento da carga na placa faz com que esta seja deformada elasticamente, resultando na tração ou compressão das FBGs, dependendo da localização da carga. Nesta configuração, fatores como a localização de cada FBG, o estiramento inicial, os suportes e o material da placa influenciam a resposta do sistema. Os fatores descritos dificultam a modelagem teórica do sistema, e por isto foi feita a escolha de determinar o modelo do

sistema (relação entre a posição da carga e a saída dos sensores) por meio de dados experimentais e de uma RNA.

Uma RNA foi treinada e utilizada para estimar a posição da carga na superfície de sensoriamento. Foi utilizada a topologia MLP, com quatro entradas, cinco neurônios na única camada escondida e dois neurônios na camada de saída. Os deslocamentos (diferença entre os picos antes e depois da colocação da carga) em comprimento de onda no sinal refletido pelas FBGs foram utilizados como entrada (uma entrada para cada FBG), enquanto que as saídas correspondem à posição estimada da carga nos eixos  $x$  e  $y$ . Todos os neurônios utilizaram a função sigmoide simétrica como função de ativação, sendo que as entradas e saídas foram escalonadas linearmente para a faixa de -1 até 1 para respeitar a faixa de operação da função de ativação. O treinamento supervisionado da RNA foi realizado pelo método NBN (similar ao método de Levenberg-Marquardt) (WILAMOWSKI; YU, 2010), partindo de pesos sinápticos pseudo-aleatórios no intervalo uniforme  $[-0,5, 0,5]$ .

A RNA foi treinada com um dos três conjuntos de dados adquiridos. A topologia da RNA e os parâmetros foram escolhidos de forma a minimizar o erro obtido ao verificar a rede treinada com o segundo conjunto de dados (conjunto de dados de validação). Por último, a RNA treinada foi testada com o terceiro conjunto de dados para estimar a capacidade de generalização da RNA.

Três diferentes métricas de erro foram estabelecidas: a distância Euclidiana média entre o ponto real e o ponto estimado pela RNA (aqui chamado de erro Euclidiano), o erro absoluto médio no eixo  $x$  e o erro absoluto médio no eixo  $y$ .

### 3.1.3 Resultados

Os resultados experimentais obtidos são mostrados na Tabela 2 (resultados obtidos com o conjunto de dados de teste), sendo necessário observar que o erro Euclidiano não pode ser calculado a partir do erro absoluto médio final para os eixos  $x$  e  $y$ . As respostas das FBGs ao estiramento podem ser vistas na Tabela 3, que mostra o maior valor e o valor médio dos deslocamentos do comprimento de onda de pico das FBGs durante a aquisição do conjunto de dados de treinamento.

Tabela 2: Resultados experimentais para as três métricas de erro.

<b>Métrica</b>	<b>Valor [mm]</b>
Erro médio absoluto no eixo $x$	2,73
Erro médio absoluto no eixo $y$	1,65
Erro Euclidiano	3,88

Tabela 3: Resposta ao estiramento para as FBGs utilizadas durante os experimentos.

<b>FBG</b>	<b>Maior <math>\Delta \lambda_b</math> [nm]</b>	<b><math>\Delta \lambda_b</math> médio [nm]</b>
A	111	37
B	128	53
C	118	38
D	142	50

O mapeamento do erro Euclidiano na superfície da placa é apresentado na Figura 14. O mapa de erros foi construído pela interpolação do erro Euclidiano obtido com o conjunto de dados de teste para facilitar a visualização.

A visualização dos deslocamentos em comprimento de onda causados pela histerese e variações de temperatura podem ser vistas na Figura 15, que mostra os deslocamentos para as FBGs logo após a remoção da carga no ponto  $x = 15$  e  $y = 15$  cm.

O erro Euclidiano mostrado na Tabela 2 corresponde a 1,37% da diagonal da área da superfície de sensoriamento. A raiz do erro quadrático médio correspondente é igual a 1,93% da diagonal, menor do que o erro de 2,7% reportado na literatura (COWIE et al., 2007). Outro fator a ser considerado é que este trabalho propõe uma alternativa mais simples à descrita por Cowie et al. (2007), utilizando 4 FBGs ao invés de 9 e uma RNA mais compacta, com 5 neurônios na camada escondida ao invés de 42. No entanto, o presente trabalho utilizou uma área de sensoriamento levemente menor ( $20 \times 20$  cm ao invés de  $16 \times 26$  cm, uma redução de aproximadamente 4 % da área).

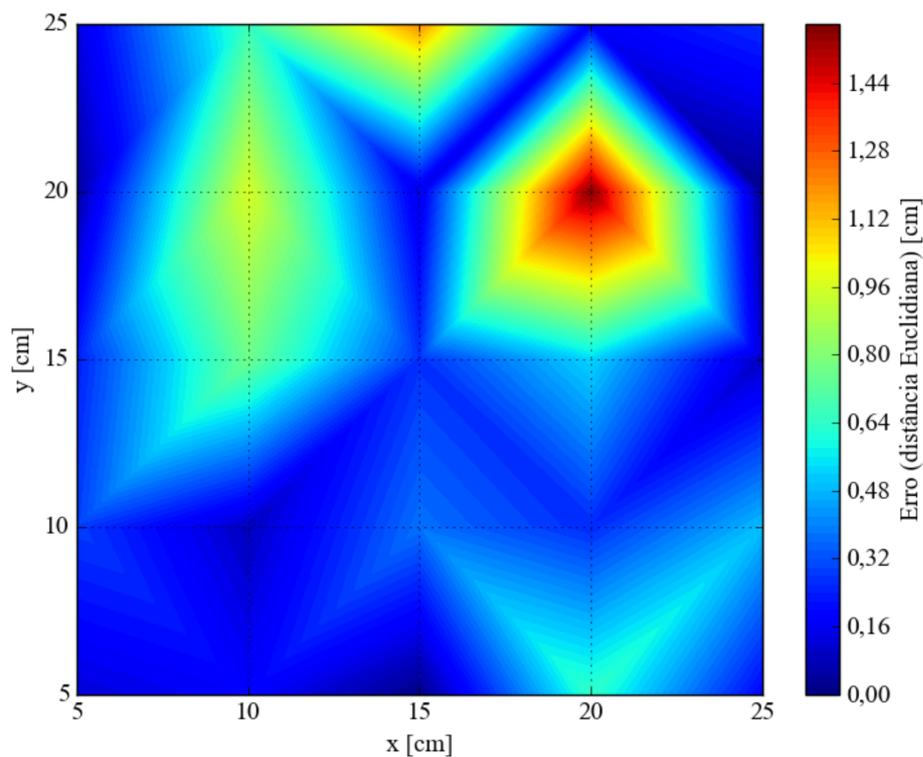


Figura 14: Estimativa do mapa do erro Euclidiano, calculado pela interpolação dos dados experimentais para a região central da placa.

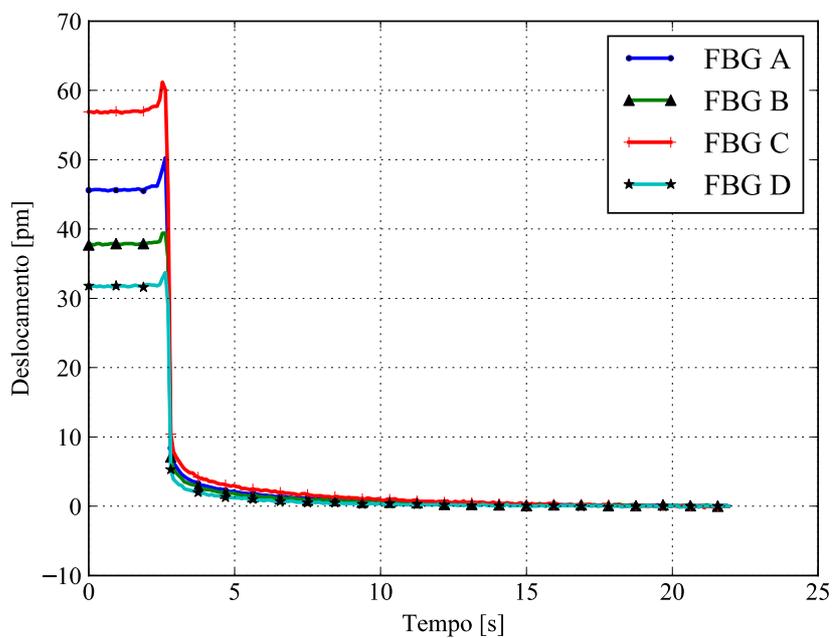


Figura 15: Deslocamento de onda de pico das FBGs após a remoção da carga de teste no ponto  $x = 15$  cm e  $y = 15$  cm.

Como visto na Tabela 3, as FBGs apresentaram respostas distintas ao estiramento, apesar de terem a mesma estrutura aproximada e mesma sensibilidade ao tracionamento (aproximadamente  $1,22 \text{ pm}/\mu\epsilon$ , medido experimentalmente) antes da fixação na placa. Este resultado indica que as FBGs não foram posicionadas simetricamente, e que o tensionamento prévio não foi uniforme nas 4 FBGs. A diferença entre os erros no eixo  $x$  e  $y$  também pode ser um resultado do posicionamento assimétrico. O mapeamento de erros visto na Figura 14 mostra que existem alguns pontos com erros significativamente maiores do que outros.

Na Figura 15, verifica-se que o sinal decai de 90% para 10% em até 0,6 s, para todos os transdutores, fornecendo uma estimativa do tempo de resposta do sistema.

## 3.2 SEGUNDO SISTEMA

Nesta seção descreve-se a configuração experimental, a metodologia de estimação e a avaliação da segunda versão do sistema de estimação da posição de cargas.

### 3.2.1 Configuração experimental

Doze FBGs foram gravadas no Núcleo de Dispositivos Fotorrefrativos da UTFPR pela técnica de iluminação direta de uma máscara de fase com um laser de excímero KrF (Xantos XS-Coherent) em 248 nm. Foram utilizadas máscaras de fase com diferentes periodicidades, de forma a cada FBG ter um comprimento de ressonância distinto (na faixa de 1520,5 nm até 1567,7 nm, em 24 °C), possibilitando a multiplexação em comprimento de onda. Estas FBGs foram utilizadas para construir 12 cabeças sensoras. As FBGs apresentaram baixa refletância ( $< 10\%$ ) e comprimentos da ordem de 2,5 mm.

Cada cabeça sensora é composta por uma FBG encapsulada em um bloco retangular de borracha de silicone acetinada (utilizada normalmente como adesivo e vedante). O encapsulamento faz com que a aplicação de uma força transversal tracione a fibra, resultando no deslocamento do espectro de reflexão da rede para maiores comprimentos de onda, além de proteger a FBG (que fora gravada em uma região sem a camada de proteção de acrilato). A Figura 16 mostra o esquemático e uma foto da cabeça sensora proposta.

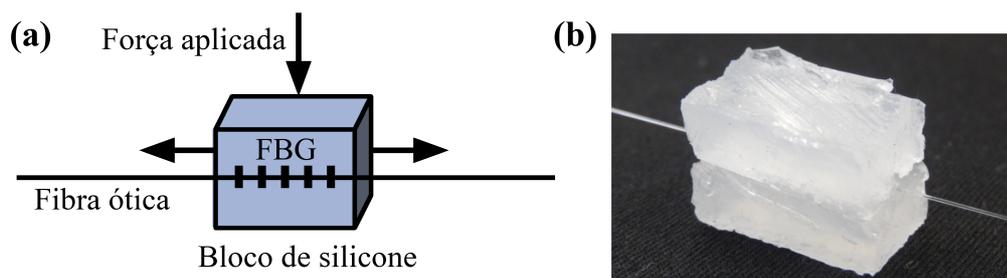


Figura 16: **(a)** Esquemático da cabeça sensora, composta por uma FBG encapsulada em um bloco retangular de silicone e **(b)** foto da cabeça sensora. A aplicação transversal de uma força resulta na tração longitudinal da fibra na qual a rede foi gravada.

O encapsulamento permite o controle da sensibilidade da cabeça sensora pela variação das dimensões do bloco de silicone, podendo ser adaptado a diferentes aplicações.

A construção das cabeças sensoras é dividida em três etapas. Na primeira etapa, um molde em forma de paralelepípedo com 30 cm de comprimento, 1,5 cm de altura e 1,5 cm de largura foi preenchido com o silicone. Na segunda etapa, o bloco de silicone curado foi cortado ao longo do comprimento em blocos secundários menores com aproximadamente 0,5 cm de comprimento. Na terceira etapa, os segmentos de fibra contendo as FBGs foram posicionadas entre as duas metades dos blocos secundários que em seguida foram unidas com a aplicação de uma camada adicional de silicone. As FBGs foram posicionadas aproximadamente no centro de cada bloco secundário. As cabeças sensoras resultantes têm a forma de um bloco retangular com aproximadamente 1,0 cm de altura, 1,5 cm de comprimento e 1,5 cm de largura.

As cabeças sensoras fabricadas foram numeradas de 1 a 12, de acordo com a ordem crescente dos comprimentos de onda. As cabeças sensoras foram concatenadas em série formando dois conjuntos, contendo 6 cabeças cada. Estes conjuntos foram posicionados entre duas placas de aço quadradas com 27 cm de lado e 0,6 mm de espessura, seguindo a disposição mostrada na Figura 17.

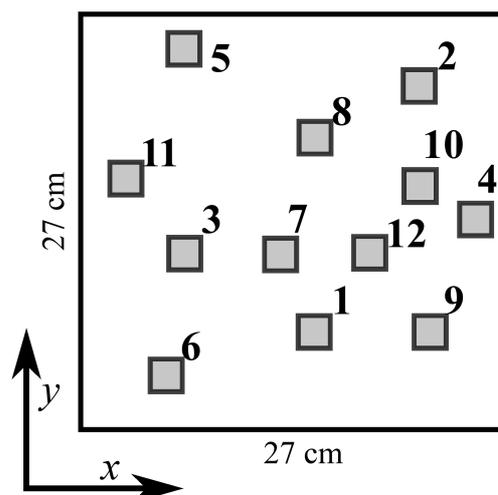


Figura 17: Esquemático (visão superior) do sistema de sensoriamento distribuído. Os quadrados preenchidos representam as cabeças sensoras, identificadas por seu número.

A aquisição de dados foi realizada da mesma forma que para o primeiro sistema (Figura 13, descrito na Seção 3.1.1), mas utilizando um acoplador 2x2 para a conexão dos dois conjuntos de cabeças sensoras. O experimento foi realizado em uma sala com a temperatura controlada em  $(24,0 \pm 0,5) ^\circ\text{C}$ .

### 3.2.2 Estimação da posição da carga

Uma força aplicada pontualmente sobre a placa superior resulta na deformação da placa e no desvio em comprimento de onda da posição da ressonância das FBGs. Estes desvios dependem da sensibilidade das cabeças sensoras e proximidade destes com a posição de aplicação da força. Os deslocamentos são medidos com relação à posição inicial em comprimento de onda das FBGs.

O aprendizado da relação entre estes deslocamentos em comprimento de onda e a posição da carga é realizado por duas SVRs com *kernel* RBF. As SVRs foram treinadas de forma que uma delas estime a posição da força no eixo  $x$  e outra no eixo  $y$ . As SVRs utilizaram os deslocamentos de comprimento de onda padronizados (transformados para ter média zero e variância unitária) como entrada, tendo como alvo a posição da carga no respectivo eixo.

Os dados experimentais foram obtidos com a colocação de um cilindro de cobre com massa igual a 500 g em diferentes posições da placa. Para concentrar a carga, o cilindro foi posicionado acima de um cilindro de plástico com massa desprezível, com diâmetro de 1 cm. Estes dados foram divididos em conjuntos e utilizados para o treinamento, validação e teste das SVRs. Os dados correspondem às respostas das 12 cabeças sensoras quando da aplicação da carga em 41 posições distintas na superfície da placa, conforme visto na Figura 18, concentrados em um quadrado central de 20 cm de lado.

Detalhadamente, a carga foi posicionada nas interseções de uma grade quadriculada com 5 cm de lado desenhada sobre a placa (total de 25 posições), e no centro das células da grade (mais 16 posições). A resposta das cabeças sensoras foi medida 5 vezes em condições de precisão intermediária em cada posição, resultando em 205 aquisições de dados.

As aquisições foram divididas em conjuntos de dados distintos, sendo que aproximadamente 70 % das aquisições foram escolhidas aleatoriamente e utilizadas na etapa de treinamento e validação, enquanto que as aquisições remanescentes foram reservadas para a etapa de teste. Os parâmetros das SVRs ( $\gamma$  e  $C$ ) foram determinados por meio de validação cruzada (estratégia *leave one out*), sem o uso do conjunto de teste. Assim como no primeiro sistema, foram utilizados como métricas o erro absoluto no eixo  $x$ , o erro absoluto no eixo  $y$  e o erro Euclidiano. A biblioteca *libsvm* foi utilizada para o treinamento das SVRs (CHANG; LIN, 2011).

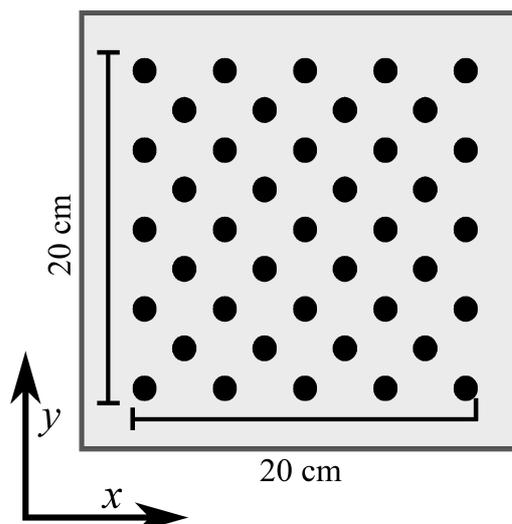


Figura 18: Diagrama dos pontos de aplicação de carga sobre a placa utilizados para obter a amostragem da resposta do sistema, onde cada círculo representa um ponto de medição.

### 3.2.3 Resultados

A Figura 19 mostra as curvas de resposta das cabeças sensoras medidas com a remoção de uma carga de 500 g da posição central da placa. Todos apresentam um tempo de resposta menor que 0,3 s (mudança de 90% para 10% na amplitude do sinal).

A Tabela 4 mostra a resposta média e máxima das cabeças sensoras ao longo do experimento, valores que estão relacionados com a sensibilidade das mesmas à carga aplicada, atentando-se ao fato desta sensibilidade ser dependente da posição de aplicação da carga. As cabeças sensoras apresentaram sensibilidades médias (média da resposta obtida durante os experimentos, dividida pela carga aplicada) de 18 pm/kg até 114 pm/kg. Esta diferença na sensibilidade média existe devido ao posicionamento das cabeças sensoras na placa, considerando a sua distância às demais cabeças e a sua proximidade ao centro da placa, e as diferenças resultantes do processo de encapsulamento impreciso. Desta forma, a sensibilidade individual das cabeças sensoras depende da configuração do sistema como um todo.

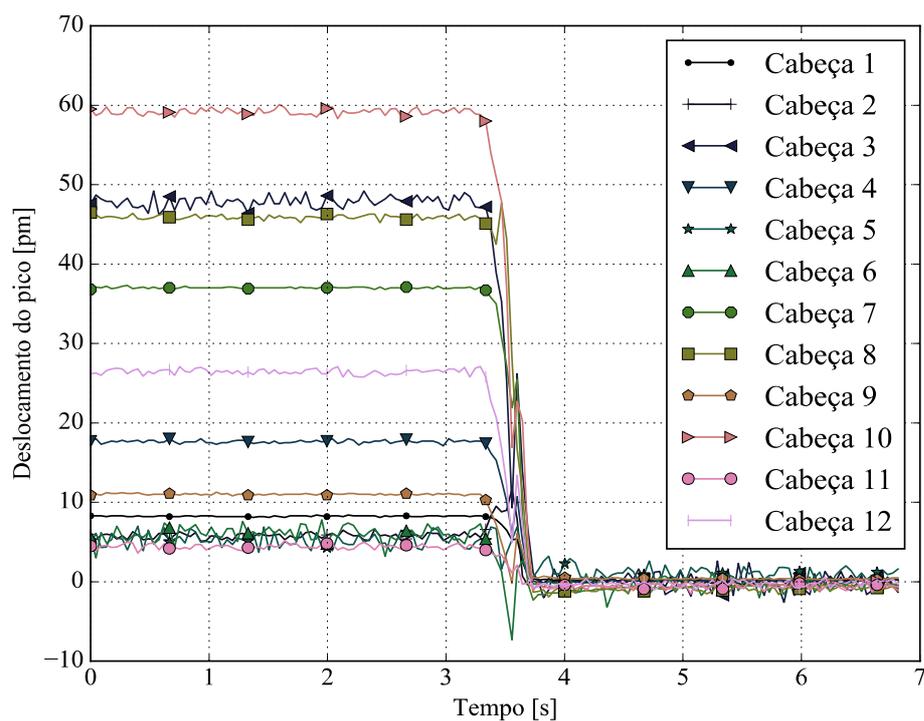


Figura 19: Resposta dos transdutores à remoção de uma carga de 500 g do centro da placa.

Tabela 4: Resposta das cabeças sensoras utilizadas durante os experimentos.

Cabeça sensora	$\Delta \lambda_b$ [pm]	
	Médio	Máximo
1	11	57
2	39	253
3	47	167
4	30	147
5	31	168
6	24	109
7	15	39
8	57	202
9	23	143
10	56	154
11	9	45
12	14	40

A Tabela 5 mostra os erros calculados seguindo as três métricas de erros adotadas, com seus valores médios e os correspondentes desvios padrão amostrais.

Tabela 5: Erros médios (e desvios padrão amostrais) obtidos com o conjunto de dados de teste.

<b>Métrica de erro</b>		
<b>Erro absoluto no eixo <math>x</math></b>	<b>Erro absoluto no eixo <math>y</math></b>	<b>Erro Euclidiano</b>
(1,55 ±1,42) mm	(1,35 ±1,21) mm	(2,29 ±1,56) mm

Durante o processo de validação cruzada observou-se que a remoção dos dados da cabeça sensora 12 causou uma diminuição no erro Euclidiano, portanto a resposta desta cabeça sensora deixou de ser utilizada. No entanto, a presença do bloco de silicone correspondente à cabeça sensora 12 continuou influenciando a resposta das outras 11 cabeças. Entre os fatores que contribuíram no erro, encontra-se a variação de temperatura do ambiente, estimada em 0,5 °C. Esta variação equivale aproximadamente a um deslocamento de 5 pm na ressonância das FBGs, calculada a partir da sensibilidade média de uma FBG em 1550 nm (KERSEY et al., 1997).

O erro Euclidiano obtido com o conjunto de teste foi interpolado e mostrado na Figura 20. A interpolação foi realizada para facilitar a visualização. Os resultados mostram que existem duas regiões onde o erro registrado foi consideravelmente maior do que o erro médio: na região próxima das coordenadas  $x=10$  e  $y=5$  cm e na região próxima de  $x=15$  e  $y=20$  cm. Ambas as regiões estão localizadas entre cabeças sensoras, sem estar imediatamente acima de nenhuma cabeça, o que está relacionado ao erro relativamente elevado registrado.

Com este segundo sistema, obteve-se um erro Euclidiano médio correspondente a 0,81 % da diagonal da área monitorada, o que constitui uma melhoria perante o primeiro sistema (que obteve um erro igual a 1,37 %). Os principais fatores que contribuíram com esta redução do erro são o uso de um maior número de cabeças sensoras e o uso de um maior conjunto de dados para treinamento. Também foi obtida uma redução no tempo de resposta, de 0,6 s para 0,3 s, principalmente devido ao encapsulamento das FBGs.

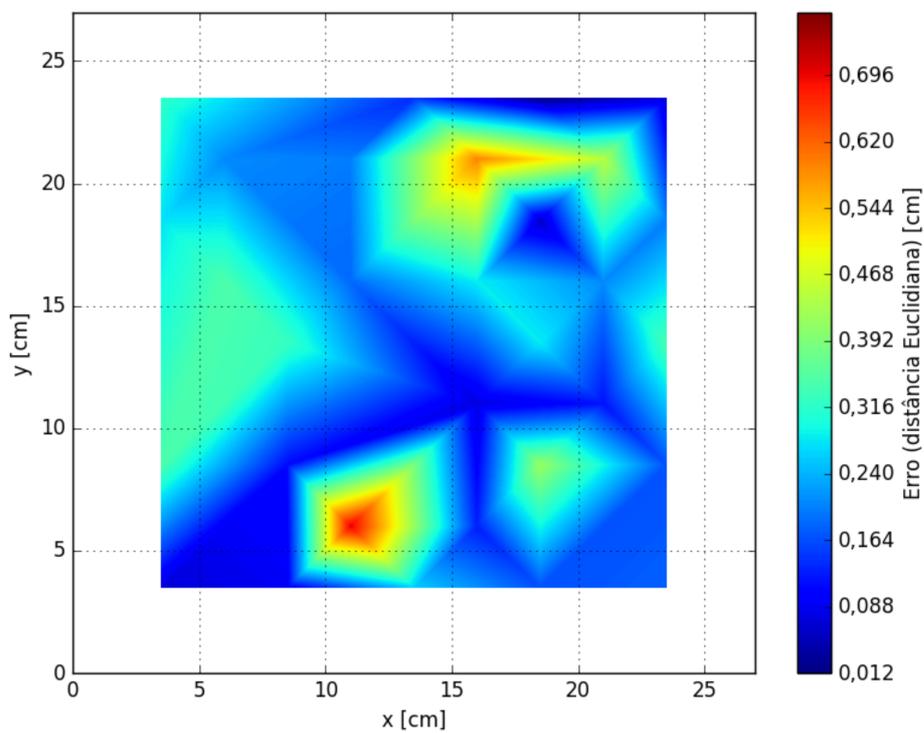


Figura 20: Estimativa do mapa do erro Euclidiano, calculada com a interpolação dos dados experimentais para a região central da placa.

## CAPÍTULO 4

### SISTEMA DE MAPEAMENTO DE FORÇAS COM RESOLUÇÃO APERFEIÇOADA

Neste capítulo são apresentadas duas versões de sistema para detecção de forças atuantes simultaneamente em múltiplas posições de uma placa. O sistema é composto por um conjunto de cabeças sensoras fixadas abaixo de uma placa de metal, sendo o número de FBGs menor do que o número de regiões mapeadas. Na primeira versão, as cabeças sensoras são formadas por FBGs posicionadas em anéis de ferro, enquanto que na segunda versão as FBGs foram encapsuladas em blocos de silicone (como apresentado na Seção 3.2.1).

A fim de contornar a subdeterminação do sistema foram empregados e comparados métodos de reconstrução utilizando regularização e a teoria de sensoriamento compressivo (Seção 1.2.1).

Os sistemas apresentados aqui diferem dos apresentados no Capítulo 3 por detectarem múltiplas forças aplicadas simultaneamente em posições diferentes da placa, que foi dividida em um número finito de áreas, enquanto que no Capítulo 3 os sistemas detectam um único ponto de aplicação e trabalham em um espaço contínuo.

#### 4.1 PRIMEIRA VERSÃO

Esta seção descreve o desenvolvimento e a avaliação da primeira versão do sistema de mapeamento de forças.

##### 4.1.1 Cabeças sensoras

Um conjunto de cabeças sensoras foi desenvolvido para a medição de forças aplicadas pontualmente. Cada cabeça sensora é composta por uma FBG encapsulada em um anel de ferro com diâmetro externo de 18 mm, espessura de 0,5 mm e largura de 5 mm. Na montagem

da cabeça sensora a fibra ótica contendo a FBG passa por dois furos com diâmetro de 0,8 mm posicionados nas paredes do anel em posições diretamente opostas, como visto na Figura 21. Após posicionar a FBG no centro do anel, esta é submetida a um estiramento inicial, e em seguida é fixada nas paredes do anel com cola de cianoacrilato.

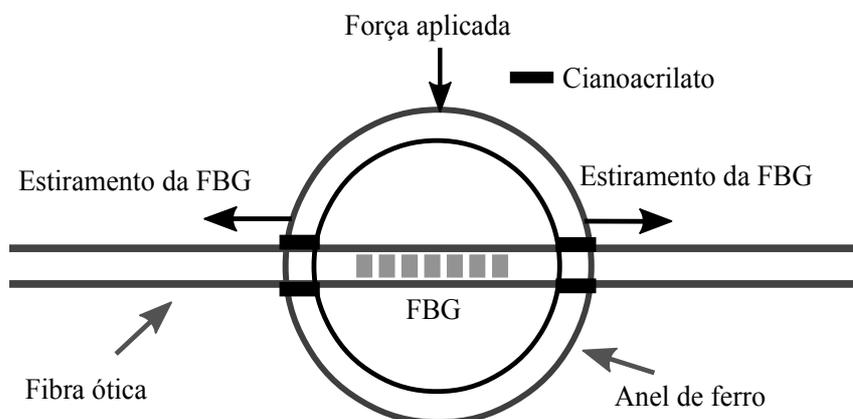


Figura 21: Cabeça sensora composta por um anel de ferro e uma FBG. O anel faz com que uma força aplicada perpendicularmente à FBG cause uma deformação no anel, que por sua vez realiza o estiramento uniforme da FBG.

As FBGs foram gravadas no Núcleo de Dispositivos Fotorrefrativos da UTFPR pela técnica de iluminação direta de uma máscara de fase com um laser de excímero KrF (Xantos XS-Coherent) em 248 nm. Para permitir a multiplexação em comprimento de onda dos transdutores no sistema de mapeamento, sete diferentes máscaras de fase foram usadas para gravar as sete FBGs com comprimentos de Bragg em 1521,15 nm, 1538,83 nm, 1541,05 nm, 1544,32 nm, 1551,01 nm, 1556,38 nm e 1564,75 nm. As FBGs possuem baixa refletância (< 10%) e comprimentos próximos de 0,25 mm.

Uma força externa aplicada sobre o anel irá deformá-lo, aumentando o seu diâmetro na direção perpendicular a força, conforme mostrado na Figura 21. Esta deformação resulta no estiramento longitudinal adicional da FBG que desloca o comprimento de onda de ressonância para maiores valores. Uma diminuição da força aplicada sobre o anel irá gerar um retorno do comprimento de ressonância da FBG à posição inicial. O deslocamento em comprimento de onda produzido durante e após a aplicação da força é utilizado como resposta da cabeça sensora.

#### 4.1.2 Configuração do sistema de sensoriamento de forças

Um diagrama do sistema experimental usado no sensoriamento e mapeamento de forças é apresentado na Figura 22. As sete cabeças sensoras e outros cinco anéis usados somente para suporte foram colados com cola de cianoacrilato em uma das superfícies de uma placa quadrada de aço, com lado de 27 cm.

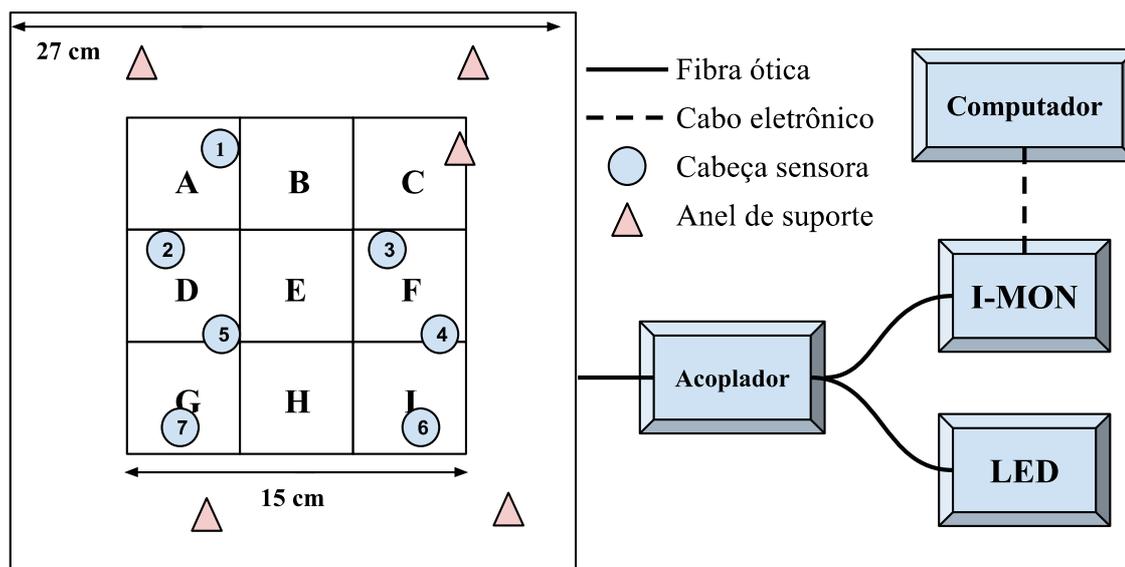


Figura 22: Representação da placa construída (vista do topo). As 9 regiões identificadas, de A até I, foram demarcadas uniformemente no quadrado com 15 cm de lado centralizado na placa. As posições aproximadas das cabeças sensoras e dos anéis de suporte são identificadas pelos círculos e triângulos.

O encapsulamento da FBG no anel garante que cada cabeça sensora possua uma reduzida área de contato com a placa. Assim, as forças aplicadas sobre a placa são transferidas para a FBG por meio deste único ponto de contato. O mesmo não aconteceria se a FBG fosse colada diretamente na placa. O mapeamento das forças foi realizado dentro de uma região quadrada central da placa com 15 cm de lado dividida em 9 regiões menores de lado igual a 5 cm. Este número de regiões foi mantido durante os experimentos realizados neste trabalho, porém a metodologia pode ser aplicada para diferentes proporções entre o número de regiões e de transdutores.

A Figura 23 mostra uma visão lateral da placa de aço com as cabeças sensoras coladas abaixo nas posições identificadas na Figura 22. O excesso de fibra ótica entre as cabeças sensoras evita que o estiramento em uma FBG afete o estiramento nas FBGs vizinhas. Apesar

disto, a colocação de uma carga (como visto na Figura 23) resulta na aplicação de forças em todos as cabeças sensoras (resposta acoplada). A placa e o conjunto de cabeças sensoras é apoiada em uma superfície lisa e rígida. Esta figura é uma representação parcial, evidenciando que a colocação de uma carga na placa altera o estiramento no conjunto de FBGs, sendo que não existe relação entre o posicionamento das cabeças sensoras com as áreas demarcadas para a colocação de cargas.

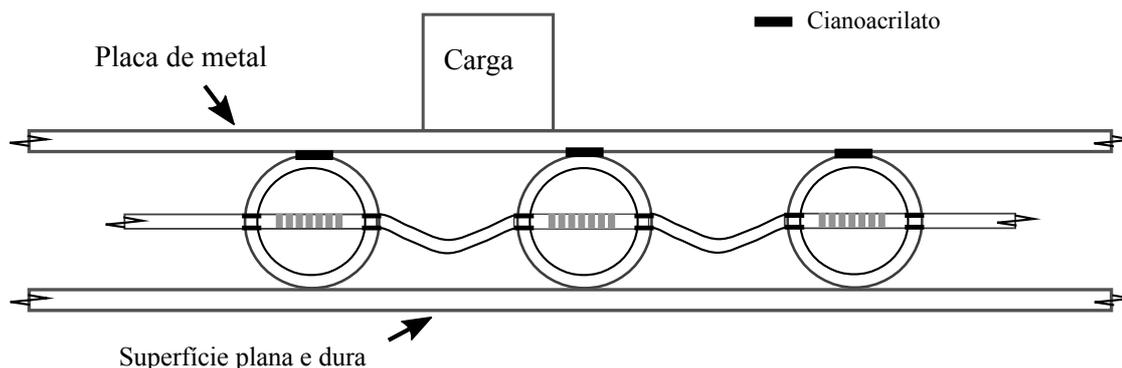


Figura 23: Vista lateral (parcial) da placa de aço com a colagem de cabeças sensoras. Uma carga posicionada na placa de aço resulta na alteração do estiramento prévio na FBG de cada cabeça sensora.

As sete FBGs foram emendadas em uma única fibra iluminada por um LED (Superlum PILOT 2 LED, centrado a 1558,2 nm com largura à meia altura de 73,8 nm). A luz refletida pelas FBGs é detectada utilizando o interrogador I-MON 512E (Ibsen I-MON E512, resolução  $< 0,5$  pm). Os espectros adquiridos são enviados para um computador, onde as etapas de detecção de picos e de estimação das forças são realizadas. Esta configuração experimental pode ser visualizada na Figura 22.

A presença de uma carga em qualquer uma das regiões causa o deslocamento no comprimento de onda de Bragg das sete cabeças sensoras, ou seja, a resposta do sistema é acoplada. No entanto, esses deslocamentos dependem da posição relativa entre a cabeça sensora e o ponto de aplicação da força. Esta resposta acoplada é essencial para a reconstrução do sinal (solução do problema inverso) quando se tem um número de regiões maior do que o número de cabeças sensoras.

Os deslocamentos de comprimento de onda são medidos a partir de uma leitura de referência tomada antes da colocação de cargas na placa. Para evitar efeitos de sensibilidade

cruzada na operação dos transdutores, os experimentos foram realizados em ambiente com temperatura controlada de  $(22,0 \pm 0,5)$  °C.

#### 4.1.3 Método para o mapeamento de forças utilizando sensoriamento compressivo

A força aplicada em cada uma das regiões é representada pelo vetor coluna  $x$ , contendo  $n$  elementos correspondentes a cada uma das regiões. As leituras do sistema são realizadas obtendo um espectro de referência quando não há nenhuma força aplicada na placa (todos os elementos de  $x$  são iguais a zero), e então adquirindo um espectro após a aplicação das forças na placa (em regime estático). O deslocamento dos comprimentos de onda de pico obtido entre estas duas aquisições é calculado, originando o vetor coluna de observações  $y$  com  $m$  elementos. A determinação dos comprimentos de onda de pico é realizada ajustando uma gaussiana para a reflexão de cada cabeça sensora.

Utilizando uma carga conhecida, pode-se obter a matriz de sensoriamento  $A$  ( $m$  por  $n$ ) experimentalmente ao medir o deslocamento dos comprimentos de onda de pico ao colocar a carga em cada região. A cada posicionamento, determina-se uma coluna da matriz  $A$ , que é preenchida com a sensibilidade (relação entre o deslocamento em comprimento de onda obtido em cada cabeça sensora pela massa da carga utilizada) registrada no posicionamento.

Num caso ideal onde a resposta das cabeças sensoras é linear, onde não há ruído e o número de cabeças sensoras ( $m$ ) é igual ao número de regiões ( $n$ ), é possível recuperar a força aplicada em qualquer uma das regiões (vetor coluna  $x$ ) a partir da solução do sistema linear  $Ax=y$ . No entanto, a aplicação de um sistema com estas características exige a disponibilidade de um grande número de cabeças sensoras ideais e de um sistema de medição sem ruído, implicando em dificuldades de implementação.

Quando o número de cabeças é menor do que o número de regiões, o sistema resultante é subdeterminado e não caracteriza um problema bem-posto. Uma das formas de contornar este problema está no uso de regularização para melhorar o condicionamento. Dentre os métodos existentes, foram aplicados e comparados dois para a determinação da força (vetor  $x$ ): o método de regularização de Tikhonov e o método de Lasso.

#### 4.1.4 Metodologia de avaliação

Apesar das FBGs apresentarem tipicamente uma resposta linear em relação ao seu estiramento, não se pode afirmar o mesmo do sistema sensor, pois as respostas das cabeças sensoras dependem das propriedades dos anéis metálicos utilizados e também das deformações realizadas na placa, além de outros fatores como o suporte da placa. Portanto, diferentes experimentos foram realizados para avaliar o desempenho do sistema. Numa primeira etapa foi obtida a resposta ao estiramento longitudinal da FBG (não encapsulada). Em seguida, avaliou-se a sua resposta ao ser encapsulada em um anel. Outros testes avaliaram a repetibilidade e a linearidade do sistema completo (placa instrumentada com as cabeças sensoras) a forças aplicadas em diferentes posições da placa. Para tanto, pesos de precisão foram usados para exercer forças sobre a placa. Cada etapa seguiu procedimentos específicos:

**Sensibilidade da FBG (elemento transdutor)** – Avaliada estirando uma FBG semelhante às utilizadas nos transdutores com um sistema controlado por meio de um parafuso micrométrico.

**Sensibilidade da cabeça sensora** – Avaliada pela resposta do transdutor composto por uma FBG encapsulada no anel de ferro a forças aplicadas ao longo do seu diâmetro. A caracterização foi realizada aplicando forças de 0,01 kgf, 0,02 kgf, 0,05 kgf, 0,1 kgf e 0,2 kgf sobre o anel e detectando o deslocamento no comprimento de onda de Bragg da FBG.

**Repetibilidade** – Fornecida pela precisão do sistema obtida com a medição da resposta das cabeças sensoras em condições de repetibilidade. Para tanto, as respostas das sete cabeças a uma força de 0,2 kgf aplicada no centro da placa (região E indicada na Figura 22) foram medidas durante 20 s sendo a medição repetida seis vezes utilizando uma taxa de aquisição próxima de 5 Hz, com um tempo de espera de 20 s entre cada medição.

**Linearidade** – A linearidade do sistema foi avaliada quanto às propriedades de aditividade e de homogeneidade. A avaliação da propriedade de aditividade foi realizada submetendo o sistema a forças de 0,1 kgf, 0,1 kgf e 0,2 kgf aplicadas tanto individualmente quanto simultaneamente nas regiões A, G e I da Figura 22. O resultado esperado para um sistema linear é que o somatório das respostas obtidas com a aplicação individual de cada força seja igual à resposta obtida com a aplicação simultânea das três forças. A avaliação foi

realizada medindo a resposta de cada cabeça sensora. Para a avaliação da homogeneidade, forças de 0,05 kgf, 0,1 kgf e 0,2 kgf foram aplicadas, individualmente, no centro da placa. Em um sistema linear, a resposta das cabeças sensoras deve ser proporcional à força aplicada.

**Recuperação do sinal** – A capacidade de recuperação da configuração de forças aplicadas sobre o sistema foi avaliada em 30 medições realizadas para amostrar a resposta dos transdutores acoplados à placa. Cada medição corresponde a uma configuração com três forças (0,2 kgf, 0,1 kgf e 0,1 kgf) aplicadas simultaneamente sobre a placa em posições distintas aleatórias. O uso de três cargas para nove regiões torna o vetor  $x$  esparso, um requisito para a aplicação de sensoriamento compressivo. A relação sinal/ruído (SNR) foi avaliada para cada um dos métodos de reconstrução. A SNR foi calculada conforme a Equação 35:

$$SNR = 20 \log_{10} \left( \frac{\|x_0\|}{\|x - x_0\|} \right) \quad (35)$$

onde  $x_0$  é o vetor contendo a força real conhecida e  $x$  é o vetor contendo a força estimada. Nota-se que a Equação 35 calcula efetivamente a relação do sinal com o erro de reconstrução. Manteve-se a nomenclatura de SNR para concordar com a literatura da área (KREUTZ-DELGADO et al., 2003)

#### 4.1.5 Resultados

As FBG usadas apresentam sensibilidade ao tracionamento próxima de  $1,22 \text{ pm}/\mu\epsilon$ . Os resultados do teste da sensibilidade das cabeças sensoras à aplicação de cargas podem ser vistos na Figura 24. A cabeça sensora apresentou sensibilidade de  $6,23 \text{ nm/kgf}$  com linearidade em unidade de força de  $0,013 \text{ kgf}$  calculada pelo maior desvio dos pontos experimentais com relação a reta ajustada.

No entanto, a sensibilidade das cabeças sensoras depende também da configuração do sistema, isto é, das dimensões da placa, do posicionamento das cabeças sensoras e dos anéis de apoio e da posição de aplicação da força. Sendo assim, a faixa dinâmica do sistema pode ser sintonizada pela escolha adequada do número de anéis usados para apoio. Quanto maior este número, maior é a distribuição da força aplicada entre os anéis, conseqüentemente, a faixa de operação do sistema é desviada para maiores valores de força. Esta escolha deve

levar em conta a faixa dinâmica de operação das cabeças, considerando a menor separação em comprimento de onda entre as ressonâncias das FBGs. Contudo, o aumento do número de anéis de apoio torna mais difícil a tarefa de nivelar todos os anéis, introduzindo assim não-linearidades nas respostas dos transdutores.

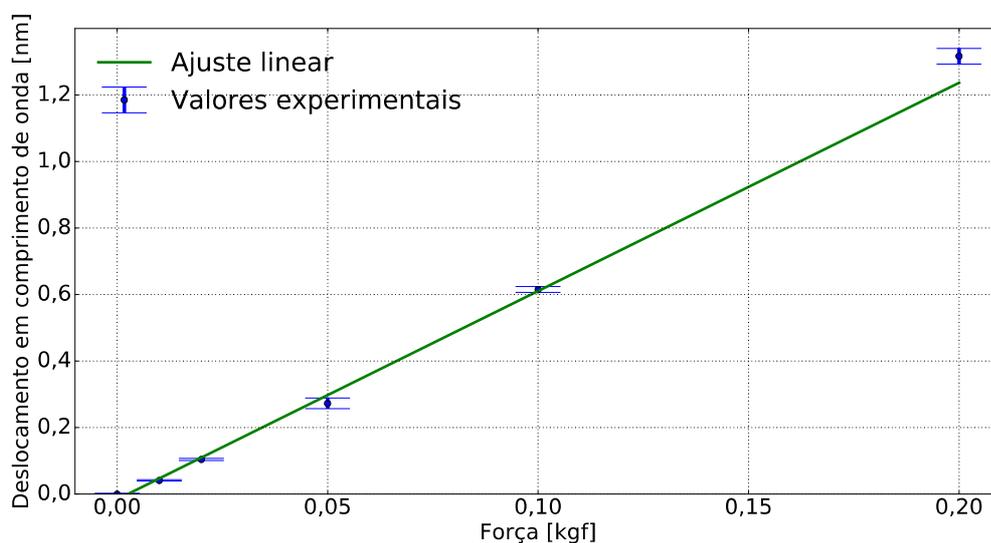


Figura 24: Deslocamento do comprimento de onda de uma cabeça sensora em relação à força aplicada.

Os resultados do teste de repetibilidade do sistema podem ser vistos na Figura 25, que mostra o deslocamento dos comprimentos de onda de cada cabeça sensora, que resulta de uma força de 0,2 kgf aplicada na posição central da placa.

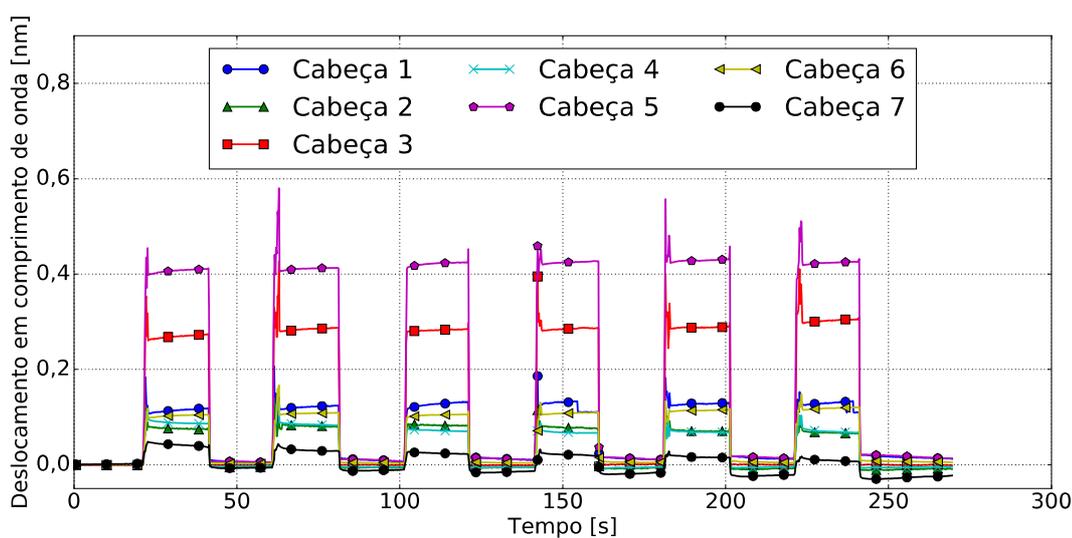


Figura 25: Resultados do experimento de repetibilidade.

Os resultados do teste de repetibilidade mostram que a variação no sinal resultante da aplicação/remoção de uma força aplicada sobre a placa persiste por dezenas de segundos. Este comportamento gera os valores negativos no gráfico quando a força deixa de ser aplicada sobre a placa. A aquisição de um novo sinal de referência após a remoção das cargas pode reduzir o problema parcialmente, compensando também as alterações causadas por variações de temperatura.

Os resultados dos testes de linearidade são apresentados nas Figuras 26 e 27. Quanto ao teste da propriedade de aditividade, os resultados são mostrados no gráfico da Figura 26. Os círculos representam o desvio no comprimento de onda Bragg de cada cabeça sensora quando três forças são aplicadas simultaneamente ao sistema, enquanto que as barras correspondem aos desvios medidos quando as forças são aplicadas isoladamente. As cabeças sensoras 1, 2, 4, 6 e 7 apresentaram um erro menor do que 6% do valor alvo. O erro foi calculado pela diferença entre o somatório dos deslocamentos em comprimento de onda resultantes das forças individuais e deslocamento de onda resultante da aplicação simultânea da 3 forças. Os piores resultados foram obtidos com as cabeças sensoras 3 e 5, onde os erros foram de 30% e 14%, respectivamente. Este resultado tem como causa as curvaturas não controladas da placa e as pequenas variações observadas nos diâmetros dos anéis, que afetaram o contato entre as cabeças sensoras e a superfície de apoio do sistema.

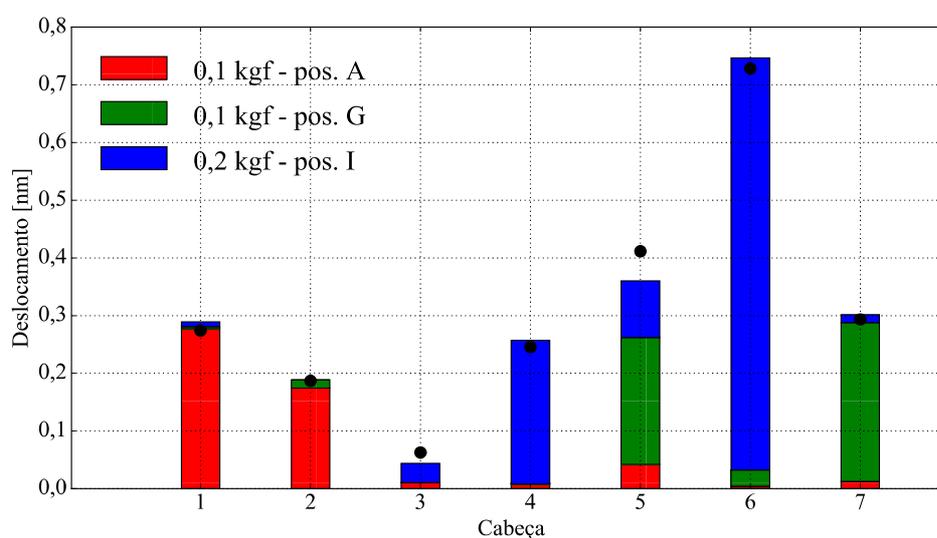


Figura 26: Resultados do teste da propriedade de aditividade para cada cabeça sensora. Os círculos representam as respostas das cabeças sensoras às forças aplicadas simultaneamente, enquanto que as barras representam as respostas das cabeças sensoras às cargas aplicadas individualmente.

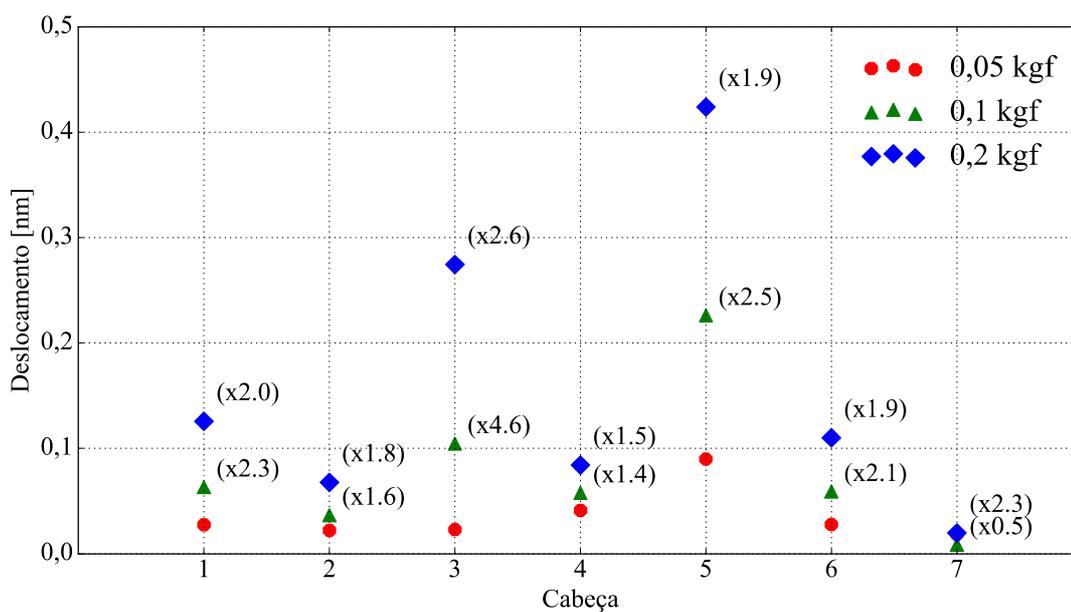


Figura 27: Resultados do teste de homogeneidade para cada cabeça sensora. Forças de 0,05 kgf, 0,1 kgf e 0,2 kgf foram aplicadas, individualmente, no centro da placa.

Os resultados referentes ao teste de homogeneidade são mostrados na Figura 27 onde os círculos representam o deslocamento no comprimento de onda de Bragg de cada cabeça sensora para cada uma das forças aplicadas no centro da placa. A relação entre os deslocamentos sucessivos experimentados por cada cabeça sensora foi marcada ao lado dos símbolos.

No teste de homogeneidade, foram medidos erros que variaram de 16% (cabeças 1 e 5) até 230% (cabeças 3 e 7) do valor esperado, sendo que os maiores erros ocorreram para as menores forças (50 g e 100 g). Estes erros evidenciam que existe uma pequena variação no diâmetro dos anéis. Esta diferença no diâmetro faz com que alguns anéis não estejam em contato prévio com a superfície de apoio da placa, passando a responder somente com a aplicação de uma força capaz de deformar a placa o suficiente para encostá-lo na superfície de apoio. A Tabela 6 mostra os resultados da reconstrução da configuração de forças aplicadas sobre a placa, obtidos com os métodos de regularização de Tikhonov e de Lasso. Os mesmos resultados foram agrupados em histogramas na Figura 28, permitindo a comparação do desempenho obtido com os algoritmos.

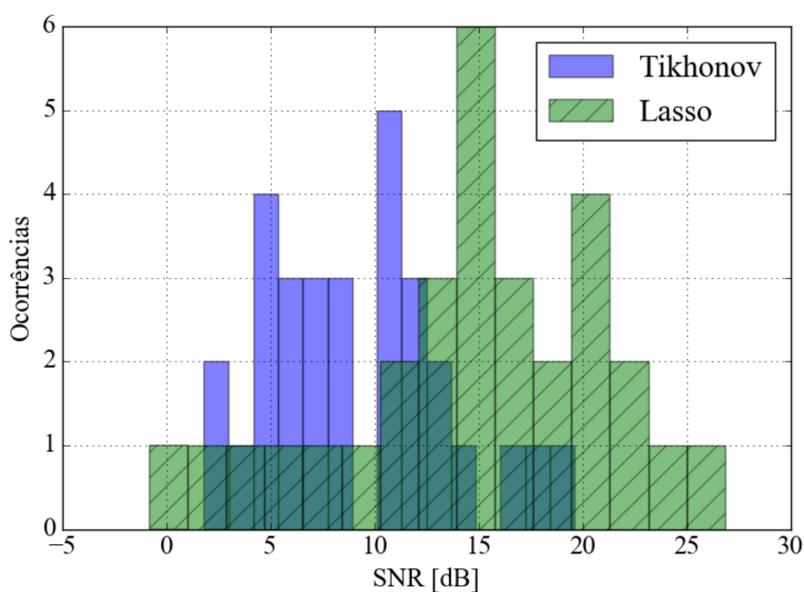


Figura 28: Resultados do experimento de reconstrução, comparando a qualidade das reconstruções obtidas utilizando o método de regularização de Tikhonov com as obtidas utilizando o método Lasso. Neste experimento foram utilizados 7 cabeças sensoras para 9 regiões.

Tabela 6: Resultado da reconstrução das 30 configurações para os métodos de Regularização de Tikhonov e Lasso. A posição das cargas é mostrada nas colunas 2,3 e 4, enquanto que o SNR obtido por cada método é visto nas colunas 5 e 6 (melhor resultado grifado).

Teste	Força de 0,2 kgf	Força de 0,2 kgf	Força de 0,1 kgf	SNR	
	(posição)	(posição)	(posição)	Tikhonov [dB]	Lasso [dB]
1	F	B	C	7,90	<b>10,70</b>
2	A	B	D	16,50	<b>18,10</b>
3	G	E	F	10,20	<b>15,60</b>
4	B	D	E	5,96	<b>16,40</b>
5	G	A	I	12,90	<b>21,00</b>
6	G	D	F	14,70	<b>22,00</b>
7	E	A	D	4,70	<b>8,49</b>
8	A	C	D	11,40	<b>19,90</b>
9	E	B	D	6,43	<b>16,00</b>
10	D	A	F	11,80	<b>20,30</b>
11	A	E	G	4,48	<b>7,66</b>
12	H	C	G	4,13	<b>12,20</b>
13	C	D	F	11,00	<b>13,90</b>
14	A	G	H	4,44	<b>14,40</b>
15	E	B	H	8,61	<b>17,10</b>
16	F	D	G	10,80	<b>14,70</b>
17	B	E	H	13,20	<b>15,70</b>
18	G	A	B	19,60	<b>26,80</b>
19	H	A	I	4,75	<b>12,20</b>
20	H	A	F	<b>1,83</b>	-0,791
21	H	A	C	2,31	<b>2,62</b>
22	F	A	E	<b>7,58</b>	5,19
23	I	A	G	10,30	<b>23,90</b>
24	C	A	H	<b>5,74</b>	4,40
25	G	B	I	8,58	<b>19,10</b>
26	H	B	E	7,69	<b>14,40</b>
27	A	B	C	12,40	<b>22,20</b>
28	G	A	D	17,60	<b>21,30</b>
29	F	E	G	10,60	<b>11,70</b>
30	I	D	F	7,53	<b>14,20</b>

Uma melhor visualização do que representa a métrica de SNR é fornecida pela Figura 29, que compara uma configuração de forças original a uma reconstrução com SNR próximo de 17 dB e outra com SNR próximo de 4 dB.

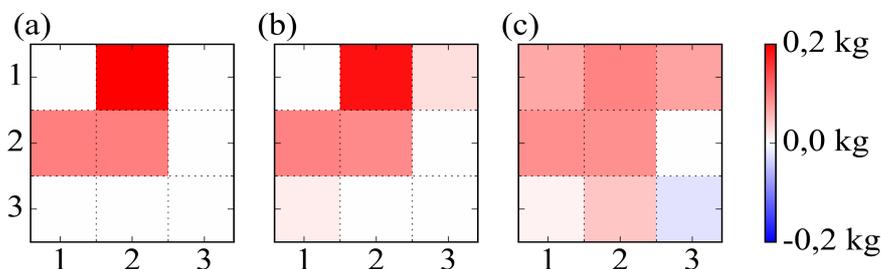


Figura 29: Exemplos de reconstrução do sinal. (a) Sinal original. (b) Reconstrução com SNR de 17 dB. (c) Reconstrução com SNR de 4 dB.

Apesar dos erros de linearidade do sistema, percebe-se com os resultados da Figura 28 que o método Lasso foi capaz de recuperar a configuração das forças com um SNR maior que 12 dB em 22 dos 30 casos testados (73,33%). O método por regularização de Tikhonov só conseguiu recuperar 7 casos entre os avaliados (23,33%) com um SNR maior que 12 dB, o que mostra que o método Lasso é mais adequado para a reconstrução nas condições deste experimento (sistema com resposta acoplada e com poucas regiões utilizadas simultaneamente).

Os experimentos de reconstrução foram repetidos para o método Lasso utilizando somente seis e cinco cabeças sensoras (descartando as cabeças de menor sensibilidade devido ao posicionamento, pela análise de resultados já obtidos). Para seis cabeças, a recuperação foi de 19 de 30 casos (63,33%), e para cinco a taxa caiu para 9 de 30 casos (30%).

## 4.2 SEGUNDA VERSÃO

Esta seção descreve a segunda versão do sistema de mapeamento de forças. Nesta nova versão alteraram-se as cabeças sensoras para melhorar a resistência mecânica do sistema. Além disto, foi proposto um novo método de reconstrução, que permitiu o aumento da relação de células monitoradas por cabeça sensora.

#### 4.2.1 Cabeças sensoras

As cabeças sensoras foram construídas pelo encapsulamento de FBGs em blocos de silicone, conforme visto na Seção 3.2.1 (vide Figura 16). As características do silicone fazem com que a cabeça sensora seja mais resistente (em comparação às cabeças sensoras propostas na Seção 4.1.1) a impactos.

As cabeças sensoras foram divididas em 2 grupos, sendo que cada grupo foi emendado em um mesmo cabo ótico.

#### 4.2.2 Configuração do sistema de sensoriamento de forças

A mesma placa da primeira versão do sistema (vista na Seção 4.1.2) foi utilizada. Entretanto, o número de cabeças sensoras aumentou de 7 para 8 e o número de regiões nas quais a placa foi dividida aumentou de 9 para 16. Além das 8 cabeças sensoras (identificadas pelos números de 1 a 8), foram utilizados 4 blocos de silicone adicionais para servirem como suporte.

A Figura 30 mostra a localização das cabeças sensoras, dos blocos de suporte e como a região de sensoriamento foi dividida. Cada região (identificada por uma letra de A até P) corresponde a um quadrado de 4 cm de lado, sendo que a área de sensoriamento da placa corresponde ao quadrado central de 16 cm de lado.

Os comprimentos de onda de Bragg das FBGs foram medidos após a instalação das cabeças sensoras no sistema, a  $18,0 \pm 0,5$  °C, sendo iguais a 1520,62 nm, 1528,98 nm, 1535,58 nm, 1537,57 nm, 1540,33 nm, 1544,15 nm, 1555,78 nm e 1559,15 nm, com FWHM (*full width at half maximum*, do inglês largura à meia altura) de aproximadamente 0,18 nm, refletância menor do que 10 % (FBGs fracas) e comprimento próximo de 2,5 mm. Nenhuma alteração foi detectada no valor de FWHM das FBGs com a aplicação de cargas, dentro da incerteza experimental (com o analisador de espectro ótico Anritsu MS9710B, resolução de 0,07 nm).

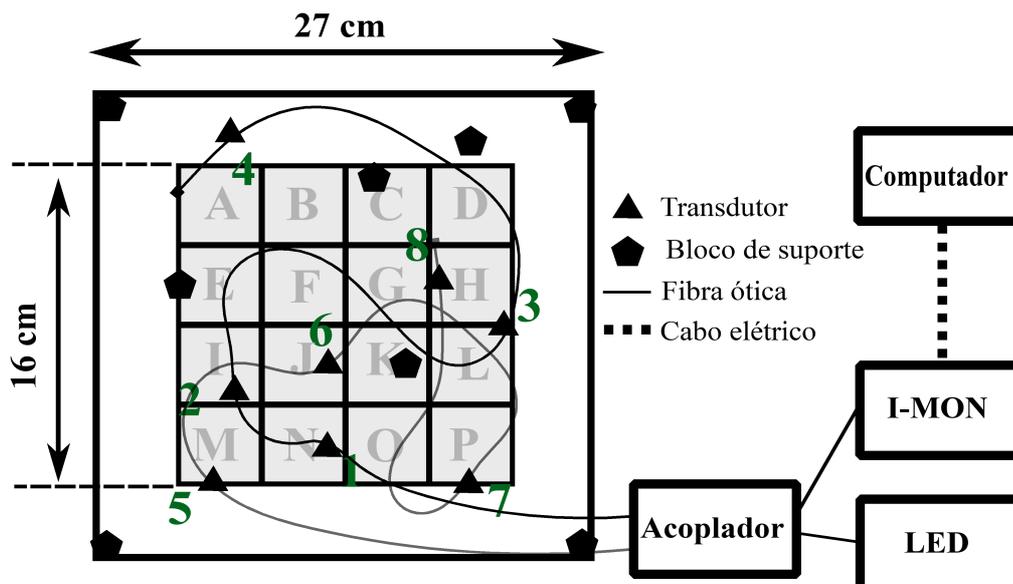


Figura 30: Esquemático do sistema de medição. À esquerda, visualiza-se a placa com a área de sensoriamento dividida em 16 células identificadas de A até P. As posições das cabeças sensoras são indicadas pelos triângulos numerados de 1 até 8, enquanto que os pentágonos representam os blocos de suporte. À direita, o sistema de interrogação é visualizado com cabos óticos (linhas contínuas) e cabo elétrico (linha tracejada).

O sistema de interrogação apresentado na Seção 4.1.2 foi utilizado para a leitura dos comprimentos de onda de Bragg das cabeças sensoras.

#### 4.2.3 Novo método para o mapeamento de forças utilizando sensoriamento compressivo e evolução diferencial

Nesta segunda versão foi proposto um novo método (nomeado SDE, do inglês *sparse differential evolution*) baseado em sensoriamento compressivo para a reconstrução das cargas aplicadas na placa. Ao invés de utilizar um termo de regularização para minimizar a norma  $l_1$ , o novo método buscou a minimização direta de uma aproximação da “norma”  $l_0$ . A nova formulação do problema de otimização é mostrada na Equação 36:

$$\begin{aligned} & \underset{x}{\text{minimizar}} && \|Ax - y\|_2^2 + \sigma \|x\|_p^p, \\ & \text{sujeito a} && 0 \leq x \leq ulimit \end{aligned} \quad (36)$$

onde  $p = 0,01$  e  $ulimit$  é o limite superior para o valor de cada carga. O valor de  $p$  foi escolhido experimentalmente (não é crítico, pode variar dentro desta ordem de magnitude).

Aqui, a norma  $l_p$  é utilizada para evitar os problemas de sensibilidade ao ruído apresentados pela “norma”  $l_0$  e para facilitar a convergência. No entanto, a minimização da norma  $l_p$  ainda é um problema intratável por métodos convencionais, como mostrado na Seção 2.3.1. Aqui, propõe-se o uso de DE para solucionar o problema de minimização proposto na Equação 36, devido às características de não utilizar a informação de gradiente e por realizar a otimização com uma população de soluções, reduzindo a probabilidade de estagnar em um ótimo local.

O método proposto utilizou o esquema *DE/rand/1/bin* com 150 indivíduos e um limite de 1500 iterações, com  $CR = 0,15$  e  $F = 0,8$ . A dimensão do problema corresponde ao número de células na placa ( $D = 16$ ). A função de *fitness* corresponde ao negativo da expressão a ser minimizada do problema mencionado na Equação 36 ( $-(\|Ax - y\|_2^2 + \sigma \|x\|_p^p)$ ), sendo que a restrição  $0 \leq x \leq ulimit$  é tratada limitando o espaço de busca do método e  $\sigma = 0,01$ . Os valores de  $CR$ ,  $F$  e  $\sigma$  foram determinados utilizando um conjunto de dados experimentais reservados (distintos dos dados de teste utilizados na avaliação do método).

Adicionalmente, uma estratégia de normalização da matriz de sensoriamento foi proposta para evitar a tendência da reconstrução em preferir as células mais próximas das cabeças sensoras com maior sensibilidade média. Sabendo que cada linha da matriz de sensoriamento  $A$  corresponde a uma cabeça sensora, pode-se calcular a sensibilidade média da cabeça sensora pela média dos valores absolutos de sua respectiva linha na matriz. A normalização é realizada pela divisão da linha da matriz que corresponde a cabeça sensora pela sensibilidade média calculada. A normalização da matriz  $A$  deve ser acompanhada da normalização das matrizes  $y$ , cujos elementos devem ser também divididos pela sensibilidade média da respectiva cabeça sensora.

#### 4.2.4 Metodologia de avaliação

A avaliação do sistema foi realizada seguindo a metodologia proposta na Seção 4.1.4, porém com diferenças nas cargas e posições de aplicação. Durante os experimentos, a

temperatura do ambiente foi mantida em  $18,0 \pm 0,5$  °C para evitar a sensibilidade cruzada das FBGs.

Para o teste de repetibilidade, uma carga com massa de 0,2 kg foi colocada no centro da região de sensoriamento por 20 s, e então retirada. Este procedimento foi repetido três vezes, com a espera de 20 s entre cada colocação. O espectro ótico foi lido com uma taxa de aquisição de 35 Hz neste experimento.

A propriedade de homogeneidade foi avaliada com a aplicação de uma sequência de cargas com massa crescente (0,01 kg, 0,02 kg, 0,05 kg, 0,1 kg, 0,2 kg e 0,5 kg) no centro da região de sensoriamento. Por sua vez, a propriedade da aditividade foi avaliada aplicando quatro cargas de massa igual a 0,1 kg nas células F, G, J, K, individualmente e depois em conjunto.

O teste de recuperação do sinal foi realizado aplicando 3 cargas simultâneas (0,2 kg, 0,1 kg e 0,1 kg) em células aleatórias. As aplicações foram repetidas 50 vezes, em posições distintas (um programa de computador foi escrito para escolher as posições e garantir que nenhuma fosse repetida). Este teste foi repetido com somente 2 cargas (0,2 kg e 0,1 kg) e uma carga (0,1 kg). O método proposto (SDE) foi comparado a outros métodos que podem ser aplicados na solução de sistemas lineares subdeterminados, sendo eles: Lasso (TIBSHIRANI, 1996), OMP (TROPPE; GILBERT, 2007), Robust-SL0 (EFTEKHARI et al., 2009) e CoSaMP (NEEDELL; TROPPE, 2009). Adicionalmente, o SDE foi avaliado com e sem o uso de *ulimit*, sendo que quando utilizado, foi configurado como 10% a mais do que a maior carga aplicada.

#### 4.2.5 Resultados

Os resultados do teste de repetibilidade podem ser observados nas Figuras 31 e 32, que mostram a variação dos comprimentos de onda de pico das cabeças sensoras ao longo do tempo. Na Figura 31 percebe-se que a aplicação repetida de uma carga em uma mesma posição produz resultados diferentes, devido a variações de temperatura localizadas, histerese e estiramento residual inerentes às propriedades elásticas das cabeças sensoras e da placa de metal. No entanto, estas variações percebidas nas aplicações repetidas estão no mesmo nível do ruído detectado no sinal, que é da ordem de unidades de pm.

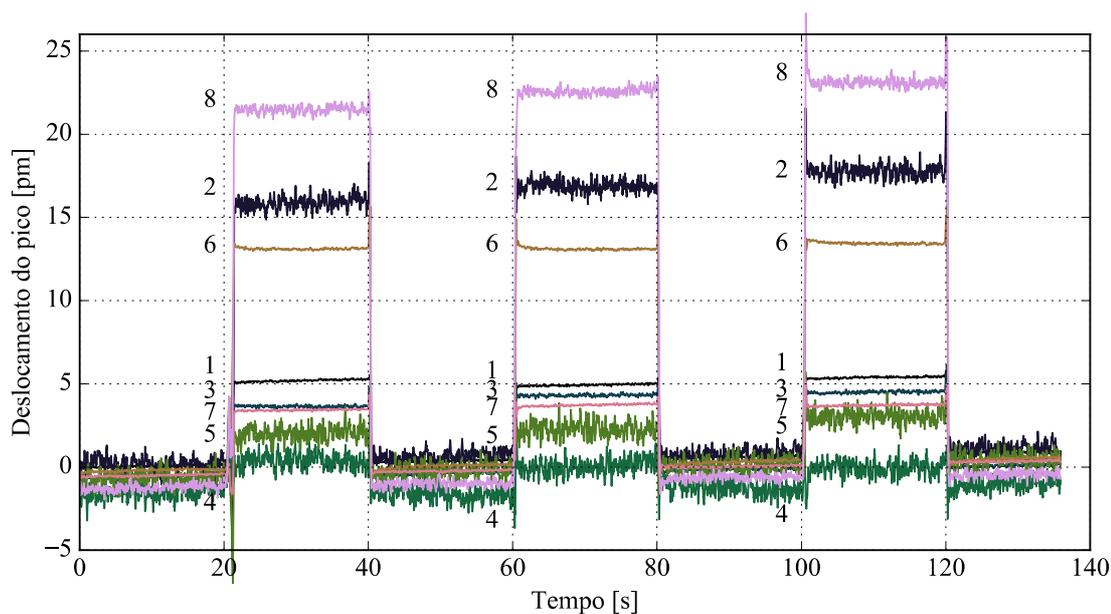


Figura 31: Resultados do teste de repetibilidade, mostrando os deslocamentos do comprimento de onda de pico das oito cabeças sensoras, identificadas pelos números de 1 até 8.

Percebe-se pela Figura 31 que a sensibilidade de uma cabeça sensora não depende somente da sua distância até o ponto de aplicação da carga, mas também no processo de encapsulamento e na proximidade da cabeça aos blocos de suporte.

A Figura 32 mostra os resultados do teste de repetibilidade no intervalo temporal de 80 s até 80,7 s, imediatamente após a remoção da carga do centro da placa, permitindo observar a resposta temporal do sistema. O tempo de descida, correspondendo ao tempo necessário para o sinal variar de 90% até 10% da sua intensidade máxima foi aproximadamente igual a 0,25 s para todas as cabeças sensoras. Nota-se que o tempo de resposta da cabeça sensora é maior do que o tempo de resposta característico de uma FBG (DAVIS et al., 2014), pois este é determinado pelas características mecânicas do bloco de silicone utilizado para encapsular as FBGs, além das características da placa de metal.

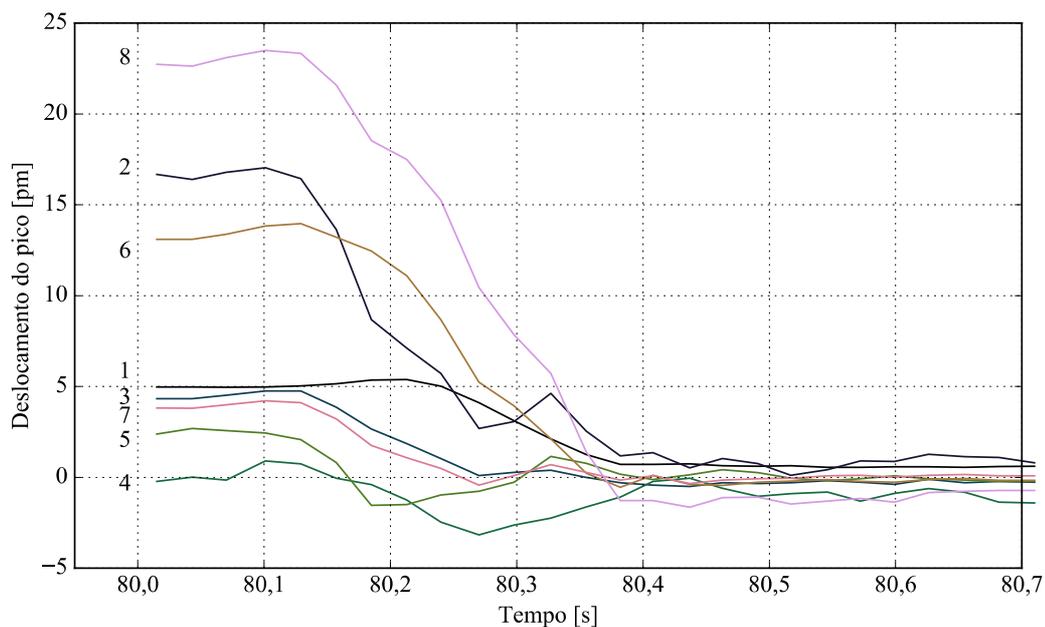


Figura 32: Resposta temporal do sistema imediatamente após a remoção da carga. Corresponde aos dados adquiridos durante o teste de repetibilidade, no intervalo de 80 s até 80,7 s.

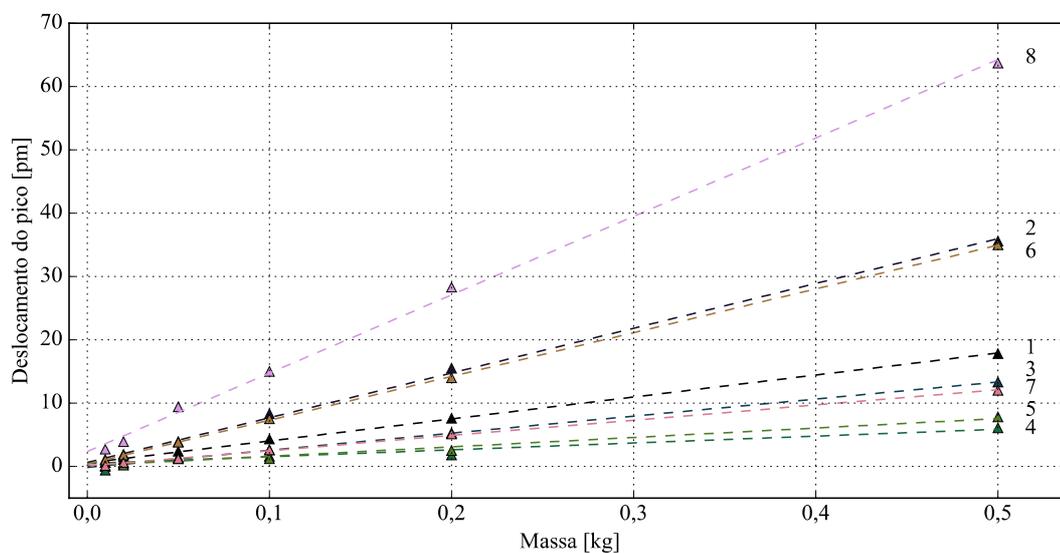


Figura 33: Resultados do teste de homogeneidade, mostrando a relação entre a massa da carga aplicada e o deslocamento do comprimento de onda de pico para cada cabeça sensora.

Os resultados do teste de homogeneidade podem ser visualizados na Figura 33. Foi realizado o ajuste de retas aos dados experimentais de cada cabeça sensora. Os ajustes para as cabeças 7 e 8 resultaram nos menores valores de  $R^2$ : 0,85 e 0,97.

Os resultados do teste de aditividade são mostrados na Figura 34. A diferença entre o somatório das respostas individuais e da resposta em conjunto variou de 2,3 % (cabeça sensora 6) até 15,3 % (cabeça 5), com um valor médio de 9,4%.

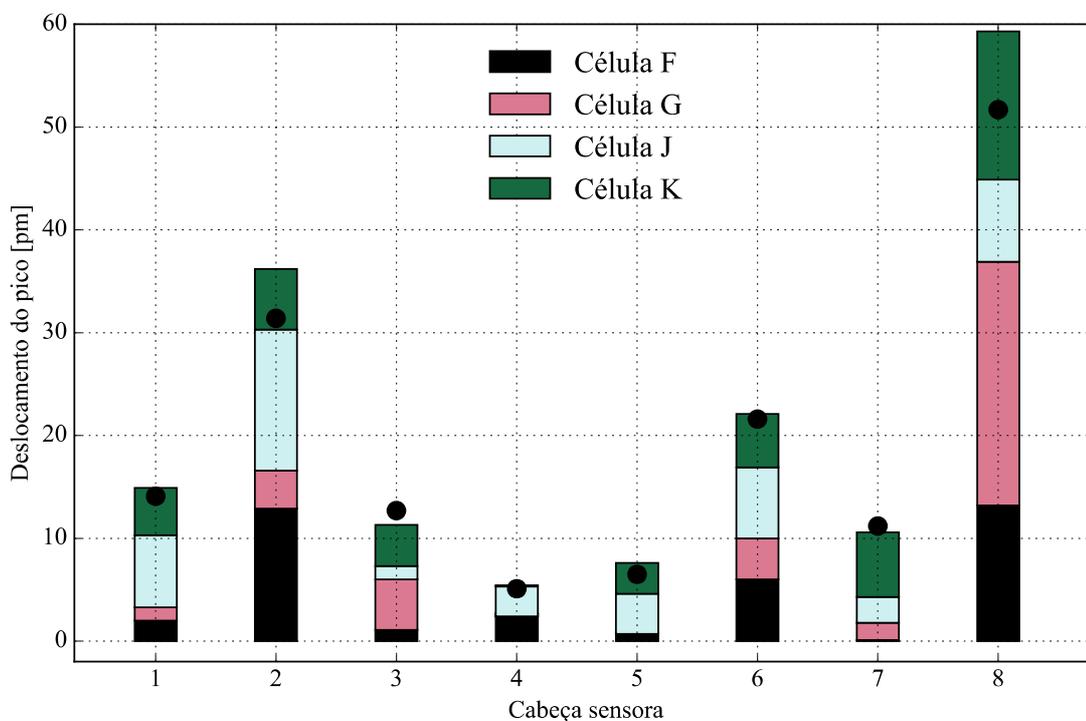


Figura 34: Resultados do teste de aditividade, mostrando o deslocamento em comprimento de onda de cargas individuais (barras empilhadas) e das cargas aplicadas simultaneamente (círculos preenchidos).

A Tabela 7 mostra a sensibilidade média das cabeças sensoras durante o experimento de reconstrução das cargas aplicadas na placa. As cabeças 2 e 8 possuem a maior sensibilidade média, pelos motivos já discutidos anteriormente (posicionamento e variações no processo de fabricação).

Tabela 7: Sensibilidade média calculada durante o experimento de reconstrução.

Cabeça sensora	Sensibilidade média [pm kg <sup>-1</sup> ]
1	31
2	87
3	47
4	30
5	32
6	36
7	39
8	114

Os resultados do teste de reconstrução podem ser vistos nas Tabelas 8 (taxa de reconstrução) e 9 (SNR médio). O método proposto resultou em taxas de reconstrução e SNRs similares ou melhores do que os outros métodos testados em todas as 3 configurações (1, 2 e 3 cargas aplicadas simultaneamente) avaliadas.

Tabela 8: Taxa de reconstrução (TR) para as três configurações de carga (com 1, 2 e 3 cargas aplicadas simultaneamente).

Método	TR – 1 carga	TR – 2 cargas	TR – 3 cargas
Lasso	82%	66%	36%
OMP	98%	52%	8%
Robust-SL0	98%	62%	24%
CoSaMP	70%	32%	10%
SDE – sem <i>ulimit</i>	100%	92%	72%
SDE – com <i>ulimit</i>	100%	96%	84%

Os resultados nas Tabelas 8 e 9 mostram que o conhecimento da maior carga aplicada (uso de *ulimit*) auxilia a reconstrução, e que o aumento do número de cargas aplicadas simultaneamente prejudica a reconstrução devido à diminuição da esparsidade e na intensificação dos efeitos da não-linearidade.

Tabela 9: SNR média (em dB) e o correspondente desvio padrão para os experimento de reconstrução.

Método	SNR – 1 cargas	SNR – 2 cargas	SNR – 3 cargas
Lasso	$18,6 \pm 7,4$	$14,4 \pm 6,2$	$10,2 \pm 7,4$
OMP	$29,1 \pm 11,5$	$14,2 \pm 13,3$	$2,6 \pm 7,9$
Robust-SL0	$25,4 \pm 9,9$	$14,8 \pm 10,1$	$7,5 \pm 7,1$
CoSaMP	$21,2 \pm 17,2$	$8,6 \pm 11,2$	$4,1 \pm 6,5$
SDE – sem <i>ulimit</i>	$34,1 \pm 10,5$	$26,0 \pm 9,7$	$17,7 \pm 9,2$
SDE – com <i>ulimit</i>	$34,3 \pm 10,3$	$26,6 \pm 8,7$	$18,9 \pm 8,7$

A Figura 35 mostra um exemplo de reconstrução para um caso com 3 cargas aplicadas simultaneamente nas células C, G e I, comparando o sinal real (a) com o sinal reconstruído (b). Um exemplo de progressão do valor da função objetivo é mostrado na Figura 36, correspondendo à reconstrução vista na Figura 35. Neste exemplo, percebe-se que a melhor solução foi encontrada até a 500ª iteração.

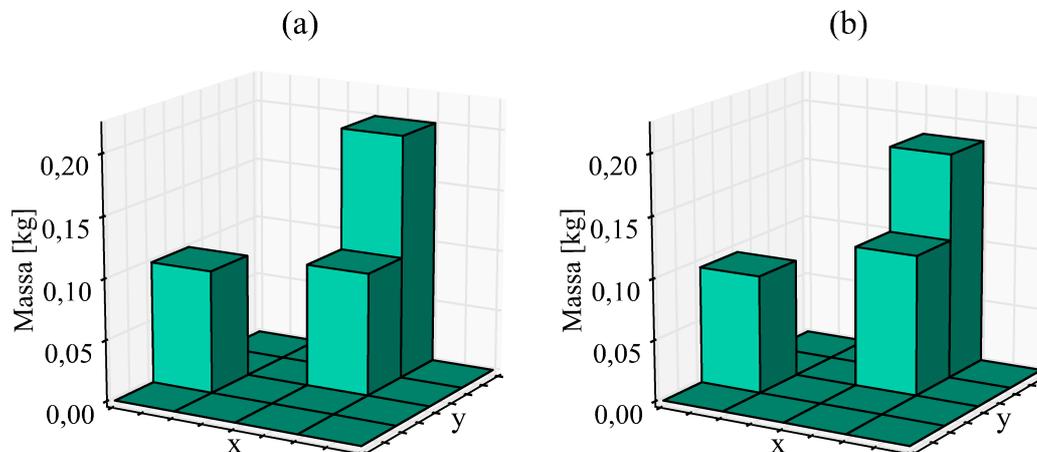


Figura 35: Exemplo de reconstrução no experimento com 3 cargas aplicadas: (a) configuração real das cargas; (b) sinal reconstruído, com SNR igual a 21,2 dB.

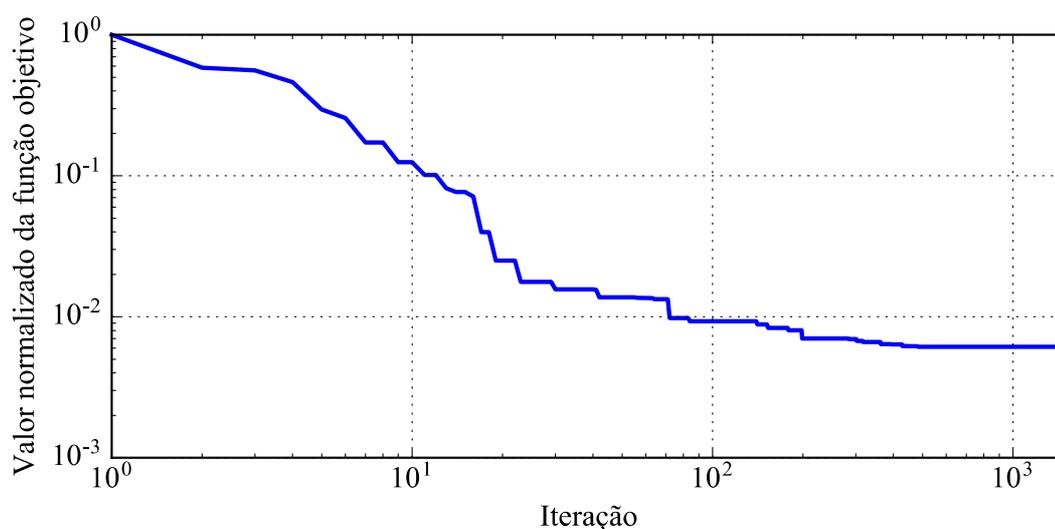


Figura 36: Exemplo de progressão do valor normalizado da função objetivo durante o processo de otimização. Este exemplo corresponde à reconstrução vista na Figura 35.

Devido à maldição da dimensionalidade (CHEN et al., 2015), o método proposto só é competitivo para problemas de reconstrução onde a dimensão do vetor  $x$  é da ordem de dezenas, pois uma dimensão maior requer um maior número de indivíduos e de iterações na busca pela solução ótima. O tempo requerido pelo método proposto durante os experimentos de reconstrução foi aproximadamente igual a 0,002 s por caso (tomando mais tempo que os outros métodos avaliados). No entanto, o tempo de reconstrução foi duas ordens de magnitude menor do que o tempo de resposta das cabeças sensoras, tornando-o irrelevante para esta aplicação.

Em comparação com a primeira versão, a segunda versão do sistema mostrou melhorias na robustez devido ao novo método de encapsulamento. Além disto, houve melhorias na taxa de reconstrução e na proporção de células monitoradas por cabeça sensora, devido tanto ao novo método de reconstrução (SDE) quanto às novas cabeças sensoras e seu posicionamento.

## CAPÍTULO 5

### SOLUÇÃO DO PROBLEMA DO ESPALHAMENTO INVERSO EM FBGS POR MEIO DE EVOLUÇÃO DIFERENCIAL

Nesta seção, é apresentado um método baseado na aplicação de evolução diferencial para determinar o perfil do estiramento aplicado a uma FBG a partir da sua refletividade (problema do espalhamento inverso visto na Seção 1.2.2). O método não utiliza informação de fase, sendo que a ambiguidade resultante é tratada pela adição de uma restrição ao método de otimização, forçando que o perfil seja suave.

#### 5.1 DETERMINAÇÃO DO PERFIL DE ESTIRAMENTO POR EVOLUÇÃO DIFERENCIAL

Um campo de deformação distribuído ao longo de uma FBG com gorjeio altera o período de modulação da rede e induz alterações no índice de refração da fibra devido ao efeito fotoelástico (HUANG et al., 1995). A alteração no período de modulação de acordo com o estiramento  $\epsilon$  é dada pela Equação 37, enquanto que a alteração no índice de refração é dada pela Equação 38, sendo  $p_{11}$  e  $p_{12}$  os coeficientes fotoelásticos da fibra e  $\nu$  é o coeficiente de Poisson. No problema do espalhamento inverso, os parâmetros estruturais da FBG são determinados a partir do espectro de reflexão, tal que:

$$\Lambda(l)' = \Lambda(l)(1 + \epsilon), \text{ e} \quad (37)$$

$$\bar{n}' = \bar{n} - 0,5\bar{n}^3(p_{12} - \nu(p_{11} + p_{12}))\epsilon. \quad (38)$$

O método baseado em DE determina o perfil de estiramento com base nos parâmetros conhecidos da rede sem estiramento. A FBG analisada é simulada por meio do método das matrizes de transferência, sendo dividida em 20 segmentos para equilibrar a exatidão da simulação e o desempenho computacional.

Uma população com 100 soluções candidatas é evoluída iterativamente utilizando o esquema DE/rand/1/bin (STORN, 1997). Cada solução candidata é composta por 20 parâmetros, correspondendo ao estiramento em cada um dos 20 segmentos na qual a rede foi decomposta. O número de segmentos pode ser aumentado ou reduzido de acordo com a resolução necessária para a aplicação, porém deve-se levar em consideração que o aumento do número de segmentos resulta no aumento na dimensão do problema.

O *fitness* de uma solução candidata é calculado pela aplicação do perfil de estiramento representado pela solução na FBG utilizando as Equações 37 e 38 para alterar os parâmetros estruturais dos segmentos. Então, o espectro de reflexão (para 64 comprimentos de onda distribuídos uniformemente) é computado. O MSE entre o espectro de reflexão calculado e o adquirido experimentalmente é multiplicado por -1, sendo o valor resultante utilizado como o valor de *fitness* individual, de forma a fazer com que o fitness aumente quando o MSE diminuir. O método de DE utilizou uma taxa de cruzamento  $CR = 0,95$  e um fator de mutação  $F = 0,7$ . Os valores de estiramento foram limitados na faixa de 0 até 2 m $\epsilon$ , próximo aos valores reportados na literatura (HUANG et al., 1995; CHENG; LO, 2004) para experimentos de estiramento. A população inicial foi gerada aleatoriamente, e o processo evolutivo ocorreu por 2000 iterações. Após o processo, a solução com maior *fitness* foi selecionada. Os parâmetros do método (CR, F, tamanho da população) foram determinados empiricamente.

Como já foi discutido em outros trabalhos (HUANG et al., 1995; CHENG; LO, 2004), a indisponibilidade da informação de fase faz com que um certo número de perfis de estiramento distintos resultem no mesmo espectro de reflexão. Para obter uma solução única correspondendo ao estiramento real, uma única FBG com gorjeio e apodização Gaussiana foi utilizada. Adicionalmente, uma restrição à solução candidata foi utilizada para evitar perfis de estiramento impraticáveis, mas que resultariam no mesmo espectro de reflexão. Esta restrição impõe que o estiramento para cada segmento da FBG não pode diferir mais do que 0,2 m $\epsilon$  do estiramento nos segmentos vizinho, sendo que cada segmento que violar esta restrição acarreta na penalização do *fitness* por um valor igual ao estiramento excedente multiplicado por 10 (peso arbitrário). Esta restrição atua como um termo de regularização, e pode ser modificada de acordo com a aplicação.

### 5.1.1 Metodologia de avaliação

O método proposto foi avaliado por meio de simulações, utilizando uma FBG com gorjeio de  $0,5 \text{ nm/cm}$ , comprimento  $l=1 \text{ cm}$ ,  $\Lambda=532,4 \text{ nm}$  (inicial),  $\bar{n}=1.457$ ,  $\Delta n_0=2.5 \times 10^{-4}$ , com apodização por envelope Gaussiano na modulação do índice de refração. A FBG foi deformada seguindo três perfis distintos, resultando nos experimentos  $E_1$ ,  $E_2$  e  $E_3$ , cujos resultados são vistos na Figura 37. Em cada experimento, a FBG foi distendida de acordo com o perfil do experimento, e o método proposto foi utilizado para recuperar o perfil de estiramento ao longo da FBG a partir da refletância do sinal refletido pela FBG. O espectro de refletância consistiu de uma sequência de 64 comprimentos de onda, uniformemente distribuídos na faixa de 1552 nm até 1555 nm. Os coeficientes fotoelásticos foram assumidos como  $p_1=0,113$  e  $p_2=0,252$ , e o coeficiente de Poisson  $\nu=0,16$  (BERTHOLDS; DANDLIKER, 1988).

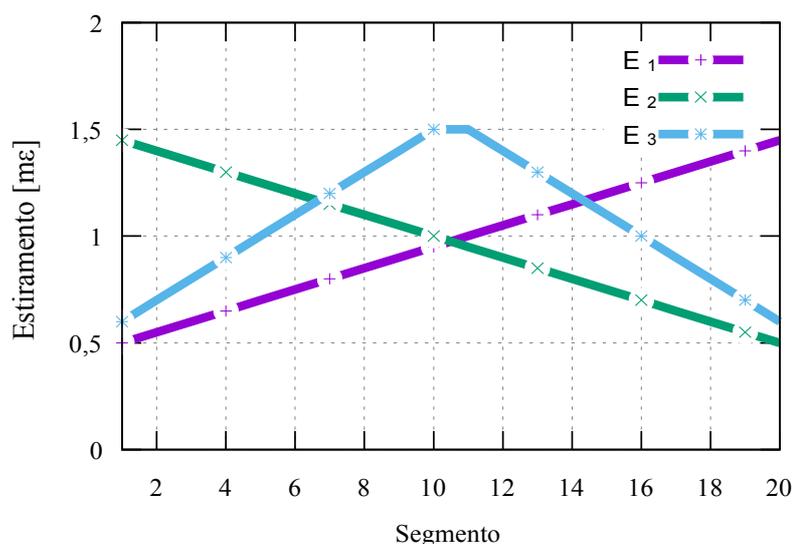


Figura 37: Perfis de estiramento utilizados nos experimentos  $E_1$ ,  $E_2$  e  $E_3$ .

O erro absoluto médio (MAE, do inglês *mean absolute error*) entre o perfil de estiramento obtido e o perfil alvo foi utilizado como métrica para determinar a qualidade da solução final. O MAE é definido pela Equação :

$$MAE = \frac{1}{q} \sum_{k=1}^q |d_k - y_k|, \quad (39)$$

onde  $q$  é o número total de elementos,  $d_k$  é o  $k$ -ésimo elemento do vetor de valores esperados e  $y_k$  é o  $k$ -ésimo elemento do vetor de valores obtidos.

Cada experimento foi repetido 100 vezes, registrando o MAE. Os experimentos foram realizados utilizando todos os núcleos de processamento de um processador Intel(R) Core(TM) i7-3520M 2,90GHz (com avaliação paralela de *fitness*).

### 5.1.2 Resultados

A Tabela 10 mostra as estatísticas de média (com o desvio padrão amostral) e mediana do MAE obtido com a execução dos experimentos  $E_1$ ,  $E_2$  e  $E_3$ . Em todos os experimentos, a mediana do MAE é ordens de magnitude (fator de  $10^5$ ) menor do que o estiramento nas fibras, indicando que os resultados correspondem a resposta esperada.

A análise individual dos resultados mostra que aproximadamente 2% das execuções não convergiram para o ótimo global (perfil alvo), motivo pelo qual a média é ordens de magnitude maior do que a mediana para todos os experimentos.

Tabela 10: Resultados dos experimentos de determinação do perfil de estiramento, executados em CPU.

<b>Experimento</b>	<b>Média e desvio [ m ε ]</b>	<b>Mediana [ m ε ]</b>
$E_1$	$(9,34 \pm 93,45) \times 10^{-3}$	0
$E_2$	$(7,59 \pm 66,95) \times 10^{-3}$	$2,35 \times 10^{-5}$
$E_3$	$(5,22 \pm 52,2) \times 10^{-3}$	$2,5 \times 10^{-7}$

A implementação levou aproximadamente 17 s para convergir para o resultado final, sendo que este desempenho computacional pode ser melhorado diminuindo o número de segmentos na modelagem da FBG analisada.

O método mostrou uma melhoria no desempenho de cerca de duas ordens de magnitude quanto ao algoritmo genético proposto por CHENG; LO (2004), para um mesmo número de segmentos e perfis de estiramento semelhantes.

## 5.2 PROCESSAMENTO PARALELO EM GPU

Como visto na Seção 5.1.2, a implementação em CPU do método de recuperação do perfil de estiramento requer um tempo de processamento da ordem de dezenas de segundos. Apesar deste requerimento ser ordens de magnitude menor do que o visto na literatura (CHENG; LO, 2004), ele ainda impede o uso do método em aplicações de monitoramento contínuo. Para contornar esta limitação, investigou-se a implementação do método para execução em GPU (unidade de processamento gráfico, do inglês *graphics processing unit*), com o objetivo de possibilitar taxas de aquisição maiores do que 1 Hz, possibilitando o monitoramento contínuo.

### 5.2.1 Implementação em GPU

As GPUs modernas possuem a capacidade de executar funções denominadas *kernels* de forma massivamente paralela, resultando na execução simultânea de milhares de processos (NICKOLLS et al., 2008). A implementação de um programa para execução em GPU é benéfica se este pode se adequar aos requisitos impostos pela arquitetura da GPU alvo: usualmente, isto implica na possibilidade de separar o processamento em centenas ou milhares de processos paralelos, minimizando o acesso a memória compartilhada, e limitando a precisão dos números de ponto flutuante para 32 bits.

O método de recuperação do perfil de estiramento proposto neste capítulo é um exemplo de programa que pode ser beneficiado pela implementação em GPU, considerando que a avaliação de cada indivíduo da população pode ser avaliado independentemente dos outros. Considerando que a avaliação de um indivíduo é composta pelo cálculo independente da refletância em uma sequência de comprimentos de onda, percebe-se que é possível utilizar um processo para cada comprimento de onda avaliado.

Detalhadamente, foi utilizada a plataforma de computação paralela CUDA (do inglês *Compute Unified Device Architecture*), possibilitando que o método fosse executado em GPUs que suportam a plataforma. Nesta implementação, as diferentes etapas do algoritmo DE foram implementadas sequencialmente para execução em CPU, com exceção da etapa de

avaliação dos indivíduos, que foi implementada na forma de *kernel* para ser executada paralelamente na GPU.

O *kernel* de avaliação de indivíduos é executado em GPU por 96 (reduzido de 100 para corresponder a um múltiplo de 16, devido a arquitetura) blocos de processos, onde cada bloco corresponde a um indivíduo. Cada bloco contém 64 processos, sendo que cada processo simula a resposta da FBG para um dado comprimento de onda. Em cada processo, são realizadas as multiplicações matriciais necessárias, calculando o erro entre esta resposta calculada e a resposta alvo. Quando todos os processos de um bloco terminam de computar os erros em cada ponto, estes erros são somados pelo operador paralelo de redução para o cálculo do erro quadrático médio do indivíduo. Assim, com este *kernel* tem-se a criação de  $96 \times 64 = 6144$  processos, sendo que a quantidade de processos que são executados efetivamente de forma paralela dependem da GPU utilizada para a computação.

De forma a minimizar o uso de memória global na GPU, cada bloco de processos compartilha a informação sobre o indivíduo analisado, sendo que os parâmetros da FBG que está sob deformação são armazenados em memória global, porém estática e somente para leitura.

### 5.2.2 Metodologia de avaliação

O método foi avaliado conforme descrito na Seção 5.1.1, utilizando porém 1000 repetições por experimento ao invés de 30. Os três experimentos ( $E_1$ ,  $E_2$  e  $E_3$ ) foram realizados novamente de forma a comparar os resultados com a implementação em CPU.

### 5.2.3 Resultados

As estatísticas (MAE médio e desvio padrão amostral) dos resultados obtidos nos três experimentos são mostrados na Tabela 11. Os resultados completos são mostrados na Figura 38, onde cada execução corresponde a um ponto no gráfico.

O tempo médio de execução de uma repetição foi 0,67 s, alcançando o objetivo inicial de possibilitar o monitoramento de um sensor com taxa de aquisição maior do que 1 Hz.

Tabela 11: Resultados dos experimentos de determinação do perfil de estiramento, executados em GPU.

Experimento	Média e desvio [ m $\epsilon$ ]	Mediana [ m $\epsilon$ ]
E <sub>1</sub>	$(4,78 \pm 65,94) \times 10^{-3}$	$1,08 \times 10^{-4}$
E <sub>2</sub>	$(3,69 \pm 24,47) \times 10^{-3}$	$1,01 \times 10^{-3}$
E <sub>3</sub>	$(3,51 \pm 40,30) \times 10^{-3}$	$3,72 \times 10^{-4}$

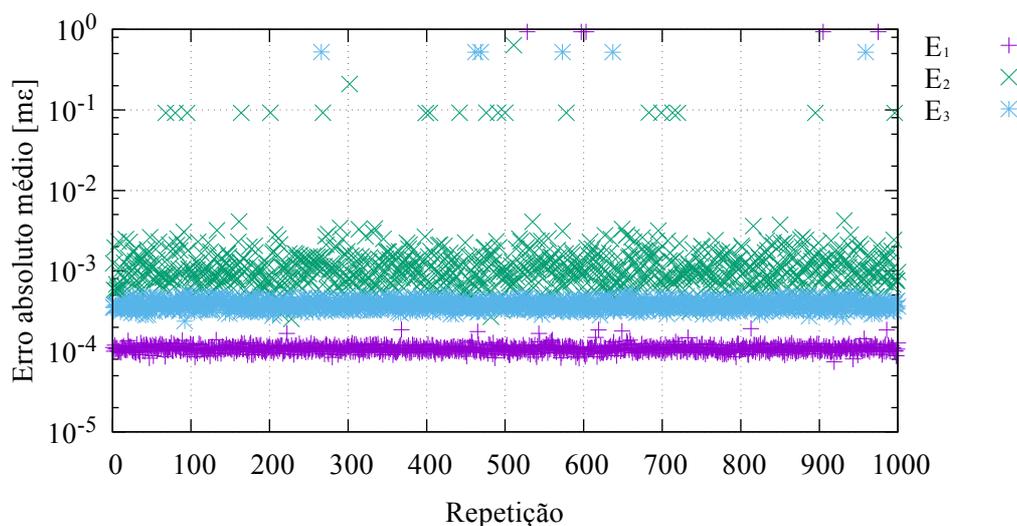


Figura 38: Resultados das repetições dos experimentos E<sub>1</sub>, E<sub>2</sub> e E<sub>3</sub>. Cada ponto no gráfico representa o resultado de uma execução.

Os resultados na Tabela 11 mostram que o método converge para as soluções esperadas (mediana da ordem de  $\mu\epsilon$ , enquanto que o estiramento está da ordem de  $m\epsilon$ ). Os altos desvios (da ordem de 10 vezes o erro médio) e a diferença entre a média e a mediana vistos Tabela 11 evidenciam que algumas execuções não convergiram para o ótimo global. Isto é confirmado ao observar a Figura 38, onde percebe-se que algumas execuções obtiveram erros ordens de magnitude maiores do que o erro médio.

As medianas dos erros obtidos nos experimentos em CPU foram menores do que as obtidas em GPU. Isto se deve ao uso (em GPU) de números de ponto de flutuante com precisão limitada (32 bits em GPU vs 64 bits em CPU) e a diferenças na geração de números pseudo-aleatórios entre as implementações.

### 5.3 VERIFICAÇÃO EXPERIMENTAL

O método proposto foi aplicado na determinação do perfil de estiramento de uma FBG sujeita a um estiramento não-uniforme controlado, de forma a avaliar o método experimentalmente. A metodologia e os resultados são apresentados nesta seção.

#### 5.3.1 Metodologia de avaliação

Uma FBG foi gravada em um segmento de fibra ótica no Núcleo de Dispositivos Fotorrefrativos da UTFPR pela técnica de iluminação direta de uma máscara de fase. Uma máscara de fase longa (comprimento de 1 cm) foi utilizada na gravação, sendo esta iluminada por um laser de excímero KrF (Xantos XS-Coherent) em 248 nm. O feixe do laser foi deslocado linearmente para cobrir toda a região da máscara de fase, produzindo uma FBG com comprimento aproximadamente igual a 6,5 mm, com  $\lambda_b = 1546,33$  nm .

O segmento de fibra ótica com a FBG foi fixado em um suporte de tracionamento de fibras utilizando cola de cianoacrilato. A fibra foi fixada em dois pontos, conforme visto na Figura 39, que apresenta o esquemático do suporte de tracionamento, com uma visão superior (a) e lateral (b). O ponto de colagem *A* cobre aproximadamente metade da FBG, fazendo com que metade fique fixa e a outra metade possa ser estirada. O ponto de colagem *B* está a 91,3 mm do ponto *A*. O ponto de colagem *A* está em uma plataforma móvel, cujo deslocamento é efetuado por um parafuso micrométrico, controlado eletronicamente.

O espectro de reflexão da FBG foi monitorado com um analisador de espectro ótico (Anritsu MS9710B , utilizando resolução de 0,1 nm). Uma aquisição de dados (leitura do espectro de reflexão) foi realizada com a plataforma móvel em sua posição inicial, para servir como referência. Em seguida, a plataforma foi deslocada em passos de 0,05 mm até chegar em um deslocamento final de 0,2 mm. A cada passo fez-se uma aquisição de dados.

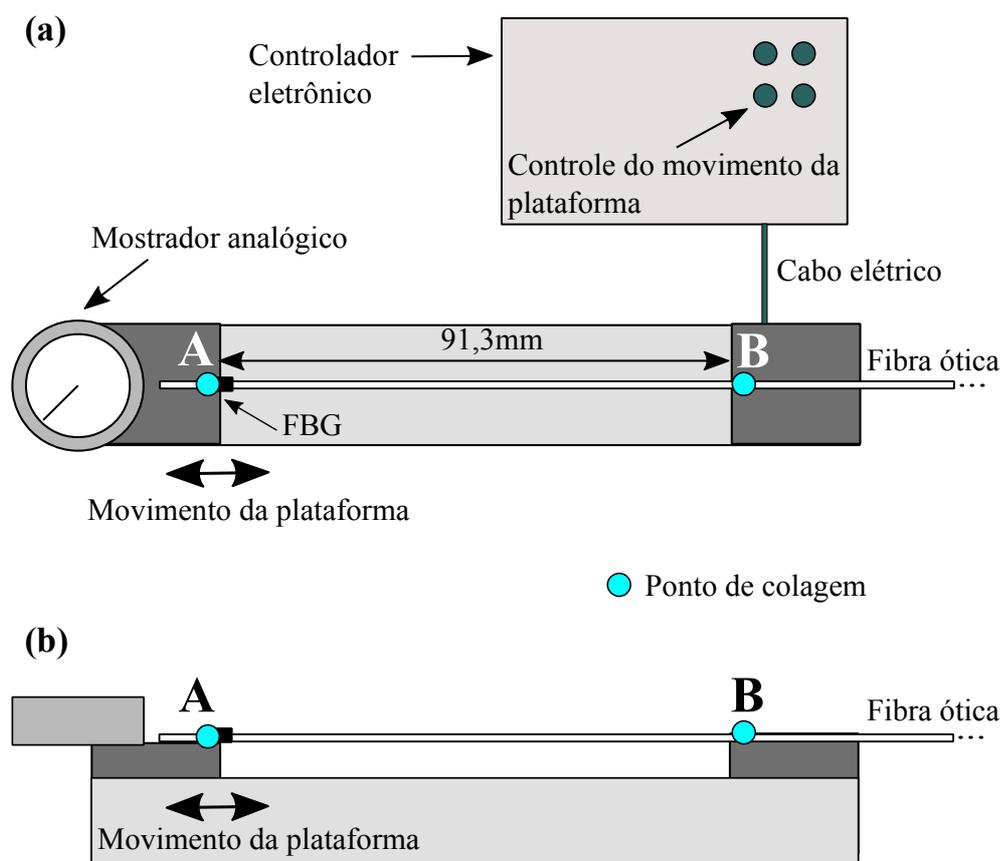


Figura 39: Esquemático do suporte de tração de fibras: (a) visão superior e (b) visão lateral.

O método proposto neste capítulo foi utilizado inicialmente para determinar os parâmetros iniciais da FBG (sem nenhum estiramento). O método foi utilizado então para determinar o perfil de estiramento da FBG utilizando as aquisições de dados realizadas a cada passo da plataforma móvel. Para esta determinação forçou-se os parâmetros obtidos com a FBG relaxada (comprimento, periodicidade, índice de refração efetivo, modulação do índice e parâmetros da apodização), de forma com que o método determine somente o perfil de estiramento. A FBG foi modelada de forma a ter 10 segmentos, e a restrição de continuidade do perfil (proposta na Seção 5.1) foi utilizada, porém sem o uso do limitador de  $0,2\text{ m}\epsilon$ .

Com a colagem de aproximadamente metade da FBG, tem-se como alvo um perfil de estiramento que tenha o formato de degrau, com um estiramento próximo a zero no segmento colado. No segmento solto, espera-se o estiramento  $\epsilon_{seg}$  dado pela Equação 40:

$$\epsilon_{seg} = D_p / L_p, \quad (40)$$

onde  $D_p$  é o deslocamento da plataforma e  $L_p$  é a distância entre os pontos de colagem. Como a cola de cianoacrilato possui uma determinada elasticidade é possível que o estiramento no segmento colado seja diferente de zero, mas consideravelmente menor do que o no segmento livre. Considerando que no ponto B a cola foi aplicada em um segmento da fibra com o revestimento de acrilato, espera-se que o estiramento real na fibra ótica seja menor do que o aplicado no revestimento (HER; HUANG, 2011).

O experimento foi realizado em uma sala com temperatura controlada em  $(20,0 \pm 0,5)$  °C.

### 5.3.2 Resultados

A Figura 40 mostra o espectro de reflexão experimental da FBG avaliada na condição inicial (sem estiramento) e para os deslocamentos de 0,05 mm até 0,2 mm. Os resultados mostram a divisão do espectro de reflexão em duas regiões: uma próxima ao pico original (referente ao segmento colado da FBG) e outra que se desloca para maiores comprimentos de onda conforme o deslocamento da plataforma (referente ao segmento solto da FBG).

Um comparativo entre o espectro de reflexão experimental e o obtido por simulação com os parâmetros obtidos pelo método de recuperação do perfil de estiramento pode ser visto na Figura 41. O espectro simulado aproxima o espectro experimental, apresentando o seu maior erro na região de menores comprimentos de onda.

A Tabela 12 mostra o perfil de estiramento obtido para cada passo da plataforma móvel, comparando-o com o estiramento esperado para a parte solta, calculado pela Equação 40.

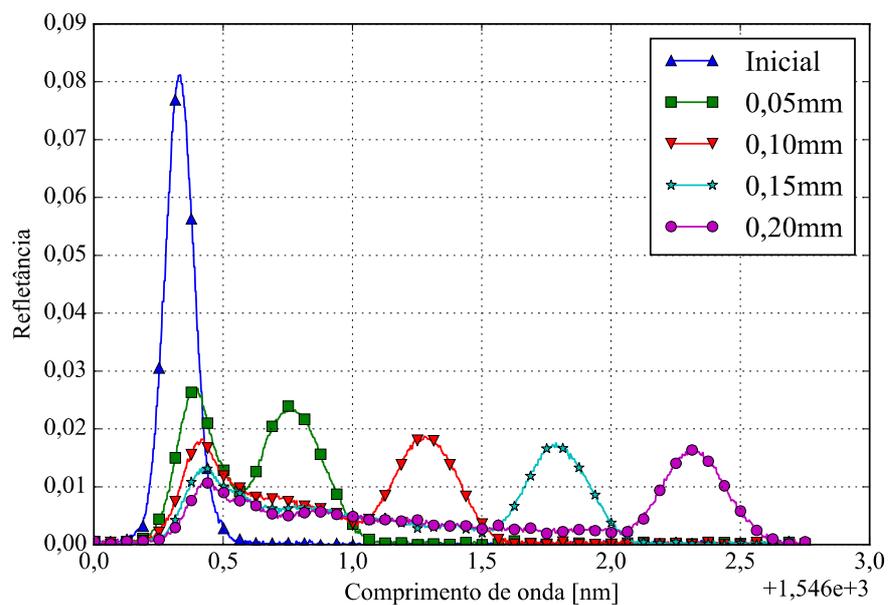


Figura 40: Espectros de reflexão para a FBG na condição inicial e para os deslocamentos de 0,05 mm até 0,2 mm.

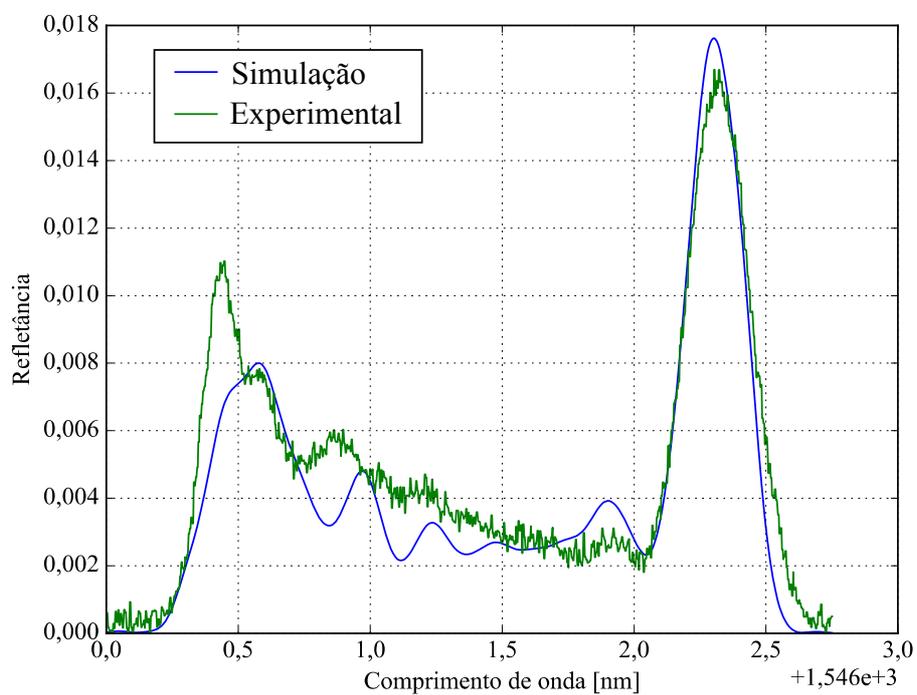


Figura 41: Comparação entre o espectro de reflexão experimental e o obtido pela simulação com o perfil de estiramento e parâmetros recuperados.

Tabela 12: Comparativo entre o perfil de estiramento obtido (estiramento em cada uma das 10 seções) e o estiramento esperado para a região solta da FBG, para cada deslocamento da plataforma móvel.

Deslocamento	Estiramento [ m $\epsilon$ ]										Esperado
	1	2	3	4	5	6	7	8	9	10	
0,05 mm	0,05	0,05	0,05	0,05	0,05	0,39	0,39	0,39	0,39	0,39	0,54
0,10 mm	0,05	0,05	0,05	0,10	0,26	0,64	0,82	0,82	0,82	0,82	1,09
0,15 mm	0,06	0,06	0,06	0,18	0,40	0,89	1,23	1,23	1,23	1,23	1,64
0,20 mm	0,13	0,13	0,13	0,33	0,80	1,42	1,65	1,65	1,65	1,65	2,19

Como visto na Tabela 12, os perfis de estiramento recuperados tem a forma aproximada de uma função degrau. Para o deslocamento de 0,05 mm, verifica-se que metade dos segmentos da FBG apresentaram um estiramento igual a 0,05 m $\epsilon$  (referentes ao segmento colado da FBG), enquanto que os segmentos restantes (referentes ao segmento solto da FBG) apresentaram um estiramento aproximadamente igual a 8 vezes o estiramento na primeira metade. Com o deslocamento da plataforma, verifica-se um aumento proporcional no estiramento dos segmentos relativos a parte solta da FBG. Os resultados também mostram que, para deslocamentos maiores, um maior número de segmentos passa a ser afetado, o que está relacionado à elasticidade da cola de cianoacrilato.

O estiramento recuperado para os segmentos referentes a parte solta da FBG foi sistematicamente menor do que o estiramento esperado. Em todos os casos o estiramento esperado é cerca de 1/3 maior do que o obtido. Isto é explicado pela diferença entre o estiramento no revestimento e na fibra em si, como discutido na Seção 5.3.1. Uma evidência disto está no fato do estiramento obtido ser consistente com o alargamento espectral mostrado na Figura 41, considerando a sensibilidade de uma FBG ao estiramento de 1,22 pm/ $\mu\epsilon$  para a faixa de comprimento de onda da FBG utilizada.

## CAPÍTULO 6

### CONCLUSÕES

Este trabalho investigou a aplicação de métodos de inteligência computacional e sensoriamento compressivo para otimizar o uso de sensores a fibra ótica para o sensoriamento de deformação mecânica, em aplicações envolvendo a detecção de deformação em superfícies e no sensoriamento tátil.

O uso de RNAs permitiu que a resposta acoplada dos sensores fosse utilizada para determinar a posição de uma única carga de teste em uma placa (Seção 3.1). Os resultados obtidos foram superiores aos citados na literatura para aplicações similares, obtendo a redução da raiz do erro Euclidiano médio de 2,7 % para 1,93 % da diagonal da placa, utilizando um número reduzido de FBGs (4 FBGs ao invés de 9, como no método original). Em uma nova versão, o aumento do número (de 4 para 11) e a mudança no encapsulamento das FBGs, juntamente com a aplicação de SVRs (Seção 3.2), possibilitou uma nova diminuição na raiz do erro Euclidiano médio para 0,9 % da diagonal da placa.

Resultados confirmaram a possibilidade da determinação de até três cargas posicionadas simultaneamente em uma superfície pelo uso do sistema de mapeamento de forças proposto (Seção 4.1). O uso da teoria de CS permitiu a solução do problema inverso subdeterminado, resultando em uma taxa de reconstrução superior a obtida pela determinação da solução com menor norma Euclidiana. Uma segunda versão do sistema de mapeamento foi proposta, melhorando a robustez das cabeças sensoras pelo encapsulamento de FBGs em blocos de silicone. Um novo método para a solução do problema inverso subdeterminado utilizando DE foi proposto, aumentando a taxa de reconstrução de 73,33 % para 84 % (comparativo com a primeira versão), e um aumento na relação de células monitoradas por cabeça sensora de 1,27 para 2 células por cabeça.

Um método baseado em DE para a solução do problema do espalhamento inverso em FBGs com gorjeio foi proposto (Seção 5.1). Este método requer somente a refletância da rede, dispensando a informação de fase. Além disto, não há a necessidade de operar somente com redes fracas. Resultados simulados mostram que o método foi capaz de recuperar o perfil do estiramento aplicado na FBG de teste. Entre as contribuições, destaca-se o menor custo computacional (tempo da ordem de dezenas de segundos em um computador de uso geral) em relação a métodos evolutivos já apresentados e a capacidade de tratar da ambiguidade sem a necessidade de utilizar múltiplas FBGs simultaneamente. O método foi implementado para uso em GPUs (Seção 5.2), reduzindo o tempo necessário da ordem de dezenas de segundos para uma fração de segundo. Foi realizada uma verificação experimental do método (Seção 5.3), onde este foi utilizado para recuperar o perfil de estiramento de uma FBG, que fora tracionada de forma controlada. Resultados mostraram que o método recuperou aproximadamente o perfil esperado, quando compensada a diferença de estiramento entre o revestimento de acrilato e da fibra em si, fornecendo uma base para o uso de uma FBG no sensoriamento *quasi*-distribuído de deformações mecânicas.

Os resultados combinados das avaliações realizadas nos Capítulos 3, 4 e 5 mostram que as técnicas propostas neste trabalho contribuem na otimização do uso de FBGs em aplicações relacionadas ao sensoriamento de deformações mecânicas. Foram propostos métodos (Capítulos 3 e 4) que se beneficiam do acoplamento entre os sensores, característica usualmente indesejada, e métodos (Capítulos 3 e 5) que permitem reduzir o número de sensores necessários em tarefas de sensoriamento.

Foi identificado um conjunto de trabalhos futuros relacionados aos temas abordados nesta tese. Em relação ao sistema de mapeamento de forças, pode-se estudar a aplicação do método em superfícies de sensoriamento flexíveis, para a medição de deformações localizadas em objetos diversos. Um estudo relacionado, já em andamento, inclui a mudança do uso de FBGs para sensores em fibra ótica por modulação de intensidade, simplificando e barateando o método de leitura dos sensores pelo uso de câmeras e algoritmos de processamento de imagem. Como melhorias para o sistema de mapeamento de forças, pode-se investigar a viabilidade da troca do modelo linear por outro que considere a não-linearidade do sistema, além do estudo sobre como posicionar as cabeças sensoras na placa de forma a maximizar a capacidade de reconstrução.

Em relação ao uso de DE para a solução do problema do espalhamento inverso em FBGs, sugere-se a aplicação do método para a detecção de perfis de temperatura ao longo FBGs longas.

## PUBLICAÇÕES

Os seguintes artigos (relacionados a esta tese) foram publicados ou aceitos para publicação em periódicos e congressos durante o período de doutoramento:

1. NEGRI, L. H.; PATERNO, A. S.; MULLER, M.; FABRIS, J. L. Sparse Force Mapping System based on Compressive Sensing. *IEEE Transactions on Instrumentation and Measurement*, 2017;
2. NEGRI, L. H.; MULLER, M.; FABRIS, J. L.; PATERNO, A. S. A high performance approach for parallel computing of fiber Bragg grating strain profiles using graphics processing units. *International Journal of High Performance Systems Architecture*, 2016;
3. NEGRI, L. H.; PATERNO, A. S.; MULLER, M.; FABRIS, J. L. Sensoriamento Táctil Distribuído com Redes de Bragg em Fibra Ótica. *Latin American Workshop on Optical Fiber Sensors. (Anais)*. p.64–67, 2016. Porto Alegre, RS;
4. NEGRI, L. H.; SCHIEFER, E. M.; PATERNO, A. S.; MULLER, M.; FABRIS, J. L. An approach to improve the spatial resolution of a force mapping sensing system. *Measurement Science and Technology*, v. 27, n. 2, p. 25103, 2016;
5. NEGRI, L. H.; LOPES, H. S.; MULLER, M.; FABRIS, J. L.; PATERNO, A. S. An efficient method to determine strain profiles on FBGs by using differential evolution and GPU. *2015 Latin America Congress on Computational Intelligence (LA-CCI)*. (Anais). p.1–6, 2015. Curitiba, PR;
6. NEGRI, L. H.; SCHIEFER, E. M.; PATERNO, A. S.; MULLER, M.; FABRIS, J. L. Smartphone-based portable intensity modulated force sensor. In: H. J. Kalinowski; J. L. Fabris; W. J. Bock (Eds.); *24th International Conference on Optical Fibre Sensors*. (Anais). v. 1, p.96347S, 2015. Curitiba, PR;

7. NEGRI, L. H.; WANG, Y.; PATERNO, A. S.; MULLER, M. Distributive Surface Load Position Estimation by Smart Optical Sensing. MOMAG 2014. (Anais). p.359–362, 2014. Curitiba, PR;
8. NEGRI, L. H.; MULLER, M.; PATERNO, A. S.; FABRIS, J. L. A New Approach to Solve the Inverse Scattering Problem Using a Differential Evolution Algorithm in Distributed Fiber Bragg Grating Strain Sensors. Latin America Optics and Photonics Conference. (Anais). p.LTu4A.19, 2014. Washington, D.C.

## REFERÊNCIAS

BAO, Y.; LI, H.; OU, J. Emerging data technology in structural health monitoring: compressive sensing technology. *Journal of Civil Structural Health Monitoring*, v. 4, n. 2, p. 77–90, 2014.

BERTHOLDS, A.; DANDLIKER, R. Determination of the individual strain-optic coefficients in single-mode optical fibres. *Journal of Lightwave Technology*, v. 6, n. 1, p. 17–20, 1988.

BISHOP, C. M. Training with Noise is Equivalent to Tikhonov Regularization. *Neural Computation*, v. 7, n. 1, p. 108–116, 1995.

BOLOGNINI, G.; HARTOG, A. Raman-based fibre sensors: Trends and applications. *Optical Fiber Technology*, v. 19, n. 6, p. 678–688, 2013. Elsevier Inc.

CANDES, E. J.; TAO, T. Decoding by Linear Programming. *IEEE Transactions on Information Theory*, v. 51, n. 12, p. 4203–4215, 2005.

CHAN, T. H. T.; YU, L.; TAM, H. Y.; et al. Fiber Bragg grating sensors for structural health monitoring of Tsing Ma bridge: Background and experimental observation. *Engineering Structures*, v. 28, n. 5, p. 648–659, 2006.

CHANG, C.-C.; LIN, C.-J. LIBSVM: A library for support vector machines. *ACM Transactions on Intelligent Systems and Technology*, v. 2, n. 3, p. 27:1--27:27, 2011.

CHEN, S.; MONTGOMERY, J.; BOLUFÉ-RÖHLER, A. Measuring the curse of dimensionality and its effects on particle swarm optimization and differential evolution. *Applied Intelligence*, v. 42, n. 3, p. 514–526, 2015.

CHEN, S. S.; DONOHO, D. L.; SAUNDERS, M. A. Atomic Decomposition by Basis Pursuit. *SIAM Review*, v. 43, n. 1, p. 129–159, 2001.

CHENG, H.-C.; LO, Y.-L. Arbitrary strain distribution measurement using a genetic algorithm approach and two fiber Bragg grating intensity spectra. *Optics Communications*, v. 239, n. 4–6, p. 323–332, 2004.

CHILDERS, B. A.; FROGGATT, M. E.; ALLISON, S. G.; et al. Use of 3000 Bragg grating strain sensors distributed on four 8-m optical fibers during static load tests of a composite structure. In: A.-M. R. McGowan (Ed.); *SPIE's 8th Annual International Symposium on Smart Structures and Materials*. (Anais). v. 4332, p.133–142, 2001. Newport Beach.

CHOJNOWSKI, P.; JĘDRZEJEWSKI, K. P. Strain and temperature sensor applications of fiber Bragg gratings. In: R. S. Romaniuk (Ed.); *Proceedings of SPIE*. (Anais). v. 6347, p.63470W–63470W–11, 2006. [S.I]: SPIE.

CLIFFORD, P. M. The international vocabulary of basic and general terms in metrology. *Measurement*, v. 3, n. 2, p. 72–76, 1985.

CORADIN, F. K.; POSSETTI, G. R. C.; KAMIKAWACHI, R. C.; MULLER, M.; FABRIS, J. L. Etched Fiber Bragg Gratings Sensors for Water-Ethanol Mixtures : a Comparative Study. , v. 9, n. 2, p. 131–143, 2010.

COROTTI JR, R. DE P.; THALER, J.; KALINOWSKI, H. J.; et al. Etched FBG written in multimode fibers: sensing characteristics and applications in the liquid fuels sector. *Journal of Microwaves, Optoelectronics and Electromagnetic Applications*, v. 14, n. 1, p. 51–59, 2015.

COWIE, B. M.; WEBB, D. J.; TAM, B.; SLACK, P.; BRETT, P. N. Fibre Bragg grating sensors for distributive tactile sensing. *Measurement Science and Technology*, v. 18, n. 1, p. 138–146, 2007.

DAS, S.; MULLICK, S. S.; SUGANTHAN, P. N. Recent advances in differential evolution – An updated survey. *Swarm and Evolutionary Computation*, v. 27, p. 1–30, 2016.

DAS, S.; SUGANTHAN, P. N. Differential Evolution: A Survey of the State-of-the-Art. *IEEE Transactions on Evolutionary Computation*, v. 15, n. 1, p. 4–31, 2011.

DAVIS, C.; ROBERTSON, D.; BROOKS, C.; et al. Reduced length fibre Bragg gratings for high frequency acoustic sensing. *Measurement Science and Technology*, v. 25, n. 12, p. 125105, 2014.

DAVIS, M. A.; BELLEMORE, D. G.; KERSEY, A. D. Structural Strain Mapping using a Wavelength/Time Division Addressed Fiber Bragg Grating Array. *Second European Conference on Smart Structures and Materials*, p. 342–345, 1994.

DONG, L.; COLE, M. J.; ELLIS, A. D.; LAMING, R. I.; WIDDOWSON, T. 40 Gbit/s 1.55  $\mu\text{m}$  RZ transmission over 109 km of non-dispersion shifted fibre with long continuously chirped fibre gratings. *Electronics Letters*, v. 33, n. 18, p. 1563, 1997. IET.

DUARTE, M. F.; DAVENPORT, M. A.; TAKHAR, D.; et al. Single-Pixel Imaging via Compressive Sampling. *IEEE Signal Processing Magazine*, v. 25, n. 2, p. 83–91, 2008.

EFTEKHARI, A.; BABAIE-ZADEH, M.; JUTTEN, C.; MOGHADDAM, H. A. Robust-SL0 for stable sparse representation in noisy settings. *2009 IEEE International Conference on Acoustics, Speech and Signal Processing. (Anais)*. p.3433–3436, 2009. Taipei: IEEE.

ELLIOTT, M. T.; MA, X.; BRETT, P. N. Tracking the position of an unknown moving load along a plate using the distributive sensing method. *Sensors and Actuators A: Physical*, v. 138, n. 1, p. 28–36, 2007.

ERDOGAN, T. Fiber grating spectra. *Journal of Lightwave Technology*, v. 15, n. 8, p. 1277–1294, 1997.

GLOROT, X.; BENGIO, Y. Understanding the difficulty of training deep feedforward neural networks. *International conference on artificial intelligence and statistics. (Anais)*. v. 9, p.249–256, 2010. Sardenha.

HAYKIN, S. **Redes neurais: princípios e prática**. 2<sup>a</sup> ed. Porto Alegre, RS: Bookman, 2001.

HEO, J.-S.; CHUNG, J.-H.; LEE, J.-J. Tactile sensor arrays using fiber Bragg grating sensors. *Sensors and Actuators A: Physical*, v. 126, n. 2, p. 312–327, 2006.

HEO, J.-S.; KIM, K.-Y.; LEE, J.-J. Development of a Distributed Force Detectable Artificial Skin Using Microbending Optical Fiber Sensors. *Journal of Intelligent Material Systems and Structures*, v. 20, n. 17, p. 2029–2036, 2009.

HER, S. C.; HUANG, C. Y. Effect of coating on the strain transfer of optical fiber sensors. *Sensors*, v. 11, n. 7, p. 6926–6941, 2011.

HILL, K. O.; FUJII, Y.; JOHNSON, D. C.; KAWASAKI, B. S. Photosensitivity in optical fiber waveguides: Application to reflection filter fabrication. *Applied Physics Letters*, v. 32, n. 10, p. 647, 1978.

HILL, K. O.; MALO, B.; BILODEAU, F.; JOHNSON, D. C.; ALBERT, J. Bragg gratings fabricated in monomode photosensitive optical fiber by UV exposure through a phase mask. *Applied Physics Letters*, v. 62, n. 10, p. 1035–1037, 1993. AIP Publishing.

HINTON, G. E.; OSINDERO, S.; TEH, Y.-W. A Fast Learning Algorithm for Deep Belief Nets. *Neural Computation*, v. 18, n. 7, p. 1527–1554, 2006.

HO, Y.-T.; HUANG, A.-B.; LEE, J. Development of a chirped/differential optical fiber Bragg grating pressure sensor. *Measurement Science and Technology*, v. 19, n. 4, p. 45304, 2008.

HORNIK, K. Approximation Capabilities of Multilayer Feedforward Networks. , v. 4, n. 1989, p. 251–257, 1991.

HORNIK, K.; STINCHCOMBE, M.; WHITE, H. Multilayer feedforward networks are universal approximators. *Neural Networks*, v. 2, n. 5, p. 359–366, 1989.

HUANG, S.; LEBLANC, M.; OHN, M. M.; MEASURES, R. M. Bragg intragrating structural sensing. *Applied optics*, v. 34, n. 22, p. 5003–5009, 1995.

IGEL, C.; HUSKEN, M. Improving the Rprop Learning Algorithm. *Proceedings of the Second International Symposium on Neural Computation. (Anais)*. p.115–121, 2000. [S.I].

JINGQIAO ZHANG; SANDERSON, A. C. JADE: Adaptive Differential Evolution With Optional External Archive. *IEEE Transactions on Evolutionary Computation*, v. 13, n. 5, p. 945–958, 2009.

KAMIZI, M. A.; POSSETTI, G. R. C.; MULLER, M.; FABRIS, J. L. Fiber Bragg grating sensors probed by artificial intelligence to detect and localize impacts on structures. *Journal of Microwaves, Optoelectronics and Electromagnetic Applications*, v. 14, n. SI-1, p. 25–34, 2015.

KANELLOS, G. T.; PAPAIOANNOU, G.; TSIOKOS, D.; et al. Two dimensional polymer-embedded quasi-distributed FBG pressure sensor for biomedical applications. *Optics express*, v. 18, n. 1, p. 179–186, 2010.

KERSEY, A. D.; DAVIS, M. A.; PATRICK, H. J.; et al. Fiber grating sensors. *Journal of Lightwave Technology*, v. 15, n. 8, p. 1442–1463, 1997.

KERSEY, A. D.; BERKOFF, T. A.; MOREY, W. W. Multiplexed fiber Bragg grating strain-sensor system with a fiber Fabry - Perot wavelength filter. *Optics letters*, v. 18, n. 16, p. 1370, 1993.

KONAR, A. **Computational Intelligence**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2005.

KREUTZ-DELGADO, K.; MURRAY, J. F.; RAO, B. D.; et al. Dictionary learning algorithms for sparse representation. *Neural computation*, v. 15, n. 2, p. 349–96, 2003.

LADICICCO, A.; CUSANO, A.; CUTOLO, A.; BERNINI, R.; GIORDANO, M. Thinned Fiber Bragg Gratings as High Sensitivity Refractive Index Sensor. *IEEE Photonics Technology Letters*, v. 16, n. 4, p. 1149–1151, 2004.

LEBLANC, M.; HUANG, S. Y.; OHN, M.; et al. Distributed strain measurement based on a fiber Bragg grating and its reflection spectrum analysis. *Optics letters*, v. 21, n. 17, p. 1405–7, 1996.

LENG, J.; ASUNDI, A. Structural health monitoring of smart composite materials by using EFPI and FBG sensors. *Sensors and Actuators A: Physical*, v. 103, n. 3, p. 330–340, 2003.

LIANG, W.; HUANG, Y.; XU, Y.; LEE, R. K.; YARIV, A. Highly sensitive fiber Bragg grating refractive index sensors. *Applied Physics Letters*, v. 86, n. 15, p. 151122, 2005.

LIU, W.; WANG, Z.; LIU, X.; et al. A survey of deep neural network architectures and their applications ☆. *Neurocomputing*, v. 234, n. October 2016, p. 11–26, 2017. Elsevier B.V.

LOURENÇO, I.; POSSETTI, G. R. C.; MULLER, M.; FABRIS, J. L. Fiber Bragg Grating Sensor to Monitor Stress Kinetics in Drying Process of Commercial Latex Paints. *Sensors*, v. 10, n. 5, p. 4761–4776, 2010.

LUSTIG, M.; DONOHO, D.; PAULY, J. M. Sparse MRI: The application of compressed sensing for rapid MR imaging. *Magnetic Resonance in Medicine*, v. 58, n. 6, p. 1182–1195, 2007.

MÉNDEZ, A. Fiber Bragg grating sensors: a market overview. *Proceedings of SPIE - The International Society for Optical Engineering. (Anais)*. v. 6619, p.661905, 2007. Nápoles.

MOHIMANI, H.; BABAIE-ZADEH, M.; GORODNITSKY, I.; JUTTEN, C. Sparse Recovery using Smoothed L0 (SL0): Convergence Analysis. , v. 0, p. 1–14, 2010. *Information Theory; Information Theory*, .

MOHIMANI, H.; BABAIE-ZADEH, M.; JUTTEN, C. A Fast Approach for Overcomplete Sparse Decomposition Based on Smoothed  $\ell_0$  Norm. *IEEE Transactions on Signal Processing*, v. 57, n. 1, p. 289–301, 2009.

MÜHLENBEIN, H.; SCHOMISCH, M.; BORN, J. The parallel genetic algorithm as function optimizer. *Parallel Computing*, v. 17, n. 6–7, p. 619–632, 1991.

MURIEL, M. A; AZAÑA, J.; CARBALLAR, A. Fiber grating synthesis by use of time-frequency representations. *Optics letters*, v. 23, n. 19, p. 1526–8, 1998.

NAND, A. **Intragrating Sensing Using Chirped Optical Fibre Bragg Gratings**, 2007. Victoria University.

NEDELL, D.; TROPP, J. A. CoSaMP: Iterative signal recovery from incomplete and inaccurate samples. *Applied and Computational Harmonic Analysis*, v. 26, n. 3, p. 301–321, 2009.

NEGRI, L.; NIED, A.; KALINOWSKI, H.; PATERNO, A. Benchmark for Peak Detection Algorithms in Fiber Bragg Grating Interrogation and a New Neural Network for its Performance Improvement. *Sensors*, v. 11, n. 12, p. 3466–3482, 2011.

NEGRI, L.; ZILLI, G.; CUNHA, C. DA; et al. FBG refractometry and electrical impedance analysis in fuel samples characterization. 2011 SBMO/IEEE MTT-S International Microwave and Optoelectronics Conference (IMOC 2011). (Anais). p.867–871, 2011. Natal: IEEE.

NICKOLLS, J.; BUCK, I.; GARLAND, M.; SKADRON, K. Scalable parallel programming with CUDA. *Queue*, v. 6, n. 2, p. 40, 2008.

OHN, M. M.; HUANG, S. Y.; MEASURES, R. M.; CHWANG, J. Arbitrary strain profile measurement within fibre gratings using interferometric Fourier transform technique. *Electronics Letters*, v. 33, n. 14, p. 1242, 1997.

PATERNO, A. S.; OLIVEIRA, V. DE; FIGUEREDO, T. S. S.; KALINOWSKI, H. J. J. Tunable filter interrogation method with a modulated fiber bragg grating. SBMO/IEEE MTT-S International Conference on Microwave and Optoelectronics, 2005., p. 9–12, 2005.

PATERNO, A. S.; SILVA, J. C. C.; MILCZEWSKI, M. S.; ARRUDA, L. V. R.; KALINOWSKI, H. J. Radial-basis function network for the approximation of FBG sensor spectra with distorted peaks. Measurement Science and Technology, v. 17, n. 5, p. 1039–1045, 2006.

QIN, A. K.; HUANG, V. L.; SUGANTHAN, P. N. Differential Evolution Algorithm With Strategy Adaptation for Global Numerical Optimization. IEEE Transactions on Evolutionary Computation, v. 13, n. 2, p. 398–417, 2009.

RAPP, S.; KANG, L.-H.; HAN, J.-H.; MUELLER, U. C.; BAIER, H. Displacement field estimation for a two-dimensional structure using fiber Bragg grating sensors. Smart Materials and Structures, v. 18, n. 2, p. 25006, 2009.

RIBEIRO, F. **Sensor inteligente em fibra ótica para localização de deformações em estruturas planas**, 2014. Universidade Tecnológica Federal do Paraná.

RIBEIRO, F.; COLLERE POSSETTI, G. R.; FABRIS, J. L.; MULLER, M. Smart optical fiber sensor for impact localization on planar structures. 2013 SBMO/IEEE MTT-S International Microwave & Optoelectronics Conference (IMOC). (Anais). p.1–3, 2013. Rio de Janeiro, RJ: IEEE.

RIEDMILLER, M.; BRAUN, H. A direct adaptive method for faster backpropagation learning: the RPROP algorithm. IEEE International Conference on Neural Networks. (Anais). p.586–591, 1993. [S.I]: IEEE.

SCHMIDHUBER, J. Deep learning in neural networks: An overview. Neural Networks, v. 61, p. 85–117, 2015. Elsevier Ltd.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas - Curso Prático**. Artliber, 2010.

SKAAR, J.; FECED, R. Reconstruction of gratings from noisy reflection data. Journal of the Optical Society of America. A, Optics, Image Science, and Vision, v. 19, n. 11, p. 2229–37, 2002.

SMOLA, A. J.; SCHÖLKOPF, B. A tutorial on support vector regression. Statistics and Computing, v. 14, n. 3, p. 199–222, 2004.

SONG, J.; JIANG, Q.; HUANG, Y.; et al. Research on pressure tactile sensing technology based on fiber Bragg grating array. Photonic Sensors, v. 5, n. 3, p. 263–272, 2015.

SRIVASTAVA, N.; HINTON, G. E.; KRIZHEVSKY, A.; SUTSKEVER, I.; SALAKHUTDINOV, R. Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research (JMLR)*, v. 15, n. 2, p. 1929–1958, 2014.

STORN, R. Differential Evolution – A Simple and Efficient Heuristic for Global Optimization over Continuous Spaces. *Journal of Global Optimization*, v. 11, n. 4, p. 341–359, 1997.

TIBSHIRANI, R. Regression Shrinkage and Selection via the Lasso. *Journal of the Royal Statistical Society B*, v. 58, n. 1, p. 267–288, 1996.

TROPP, J. A.; GILBERT, A. C. Signal recovery from random measurements via orthogonal matching pursuit. *IEEE Transactions on Information Theory*, v. 53, n. 12, p. 4655–4666, 2007.

VAPNIK, V.; GOLOWICH, S. E.; SMOLA, A. Support vector method for function approximation, regression estimation, and signal processing. *Advances in neural information processing systems*, p. 281–287, 1997.

VAPNIK, V. N. An overview of statistical learning theory. *IEEE Transactions on Neural Networks*, v. 10, n. 5, p. 988–999, 1999.

WANG, Y.; CHEN, N.; YUN, B.; YIPING, C. Use of Fiber Bragg Grating Sensors for Determination of a Simply Supported Rectangular Plane Plate Deformation. *IEEE Photonics Technology Letters*, v. 19, n. 16, p. 1242–1244, 2007.

WILAMOWSKI, B. M.; YU, H. Improved computation for Levenberg-Marquardt training. *IEEE transactions on neural networks / a publication of the IEEE Neural Networks Council*, v. 21, n. 6, p. 930–7, 2010.

YAMADA, M.; SAKUDA, K. Analysis of almost-periodic distributed feedback slab waveguides via a fundamental matrix approach. *Applied optics*, v. 26, n. 16, p. 3474–8, 1987. OSA.

YU, Y.; TAM, H.; CHUNG, W.; DEMOKAN, M. S. Fiber Bragg grating sensor for simultaneous measurement of displacement and temperature. *Optics Letters*, v. 25, n. 16, p. 1141–1143, 2000.