

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

FABIANO RIBEIRO

**SENSOR INTELIGENTE EM FIBRA ÓTICA PARA LOCALIZAÇÃO DE
DEFORMAÇÕES EM ESTRUTURAS PLANAS**

DISSERTAÇÃO

CURITIBA

2014

FABIANO RIBEIRO

**SENSOR INTELIGENTE EM FIBRA ÓTICA PARA LOCALIZAÇÃO DE
DEFORMAÇÕES EM ESTRUTURAS PLANAS**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do grau de “Mestre em Ciências” – Área de Concentração: Fotônica em Engenharia

Orientadora: Prof.^a Dr. Marcia Muller

Coorientador: Prof. Dr. José Luís Fabris

CURITIBA

2014

AGRADECIMENTOS

À minha família e amigos pelo apoio durante essa etapa importante da minha vida.

Aos professores Marcia Muller e José Luís Fabris pela orientação.

Aos colegas do laboratório de Laser pelas discussões decorridas durante o desenvolvimento deste trabalho, em especial ao Dr. Gustavo Rafael Collere Possetti.

À UTFPR e ao CPGEI pelas instalações e apoio financeiro para participação em eventos científicos.

À CAPES, CNPq, FINEP e Fundação Araucária pelo apoio financeiro.

RESUMO

RIBEIRO, Fabiano. **Sensor inteligente em fibra ótica para localização de deformações em estruturas planas**, 2014. Mestrado em Ciências – Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial, Universidade Tecnológica Federal do Paraná, Curitiba, 2014.

Neste trabalho é apresentado um estudo sobre a aplicabilidade de redes de Bragg na análise de impactos em estruturas planas. Para tanto, os dispositivos foram caracterizados, preliminarmente, quanto à deformação mecânica e temperatura. Nesta abordagem, para a validação experimental, quatro redes de Bragg foram fixadas nos cantos de uma placa de polimetilmetacrilato que, posteriormente, foi submetida a impactos mecânicos. Os efeitos de impactos produzidos na placa foram detectados pelas redes de Bragg, sendo que suas respostas em λ ao longo de 0,3 segundos foram utilizadas para treinar e testar redes neurais artificiais do tipo perceptron multicamadas. As localizações dos impactos nos quadrantes foram, então, fornecidas pela rede neural artificial, a qual demonstrou que a localização pode ser prevista com uma taxa de classificação correta de aproximadamente 90% na etapa de validação. Outra RNA foi implementada para localizar coordenadas de impacto, a qual permitiu fazer uma análise quantitativa dos erros, realizando uma comparação do valor desejado e o valor de saída da RNA na localização de um impacto em um plano. O maior erro quadrático médio (E_m) em relação ao valor alvo foi de 0,0802% na coordenada x, e 0,1406% para y, sendo que, o maior desvio padrão (σ_{E_m}) foi de 0,1793% para a coordenada x, e 0,3144% em y para todo o sistema, ou seja, as cinco coordenadas de impacto na etapa de teste da RNA.

Palavras-chave: Sensor em fibra ótica, Rede de Bragg, Rede neural artificial, Monitoramento de integridade estrutural.

ABSTRACT

RIBEIRO, Fabiano. **Smart optical fiber sensor for impact localization on planar structures**. Mestrado em Ciências – Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial, Universidade Tecnológica Federal do Paraná, Curitiba, 2014.

In this work the applicability of fiber Bragg gratings as tools for the analysis of impacts on planar structures was studied. In a first step, Bragg gratings were characterized and their thermal and strain sensitivities were determined. The experiments were carried out with four fiber Bragg gratings fixed at the corners of a polymethylmethacrylate board. The board was subsequently subjected to mechanical impacts detected by the four Bragg gratings. Being that their responses in λ along 0.3 second were used to train and test a multilayer perceptron artificial neural network. The locations of impacts in quadrants were supplied by the artificial neural network. The results demonstrate that such location can be predicted with correct classification rate of approximately 90.0% in validation step. Another RNA was implemented to locate impact coordinates, which allowed a quantitative analysis of errors by performing a comparison of the desired value and the output value of the RNA on the location of an impact on a plan. The highest mean square error (E_m) to the target value was 0,0802% at the coordinate x and 0,1406% for y, and the largest standard deviation (σ_{E_m}) was 0,1793% for the coordinated x and 0,3144% for y in throughout the system, namely the five coordinates of the impact test step RNA

Keywords: Optical fiber sensor, Fiber Bragg grating, Artificial neural network, Monitoring structural integrity.

LISTA DE FIGURAS

| | |
|--|----|
| Figura 1 - Alongamento de uma barra cilíndrica submetida a uma carga de tração uniaxial (Adaptada de SMITH, 1998). | 23 |
| Figura 2 - Representação da estrutura de uma fibra ótica. | 26 |
| Figura 3 - Representação esquemática do perfil de índice de fibras óticas comuns (adaptada de Agrawal, 1997). | 27 |
| Figura 4 – Representação da propagação da radiação eletromagnética em uma fibra ótica sem modulação periódica no núcleo (adaptada de KASHYAP, 1999; OTHONOS e KALLI, 1999). | 27 |
| Figura 5 - Representação da propagação da radiação eletromagnética em uma fibra ótica contendo uma FBG (adaptada de KASHYAP, 1999; OTHONOS e KALLI, 1999). | 29 |
| Figura 6 – Representação da gravação da FBG com máscara de fase. | 32 |
| Figura 7 - Diagrama de um neurônio biológico simplificado e um modelo matemático conhecido como neurônio artificial (adaptada de HAYKIN, 2008; DA SILVA et al., 2010). | 33 |
| Figura 8 - Desenho esquemático do sistema de gravação de FBGs pelo método de iluminação direta sobre a máscara de fase. | 36 |
| Figura 9 – Foto da montagem experimental para a caracterização da FBG quanto à deformação longitudinal mecânica. | 38 |
| Figura 10 – Diagrama esquemático para caracterização da FBG quanto à posição angular de impacto. | 42 |
| Figura 11 - Sistema de mapeamento de impactos instrumentado com as quatro FBGs. | 43 |
| Figura 12 - Diagrama esquemático da RNA utilizada para fornecer o quadrante da placa de ensaio de PMMA, submetido ao impacto mecânico. | 45 |
| Figura 13 - Diagrama esquemático da RNA utilizada para fornecer a localização (x, y) do impacto produzido na placa de ensaio de PMMA. | 47 |
| Figura 14 – Representação da variação do comprimento de onda central da FBG em função da deformação relativa. | 48 |
| Figura 15 - Representação da variação do comprimento de onda central da FBG em função da temperatura | 49 |

| | |
|---|----|
| Figura 16 – Resposta de uma FBG conforme posição angular da onda de choque mecânica, com impactos simulados em diferentes posições angulares em relação à direção de propagação da FBG. | 50 |
| Figura 17 – a) Montagem experimental com impacto simulado na posição (27,5; 27,0) cm, próximo da FBG 1; b) Espectro de quatro FBGs devido impacto mecânico simulado nas coordenadas (27,5; 27,0) cm, próximo da FBG 1..... | 51 |
| Figura 18 – a) Indicação das posições de impactos induzidos na placa; b) impacto gerado na posição (-27,5; -27,0 cm), próximo da FBG 1; c) impacto gerado na posição (26,0; -26,6) cm, próximo da FBG 2; d) impacto gerado na posição (27,0; 26,6) cm, próximo da FBG 3; e) impacto gerado na posição (-26,5; 26,5) cm, próximo da FBG 4; f) impacto gerado na posição (0; 0), no centro da placa. | 52 |
| Figura 19 - Respostas da RNA e valores alvos para os dados de treinamento. | 54 |
| Figura 20 - Respostas da RNA e valores alvos para os dados de validação. | 55 |
| Figura 21 - Respostas da RNA e valores alvos para os valores de treinamento de uma RNA implementada pra determinar posições de impactos em um plano. | 56 |
| Figura 22 - Respostas da RNA e valores alvos para os valores de teste de uma RNA implementada para determinar posições de impactos em um plano..... | 57 |

LISTA DE SIGLAS

| | |
|------|---|
| FBG | <i>"Fiber Bragg Grating"</i> – Rede de Bragg em fibra |
| KrF | <i>"Krypton Fluoride"</i> - Fluoreto de Criptônio |
| LED | <i>"Light Emitting Diode"</i> – Diodo Emissor de Luz |
| LPG | <i>"Long Period Grating"</i> – Rede de Período Longo |
| MLP | <i>"Multi-Layer Perceptron"</i> – Perceptron multi-camada |
| NDE | <i>"Non-Destructive Evaluation"</i> – Avaliação não destrutiva |
| PMMA | <i>"Polimetilmetacrilato"</i> |
| RBF | <i>"Radial Base Function"</i> – Função de base radial |
| RNA | <i>"Artificial neural network"</i> – Rede Neural Artificial |
| SHM | <i>"Structural Health Monitoring"</i> – Monitoramento de Integridade estrutural |
| UV | Ultravioleta |

SUMÁRIO

| | |
|---|----|
| 1 INTRODUÇÃO | 13 |
| 1.1 MOTIVAÇÕES | 13 |
| 1.2 ESTADO DA ARTE | 15 |
| 1.2.1 Sistema de monitoramento de integridade estrutural (SHM)..... | 15 |
| 1.2.2 O surgimento das redes de Bragg..... | 16 |
| 1.2.3 As FBGs como transdutores | 18 |
| 1.2.4 Sistemas de medição em fibra supervisionados por redes neurais artificiais... | 18 |
| 1.3 OBJETIVOS | 20 |
| 1.4 ESTRUTURA DO TRABALHO..... | 21 |
| 2 FUNDAMENTAÇÃO TEÓRICA | 22 |
| 2.1 FUNDAMENTOS SOBRE MECÂNICA | 22 |
| 2.1.1 Definição de tensão..... | 22 |
| 2.1.2 Definição de deformação e deslocamento | 23 |
| 2.1.3 Definições da lei de Hooke e módulo de Young..... | 24 |
| 2.1.4 Propagação de ondas mecânicas | 24 |
| 2.2 SENSORES EM FIBRA ÓTICA..... | 26 |
| 2.2.1 Propagação da radiação eletromagnética em fibras óticas..... | 26 |
| 2.2.2 Redes em fibra ótica | 27 |
| 2.2.3 FBGs: princípio de funcionamento | 29 |
| 2.2.4 Processos de gravação de FBGs..... | 31 |
| 2.3 REDES NEURAS ARTIFICIAIS | 33 |
| 3 METODOLOGIA | 36 |
| 3.1 FABRICAÇÃO DAS FBGs..... | 36 |
| 3.2 CARACTERIZAÇÃO DA FBG QUANTO À DEFORMAÇÃO LONGITUDINAL MECÂNICA | 37 |
| 3.3 CARACTERIZAÇÃO TÉRMICA DA FBG | 40 |
| 3.4 SISTEMA DE LOCALIZAÇÃO E CARACTERIZAÇÃO DE IMPACTOS..... | 42 |
| 3.4.1 Avaliação da influência de impactos na resposta da FBG..... | 42 |
| 3.4.2 Sistema experimental para mapeamento de impactos..... | 42 |
| 3.4.3 Identificação de quadrantes com RNA | 44 |
| 3.4.4 Localização de impactos com RNA | 46 |

| | |
|--|----|
| 4 RESULTADOS E DISCUSSÕES | 48 |
| 4.1 RESPOSTA DA FBG À DEFORMAÇÃO LONGITUDINAL MECÂNICA | 48 |
| 4.2 RESPOSTA TÉRMICA DA FBG | 49 |
| 4.3 RESPOSTA DA FBG QUANTO À DEFORMAÇÃO GERADA POR IMPACTOS EM DIFERENTES POSIÇÕES ANGULARES..... | 50 |
| 4.4 SISTEMA DE MEDIÇÃO DE IMPACTOS COM AS FBGs | 51 |
| 4.5 DETERMINAÇÃO DO QUADRANTE DE IMPACTO | 53 |
| 4.6 LOCALIZAÇÃO DE IMPACTOS EM UM PLANO COM RNA..... | 55 |
| 5 CONSIDERAÇÕES FINAIS | 59 |
| 5.1 CONCLUSÕES | 59 |
| 5.2 TRABALHOS FUTUROS | 60 |
| REFERÊNCIAS | 61 |
| APÊNDICES | 65 |

1 INTRODUÇÃO

1.1 MOTIVAÇÕES

Devido às constantes pesquisas na área de materiais, surgiram novas estruturas mais resistente e usada para diversos tipos de aplicações. Nesse sentido, surgem cada vez mais equipamentos e estruturas, que fazem parte da vida dos seres humanos. Sobretudo a indústria do século XXI, tem muitos desafios tecnológicos para produzir carros, barcos, aviões, entre outras aplicações não tripuladas e industriais que utilizam trabalho robô baseado na inteligência computacional. Essas tecnologias são utilizadas onde existe a demanda de trabalho repetitivo ou perigoso para as pessoas, por apresentar um alto risco de explosões, interferência eletromagnética ou por conter gases tóxicos.

Um dos campos de aplicação mais focados na atualidade é a indústria de equipamentos com alto nível tecnológico e embarcações não tripuladas, onde não há um piloto para tomar decisões ou verificar possíveis problemas de danos estruturais. Essas estruturas são controladas por sistemas inteligentes, que tomam decisões com base nos sinais recebidos de sensores, tornando-se um sistema de monitoramento de impactos de grande importância para um bom funcionamento da estrutura.

Os sistemas de monitoramento de integridade estrutural têm por finalidade detectar, danos estruturais. Segundo Rytter (1993), em sistemas avançados há um processo de cinco passos a ser seguido: (1) detectar a existência de dano; (2) localizá-lo na estrutura; (3) classificar o seu tipo; (4) ponderar a sua extensão; (5) avaliar o tempo restante de vida útil da estrutura.

Os sensores intrínsecos à fibra ótica são ideais para o desenvolvimento de métodos inovadores de monitoração, agregando maior segurança na estrutura, por medirem diversos parâmetros físico-químicos e por fornecerem uma baixa incerteza na unidade medida (LÓPEZ-HIGUERA, 1998). Quando supervisionados por inteligência artificial esses sensores podem compor soluções inteligentes e atrativas para monitoramento em tempo real de impactos nos domínios temporais ou de frequências.

Uma vez que estruturas podem se romper por desgaste de utilização ou impactos sofridos. Um sistema de localização de impactos proporciona um controle da qualidade de estruturas em tempo real ao longo da sua utilização minimizando problemas com acidentes. A falta de métodos de controle de qualidade em estruturas pode causar grandes prejuízos como acidentes, bem como alto custo de manutenção dos equipamentos.

Fica evidente a necessidade de um sistema auxiliar inteligente de medição em tempo real, e com baixa incerteza na grandeza medida. Entre os vários campos de aplicação desses sistemas inteligentes baseados em sensores óticos, estão as estruturas civis (plataformas, pontes, edifícios, estradas, etc.), as aeronáuticas, aeroespaciais (helicópteros, aviões, estações espaciais, satélites, etc.) e marítimas (submarinos e navios).

Segundo (KESSLER et al., 2002), um sistema de monitoramento de estruturas de uma aeronave poderia reduzir significativamente os custos de reparo e manutenção, que representam 27% do custo de seu ciclo de vida, por meio da detecção de danos em estágio inicial. Além disso, outros custos de manutenção da aeronave poderiam ser diminuídos devido ao menor tempo em que a aeronave permaneceria parada para serviços de manutenções.

Sistemas de monitoramento de impactos utilizam eventos dinâmicos complexos, envolvendo a detecção de diferentes tipos de ondas acústicas. Por isso, o desenvolvimento de ferramentas auxiliares, como os sistemas de medição inteligentes capazes de fornecer respostas confiáveis em tempo real, assumindo elevado grau de importância.

Sensores intrínsecos à fibra ótica, tais como as redes de Bragg (FBGs), quando aplicados como transdutores de deformação, possuem propriedades ímpares que os credenciam a serem utilizados para tais fins. Além disso, esses dispositivos apresentam uma baixa incerteza, menor que aquelas dos transdutores convencionais (LÓPEZ-HIGUERA, 1998). Entre suas particularidades se destacam a imunidade eletromagnética e a possibilidade de serem facilmente integradas às estruturas. Além disso, os sensores à fibra apresentam a passividade elétrica, a não reatividade química, o reduzido dimensionamento físico, o baixo tempo de resposta, o alto ponto de fusão, bem como a possibilidade de integração em enlaces óticos codificados em comprimento de onda e uma banda larga de detecção, e a capacidade de multiplexação (OTHONOS e KALLI, 1999).

Esses elementos transdutores óticos podem, ainda, ser supervisionados por redes neurais artificiais (RNA), que, além da inteligência, agregam maior robustez e confiabilidade aos sistemas de medição que as empregam (DA SILVA et. al, 2010; HAYKIN, 2008).

Neste trabalho é apresentado um estudo sobre a aplicabilidade da FBG como uma ferramenta auxiliar para análise de impactos em estruturas, a fim de constituir um sistema de medição inteligente, supervisionado por RNA. O sistema busca identificar a localização dos impactos em uma placa sofridos no decorrer de sua utilização, assim proporcionando um elevado grau de segurança à estrutura, com baixo custo de manutenção, devido à capacidade do sistema de monitorar e localizar impactos em tempo real.

1.2 ESTADO DA ARTE

Neste capítulo faz-se uma introdução sobre as redes de Bragg utilizadas como transdutores de deformação mecânica em sistemas de monitoramento de integridade estrutural. Discute-se o princípio de operação e as principais características dos dispositivos e das técnicas, bem como algumas limitações práticas e as metodologias sugeridas para contorná-las.

1.2.1 Sistema de monitoramento de integridade estrutural (SHM)

Um dano é qualquer tipo de modificação na estrutura que provoque uma diminuição de seu desempenho com o tempo. Podem-se considerar dois estados da estrutura, um onde ela é íntegra, sem nenhum dano, e outro onde é admissível perceber danos na estrutura. Neste caso, a estrutura apresentará alguma modificação na massa, dissipação de energia, impedância mecânica ou rigidez. Essas modificações na estrutura fazem com que suas respostas dinâmicas sejam alteradas, sendo possível a análise em modos de frequências da estrutura (SOHN et al., 2004).

Muitas das técnicas utilizadas em sistemas de SHM (*Structural Health Monitoring*), citadas por Sohn et al. (2004), têm origem nos métodos de avaliação não destrutiva, NDE (*Non-Destructive Evaluation*), tais como emissão acústica, vácuo comparativo, ondas de Lamb, inspeção por partícula magnética, correntes de

Eddy e as técnicas baseadas em fibra ótica que estão dentro do escopo deste trabalho.

Seguindo na mesma linha, Todd et al. (1999) aplicaram FBGs em uma ponte no sul do Novo México, bem como em um viaduto em construção nas proximidades de Lausanne, Suíça. Eles demonstraram que as FBGs podem ser úteis na monitoração de tráfego induzido por cargas, bem como, em cargas induzidas durante a fase de construção.

Todd, Johnson e Vohra (2000) desenvolveram um sistema de detecção de tensão para fornecer uma resolução confiável, com baixo ruído de dados. Os autores demonstraram o sistema em uma placa fixada e o dano foi causado por afrouxamento dos parafusos de fixação. Redes de Bragg (FBG) foram utilizadas como sensores usados para medir deformação mecânica em 16 locais da placa, foram conduzidos 8 testes de impacto na placa. Por exemplo, quando quatro parafusos foram totalmente apertados e quatro parafusos afrouxados, os pontos de impacto variaram, induziram diferentes tensões.

1.2.2 O surgimento das redes de Bragg

No decorrer de um experimento para estudar efeitos não lineares em fibras óticas especialmente projetadas, Hill et al., (1978) descobriram o fenômeno da fotossensibilidade. Acoplando a radiação eletromagnética de um laser de argônio a uma fibra de sílica dopada com germânio, a reflexão de Fresnel provocada pela radiação eletromagnética do laser na extremidade final da fibra, permitiu a formação de uma onda estacionária no núcleo da fibra. A modulação periódica produzida no índice de refração da sílica possibilitou observar um aumento de intensidade do sinal ótico refletido. A partir de então, foi desenvolvida uma nova classe de dispositivos em fibra, a qual foi denominada rede de Hill.

No início, a falta de interesse internacional no efeito da fotossensibilidade em fibras óticas foi decorrente da operação dos dispositivos estar limitada a comprimentos de onda somente na faixa do visível, faixa diferente daquela normalmente utilizada em comunicações óticas, e esse fenômeno esta presente somente em fibras óticas especiais. Porém, mais tarde, foi observado a fotossensibilidade em diferentes tipos de fibras, todas com alta concentração de germânio (STONE, 1987).

Um importante avanço na fabricação de redes de Bragg em fibra ótica ocorreu com o desenvolvimento de uma técnica de gravação externa, na qual a fibra é exposta a um padrão de interferência na região espectral do ultravioleta (UV) (MELTZ et. al, 1989). Com essa técnica foi possível produzir redes com períodos variados permitindo o acesso à região espectral de interesse em telecomunicações, situada no infravermelho próximo. Para tanto, foi usado um laser operando com comprimento de onda de 244 nm. As FBGs foram gravadas externamente por meio da interferência de dois feixes de radiação ultravioleta coerentes, que ilumina a fibra ótica lateralmente, produzindo uma modulação periódica no índice de refração da fibra ótica mais intensa que aquela verificada no método de Hill.

Em 1993, Hill et al., apresentaram uma técnica de gravação de redes baseada na iluminação direta de uma máscara de fase. Essa técnica é, provavelmente, a mais simples e reproduzível das técnicas de fabricação de redes de Bragg, por apresentar maior facilidade de alinhamento quando comparadas ao método que emprega um interferômetro. Outra grande vantagem dessa técnica foi permitir a gravação de FBGs em diferentes comprimentos de onda, sendo que o comprimento de onda de operação da rede não ficou mais limitado ao comprimento de onda do laser de gravação, sendo agora limitado pela periodicidade da máscara de fase.

O desenvolvimento das fibras e dos equipamentos utilizados para gravação de redes de Bragg tornou mais acessível sua utilização no desenvolvimento de dispositivos para aplicações em telecomunicações e sensoriamento. O ajuste de parâmetros de FBGs, como o tempo de exposição e potência, possibilitou gravar redes operando em diferentes comprimentos de onda na região do infravermelho. Isso permitiu conectar em um mesmo enlace de fibra ótica, diferentes dispositivos e viabilizou o sensoriamento quase distribuído.

A partir de então, o efeito passou a ser utilizado para a fabricação de filtros refletores de Bragg de banda estreita em fibra ótica (Hill e Meltz, 1997), que seriam conhecidos como redes de Bragg em fibra ótica, ou simplesmente FBGs (*fiber Bragg grating*).

1.2.3 As FBGs como transdutores

A literatura apresenta inúmeras aplicações para as redes de Bragg na área de sensores, entre as quais se incluem a monitoração de deformações mecânicas, que é a aplicação de interesse deste trabalho.

Laudatti et al., (2007) estudaram o comportamento temporal do espectro refletido pelas FBGs como ferramenta para a prevenção de abalos sísmicos e atividades vulcânicas, substituindo com sucesso os acelerômetros convencionais.

Uma FBG foi utilizada no desenvolvimento de um acelerômetro, para monitoração dinâmica de vibração em estruturas (ANTUNES et al., 2007). A medição de acelerações teve como objetivo a caracterização do comportamento dinâmico por meio das frequências naturais e modos de vibração.

Lourenço et al., desenvolveram FBGs encapsuladas para mensurar a deformação e temperatura durante o processo de secagem de tintas látex comercial. Essas FBGs encapsuladas permitiram realizar uma análise temporal da secagem de filmes poliméricos. Sendo que o sistema com a FBG encapsulada foi um sistema complexo, o qual utiliza uma FBG inserida em duas agulhas de injeção presas a uma mola. O sistema foi pintado com uma fina camada de tinta, o qual demonstrou que a FBG encapsulada foi capaz de monitorar as deformações mecânicas durante as etapas de secagem.

FBGs foram ainda utilizadas para medir tensão em respostas das frequências medidas, as quais foram utilizadas para identificar a localização de dano em duas placas. Simulações numéricas e experimentais foram feitas. Ambos os resultados mostraram a eficiência do método para identificar o local do dano (Liu et al., 2012).

Pearson et al., (2012) investigaram a localização de impactos de baixa velocidade e danos, de maneira experimental, usando FBGs como transdutores de deformação e uma análise computacional com o método de elementos finitos, para obter mapas de informações de como a falha se iniciava e se desenvolvia.

1.2.4 Sistemas de medição em fibra supervisionados por redes neurais artificiais

A ideia de se construir um sistema ou um mecanismo autônomo, dotado de inteligência e baseado na neurofisiologia e na matemática, é um sonho antigo dos pesquisadores das áreas de ciências e engenharia. Apesar de muitos trabalhos

terem sido publicados há mais de 50 anos, a técnica começou a ser fortemente pesquisada a partir do início dos anos 90, tendo um potencial de pesquisa imenso para resolver problemas de reconhecimento e classificação de padrões (DA SILVA et al., 2010; HAYKIN, 2008).

As aplicações que envolvem a utilização de sistemas considerados inteligentes são as mais variadas possíveis. RNAs, por exemplo, são bastante utilizadas para resolver problemas de classificação de reconhecimento padrões, mas sendo ainda pouco utilizadas na área de sensores óticos.

A literatura apresenta alguns trabalhos na área de sensores óticos, nos quais as RNAs foram utilizadas para classificar dados e fornecer informações sobre parâmetros monitorados. Chan et al., (2007), demonstraram técnicas para medições simultâneas de curvatura e temperatura usando FBGs e RNA.

RNAs foram utilizadas para estudar e modelar o espectro de reflexão de FBGs, propondo a inserção desse método matemático em sistemas de interrogação óticos para fins de sensoriamento. Constatou-se que uma maior eficiência e um menor erro na determinação da posição do comprimento de onda central da banda de reflexão da FBG, foram obtidos quando uma RNA com função de base radial (*Radial Base Function* - RBF) foi empregada na aproximação do espectro do dispositivo ótico (PATERNO et al., 2005).

É encontrado na literatura o desenvolvimento de superfícies táteis inteligentes instrumentadas com FBGs (MAIN et al., 2006; COWIE et al., 2007). Nesses sistemas, as deformações mecânicas foram induzidas estaticamente em uma superfície instrumentada com nove FBGs. As respostas desses dispositivos óticos foram utilizadas para implementar uma RNA capaz de determinar a localização, a forma e a orientação dos objetos colocados sobre a superfície. O sistema foi capaz de reconhecer corretamente a forma em 91% dos casos, quando conhecida a posição do objeto. Quando a posição não era conhecida, a taxa de detecção e classificação dos objetos foi de 89%.

RNAs do tipo RBF também foram implementadas para determinar zonas de conformidade de amostras, classificando amostras de gasolina em conformes e não-conformes aos padrões fixados pela legislação brasileira. Um conjunto de 165 amostras de gasolina comerciais, com parâmetros físico-químicos conhecidos, foi analisado utilizando um densímetro e uma LPG. A resposta fornecida por cada um desses equipamentos foi utilizada como dado de entrada para as RNAs, obtendo-se

uma taxa de classificação correta na etapa de teste de aproximadamente 94% (POSSETTI et al., 2009).

Costa et al., (2010) estudaram a aplicação de rede de período longo na avaliação de curvaturas. Os dados fornecidos pela rede de período longo para curvaturas em diferentes posições angulares foram utilizados para alimentar uma RNA. O sistema mostrou-se capaz de fornecer não só a magnitude de curvatura, como também a sua direção.

Loutas et al., (2012) caracterizaram deformações em uma estrutura aeronáutica composta de camadas de fibra de carbono, com quadros e longarinas, medindo (46x50) cm, com massa de 1,3 kg. Para tanto, foi utilizado um gerador de excitação com varrimento (0-500 Hz) induzindo por um agitador modal eletromecânico. Três FBGs foram fixadas no material para fazer a aquisição do sinal. Quando o gerador de excitação foi ligado, colocando a estrutura em modo de vibração, mensuraram-se as respostas das FBGs. Foram simulados 12 tipos de danos na estrutura colocando uma massa de 6 ou 12 g em cima da placa. Os sinais mensurados foram utilizados como entrada para treinar uma RNA do tipo máquina de vetor de suporte (SVM), que reconheceu a posição e o tipo do dano com sucesso.

O grande interesse na monitoração de estruturas torna importante o desenvolvimento de um sistema de monitoramento em tempo real que utilize técnicas avançadas de inteligência artificial em conjunto com as FBGs, e que ainda siga as recomendações metrológicas propostas por organizações de padronização.

1.3 OBJETIVOS

O objetivo principal deste trabalho é estudar a aplicabilidade da FBG como uma ferramenta para o monitoramento dinâmico de impactos em estruturas planares, com o intuito de compor um sistema de medição inteligente, supervisionado por RNA, apto a analisar deformações mecânicas em tempo real. Para tanto, estabeleceram-se os seguintes objetivos específicos:

- Produzir FBGs com características que permitam sua aplicação na análise de deformações mecânicas;

- Caracterizar as redes produzidas quanto à deformações longitudinais e variações de temperatura;
- Investigar a aplicabilidade das FBGs como transdutores de impacto;
- Utilizar ferramentas matemáticas como as RNAs para processar os dados fornecidos pelas FBGs e inferir a localização de impactos mecânicos.

1.4 ESTRUTURA DO TRABALHO

Esta dissertação está dividida em cinco seções. A primeira seção aborda as motivações, o estado da arte e os objetivos dessa dissertação. É apresentada uma discussão sobre a necessidade de um sistema de medição supervisionado por RNAs, para auxiliar no processo de determinação da localização de impactos. Nessa seção também são apresentados alguns trabalhos que empregam FBGs como transdutores de deformação mecânica ou utilizam RNAs como ferramentas capazes de supervisionar medições efetuadas com dispositivos óticos em fibra. A segunda seção traz a fundamentação teórica, uma visão geral sobre as FBGs e as RNAs, apresentando seus princípios de funcionamento. Na terceira seção é detalhada a metodologia utilizada para o desenvolvimento do trabalho, sendo feita uma descrição das caracterizações das FBGs e dos procedimentos realizados para efetuar as medidas. Na quarta seção é realizada uma discussão com base nos resultados obtidos. Por fim, na seção cinco são apresentadas as considerações finais e as propostas de continuidade do trabalho.

2 FUNDAMENTAÇÃO TEÓRICA

Nesse capítulo é feita uma breve análise sobre a propagação das ondas mecânicas em um sólido, a propagação de ondas em fibras, que será de grande importância para determinar as expressões que governam a sensibilidade das FBGs à deformação longitudinal mecânica e a temperatura, as quais são exploradas nesta dissertação, e uma visão geral sobre redes neurais artificiais. Os parâmetros vistos neste capítulo facilitam o entendimento das equações temporais para o deslocamento do comprimento de onda de Bragg, quando submetidas à deformações longitudinais mecânicas.

2.1 FUNDAMENTOS SOBRE MECÂNICA

2.1.1 Definição de tensão

Quando um corpo de prova é submetido a um ensaio de tração, é possível fazer um gráfico que mostra as relações entre a força aplicada e as deformações ocorridas durante o ciclo. O que interessa para determinação das propriedades do material é a relação entre a tensão e a deformação. A tensão (σ_{xx}) corresponde à força (F) dividida pela área (S_o) da seção sobre a qual a força é aplicada, conforme equação 1.

Tensão é definida genericamente como a resistência interna de uma força externa aplicada sobre um corpo, por unidade de área. Onde F é a carga instantânea aplicada em uma direção perpendicular à seção reta da amostra, e S_o , representa a área da seção reta original antes da aplicação da carga (CALLISTER, 2002).

$$\sigma_{xx} = \frac{F}{S_o} \quad (1)$$

2.1.2 Definição de deformação e deslocamento

A deformação é definida como a variação de uma dimensão qualquer desse corpo, por unidade da mesma dimensão, quando submetido a um esforço qualquer, representada de acordo com a equação 2. Sendo que, l_0 é o comprimento original da amostra antes da aplicação da carga, e l_i é o comprimento instantâneo. A grandeza $(l_i - l_0)$ é simbolizada por Δl , e representa a deformação ou a variação no comprimento a um dado instante.

Neste tipo de ensaio mede-se a variação no comprimento (l) como função da carga (F) aplicada. No Sistema Internacional de unidades (SI), a unidade de deformação, é dada em metro por metro (m/m) (CALLISTER, 2002).

$$\varepsilon = \frac{l_i - l_0}{l_0} = \frac{\Delta l}{l_0} \quad (2)$$

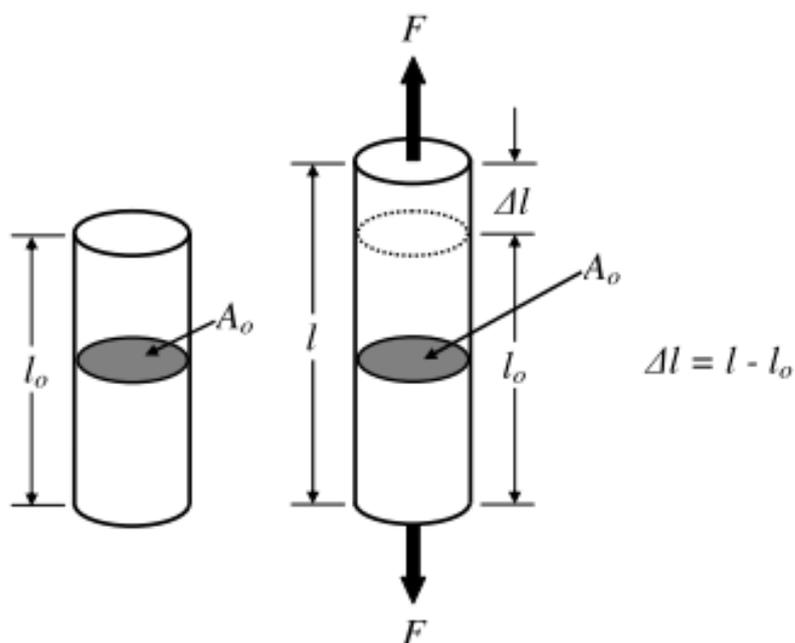


Figura 1 - Alongamento de uma barra cilíndrica submetida a uma carga de tração uniaxial (Adaptada de SMITH, 1998).

2.1.3 Definições da lei de Hooke e módulo de Young

A lei de Hooke apresenta uma proporcionalidade entre a tensão aplicada e a deformação obtida. Em um corpo em estado uniaxial em x , a tensão é dada pela equação 3.

$$\sigma_{xx} = E\varepsilon_{xx}$$

$$E = \frac{\sigma_{xx}}{\varepsilon} = \frac{F \cdot l_0}{A_0 \cdot \Delta l} \quad (3)$$

Para os materiais poliméricos, os valores dos módulos de elasticidade são menores em relação aos metais, variando entre 0,007 a 4 GPa (CALLISTER, 2002). A constante de proporcionalidade E , denominada módulo de elasticidade ou módulo de Young, fornece uma indicação da rigidez do material (resistência do material à deformação elástica), fase em que o módulo de Young tem a mesma dimensão que a tensão.

2.1.4 Propagação de ondas mecânicas

A análise das propriedades acústicas do PMMA (polimetilmetacrilato) é importante para determinar como o material reage, antes e depois de sofrer impactos mecânicos, os impactos podem gerar ondas mecânicas, e mudar as propriedades físico-químicas do material. A absorção é uma propriedade do material, a qual absorve parte da energia e a converte em calor, enquanto que a atenuação inclui a perda de energia devido à dispersão e reflexão (MARK, 2007).

Essas propriedades mudam conforme a frequência do impacto gerado, podendo ser ondas na faixa de frequência de áudio, bem como ondas ultrassônicas. As ondas acústicas geradas no material podem ser caracterizadas pela sua velocidade de propagação e absorção sonora (MARK, 2007).

Em um sólido isotrópico, os dois principais tipos de ondas que se propagam são a longitudinal, na qual os segmentos da cadeia vibram em direção à propagação e a de cisalhamento ou transversal, nas quais o movimento dos segmentos é perpendicular à direção de propagação.

Esses dois tipos de ondas se propagam independentemente, sendo que as velocidades das ondas longitudinal v_l e transversal v_s estão diretamente relacionadas com as constantes elásticas do material, conforme relação das equações 4 e 5. Onde k é o módulo de volume, G é o módulo de cisalhamento; e ρ a densidade. Na Tabela 1, estão representadas algumas das principais propriedades do PMMA, como a densidade e as velocidades típicas das ondas longitudinais e transversais (MARK, 2007).

$$v_l = \sqrt{\frac{k + 4G/3}{\rho}} \quad (4)$$

$$v_s = \sqrt{\frac{G}{\rho}} \quad (5)$$

Tabela 1 – Propriedades do PMMA em 25° C e 1 MHz (adaptado de MARK [2007])

| Nome do Material | Densidade (g/cm^3) | v_l (m/s) | v_s (m/s) |
|------------------|------------------------|-------------|-------------|
| PMMA | 1,191 | 2,690 | 1,340 |

v_l = velocidade da onda longitudinal, v_s = velocidade da onda transversal.

As ondas acústicas geradas no PMMA tem alta velocidade de propagação, portanto a sua detecção exige a utilização de equipamentos com alta taxa de amostragem. O sistema sensor proposto neste trabalho utiliza redes de Bragg e um interrogador de redes IBSEN PHOTONICS IMON-512E COM TAXA DE AMOSTRAGEM DE 970 HZ. Considerando a menor velocidade de propagação de 1340 m/s e a taxa de amostragem de 970 Hz, a separação temporal entre dois pontos consecutivos de aquisição é de (~1 ms), a qual corresponderia a uma resolução espacial em torno de (~1,4 m). Devido a essa limitação instrumental, o funcionamento do sistema proposto baseia-se na medição das deformações sofridas pela placa devido ao impacto produzido e não na detecção de ondas acústicas.

2.2 SENSORES EM FIBRA ÓTICA

2.2.1 Propagação da radiação eletromagnética em fibras óticas

Fibras óticas são produzidas com materiais dielétricos, geralmente sílica, as quais funcionam como um guia de onda capaz de confinar e guiar ondas eletromagnéticas graças à diferença entre os índices de refração da casca e do núcleo que varia de 0,001 a 0,01 μm . Essa pequena diferença se deve a diferentes concentrações de elementos dopantes presentes no núcleo e na casca da fibra. A Figura 2 representa as camadas presentes em uma fibra ótica (AGRAWAL, 1997).

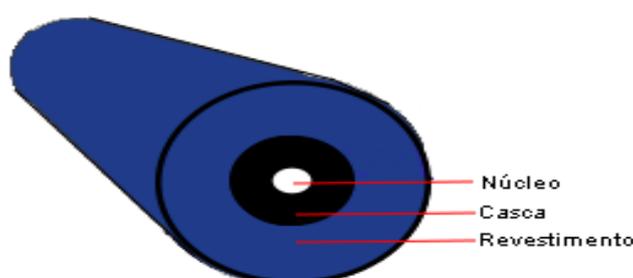


Figura 2 - Representação da estrutura de uma fibra ótica.

A radiação eletromagnética acoplada na fibra é guiada através do núcleo da mesma, com baixa perda da amplitude tornando, possível o envio de sinais óticos por longas distâncias. As equações de Maxwell descrevem a propagação das ondas eletromagnéticas nas fibras óticas, fornecendo um conjunto de soluções que, dependem das condições de contorno impostas pela geometria e constituição da fibra. Dessa forma, a radiação eletromagnética acoplada no guia se propaga por meio de modos de propagação que correspondem as distribuições de campo fornecidas pelas equações de Maxwell para o guia de onda. Tais modos determinam a distribuição espacial da energia confinada no guia (GOWAR, 1984; AGRAWAL, 1997; OKAMOTO, 2000).

As fibras óticas podem ser classificadas de acordo com o perfil espacial do índice de refração, sendo as mais comuns as fibras: multimodo com perfil de índice degrau, multimodo com perfil de índice gradual e monomodo com perfil de índice degrau. Uma representação esquemática do perfil de índice de refração dessas fibras óticas e de como se dá a propagação das ondas no seu interior está mostrada na Figura 3 (AGRAWAL, 1997).

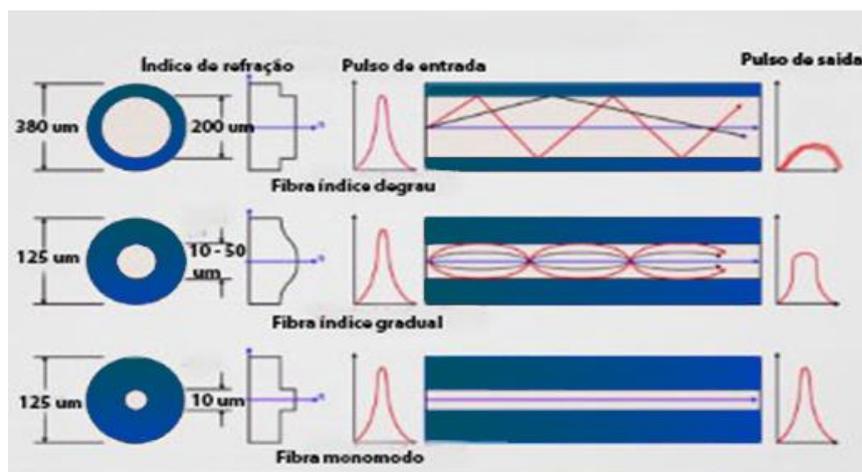


Figura 3 - Representação esquemática do perfil de índice de fibras ópticas comuns (adaptada de Agrawal, 1997).

Uma fibra óptica monomodo é constituída por um cilindro chamado de núcleo, com índice de refração n_1 , recoberto por uma casca cilíndrica com índice de refração n_2 . Fibras monomodo têm o diâmetro do núcleo pequeno, geralmente da ordem de $12 \mu m$, suportando somente um modo de propagação, conhecido como modo fundamental de núcleo, conseqüentemente, não se evidenciam alterações em seu espectro de transmissão, conforme ilustra a Figura 4 (GOWAR, 1984; AGRAWAL, 1997).



Figura 4 – Representação da propagação da radiação eletromagnética em uma fibra óptica sem modulação periódica no núcleo (adaptada de KASHYAP, 1999; OTHONOS e KALLI, 1999).

2.2.2 Redes em fibra óptica

Acoplamentos entre os modos podem acontecer se a estrutura da fibra óptica possuir uma perturbação periódica em seu núcleo, ocorrendo mudanças no espectro do sinal transportado (HILL et al., 1978; KASHYAP, 1999). A formação de redes permanentes em fibras ópticas foi demonstrada por Hill et al., no *Canadian*

Communications Research Centre (CRC) em 1978. A rede é uma modulação periódica no índice de refração de uma fibra ótica ao longo da direção longitudinal que pode ser induzida, proposital e preferencialmente em seu núcleo, por meio de técnicas óticas, químicas, térmicas ou mecânicas (HILL et al., 1978; KASHYAP, 1999; OTHONOS e KALLI, 1999).

As redes em fibra podem ser basicamente divididas em redes de Bragg (FBGs- *Fiber Bragg Grating*) também denominadas redes de reflexão ou redes de período curto, e em redes de período longo (LPG – *Long Period Grating*) também denominadas redes de transmissão. Nas FBGs, o período da modulação induzida no índice de refração do núcleo da fibra é da ordem de micrometros enquanto que nas LPGs, esta periodicidade é tipicamente da ordem de centenas de micrometros. Nas FBGs, a modulação de índice de refração é responsável pelo acoplamento entre os modos de núcleo que se propagam em sentidos opostos.

No caso das LPGs, o período de modulação de índice de refração da ordem de centenas de micrometros leva a uma condição de casamento de fase intermodal específica, fazendo com que o modo principal de núcleo guiado seja acoplado preferencialmente para modos de casca copropagantes (KASHYAP, 1999; OTHONOS e KALLI, 1999; BATHIA et al., 1996).

O interesse da aplicação das fibras óticas no campo dos sensores diz respeito às características e propriedades que estas apresentam na medição de diversos parâmetros físicos. Esses dispositivos merecem destaque pela sua importância em aplicações tanto no campo dos sensores como na área das telecomunicações.

Sensores baseados em FBGs são apropriados à integração direta no material que compõe as estruturas a monitorar. Podem ser inseridos diretamente em cimento, plásticos ou materiais compósitos. As reduzidas perdas de transmissão de sinal em longas distâncias tornam viáveis a sua utilização para monitorar grandes estruturas de engenharia civil como pontes, túneis, barragens, entre outros. Tais sensores possuem ainda a capacidade de poder ser integrados em ambientes com elevado ruído eletromagnético e/ou potencialmente perigosos, tornando-os uma solução muito competitiva no monitoramento de grandes máquinas elétricas ou na exploração petrolífera (LÓPEZ-HIGUERA, 1998).

2.2.3 FBGs: princípio de funcionamento

As FBGs em fibra ótica são dispositivos capazes de medir variações da temperatura, pressão, deformação mecânica, índice de refração, flexão, entre outros (OTHONOS e KALLI, 1999; KASHYAP, 1999). O modo geral de operação de sensores baseados em FBGs resulta da influência que esses parâmetros físicos exercem sobre o dispositivo afetando direta ou indiretamente a propagação da radiação eletromagnética.

Independentemente da quantidade de modos guiados, o sinal ótico se propaga na fibra por meio de modos que irão neste caso interagir entre si, gerando interferência, devido à diferença de fase ou percurso, os quais causam alterações no espectro de transmissão/reflexão, conforme ilustra a Figura 5.

Quando o comprimento de onda do modo de propagação do campo ótico incidente satisfaz a condição de Bragg, as frações de intensidade refletidas por cada um dos planos consecutivos da estrutura são adicionadas construtivamente, resultando em um sinal refletido. Quando a condição de Bragg não é verificada, as componentes refletidas pelos planos tornam-se progressivamente fora de fase, acabando por se anular (KASHYAP, 1999). A Figura 5 representa a propagação de um campo ótico em uma fibra contendo uma FBG.



Figura 5 - Representação da propagação da radiação eletromagnética em uma fibra ótica contendo uma FBG (adaptada de KASHYAP, 1999; OTHONOS e KALLI, 1999).

A condição de Bragg impõe que o espectro de reflexão esteja centrado no comprimento de onda de Bragg, λ_B , onde n_{eff} é o índice de refração efetivo do

modo guiado, e Λ é o período da modulação do índice de refração, representada na equação 6.

$$\lambda_B = 2\Lambda n_{eff} \quad (6)$$

Quando sujeitas a perturbações externas, as FBGs apresentam uma variação no comprimento de onda de Bragg refletido, que depende da variação do índice de refração efetivo do núcleo da fibra e da periodicidade da modulação de índice. Qualquer perturbação externa que venha a interagir com o coeficiente termo-ótico, coeficiente de expansão térmica e constante fotoelástica, poderá ser percebida pela consequente alteração no comprimento de onda de Bragg. A alteração no comprimento de onda de Bragg, devido a variações de temperatura, ΔT , ou a deformações mecânicas, Δl , é dada pela equação 7, conforme (OTHONOS e KALLI, 1999).

$$\Delta\lambda_B = 2 \left(\Lambda \frac{\partial n_{eff}}{\partial l} + \eta_{eff} \frac{\partial \Lambda}{\partial l} \right) \Delta l + 2 \left(\Lambda \frac{\partial n_{eff}}{\partial T} + \eta_{eff} \frac{\partial \Lambda}{\partial T} \right) \Delta T \quad (7)$$

O primeiro termo da equação 7 representa o efeito da perturbação mecânica no comprimento de onda refletido, enquanto que o segundo termo representa o efeito da variação da temperatura.

Para uma rede não sujeita a perturbações térmicas $\Delta T=0$, as perturbações mecânicas acarretarão em mudança no espaçamento da rede e no índice de refração efetivo. A sensibilidade à deformação longitudinal mecânica, tanto para tração quanto para compressão, gera um deslocamento no comprimento de onda de Bragg, representado pela equação 8 (HILL, 1978; MELTZ, 1997).

$$\frac{\Delta\lambda_B}{\lambda_B} = (1 - \rho_e) \varepsilon_{11} \quad (8)$$

Em que ρ_e representa o coeficiente elasto-ótico, e ε_{11} representa a componente de deformação relativa por unidade de comprimento. A sensibilidade média encontrada na literatura para a FBG quanto à deformação mecânica é $1,2 \text{ pm}/\mu\varepsilon$.

A sensibilidade à temperatura é resultante da modificação do espaçamento da rede devido à expansão térmica da sílica (prioritariamente em temperaturas

superiores a 800 °C) e da mudança do índice de refração devido ao efeito termo-ótico.

Considerando uma rede não sujeita a perturbações mecânicas ($\Delta l=0$), o deslocamento no comprimento de onda de Bragg devido ao efeito da variação da temperatura ΔT , conforme o segundo termo da equação 7 (OTHONOS e KALLI, 1999).

$$\frac{\Delta\lambda_B}{\lambda_B} = (\alpha + \xi)\Delta T \quad (9)$$

Em que λ_B é o comprimento de onda de Bragg inicial, α é o coeficiente de expansão térmica e ξ é o coeficiente termo-ótico, dados por:

$$\alpha = \frac{1}{\Lambda} \left(\frac{\partial \Lambda}{\partial T} \right) \quad (10)$$

$$\xi = \frac{1}{\eta_{eff}} \left(\frac{\partial \eta_{eff}}{\partial T} \right) \quad (11)$$

O coeficiente de expansão térmica no caso da sílica é $\alpha = 0,55 \cdot 10^{-6} \text{ } ^\circ\text{C}^{-1}$ e o coeficiente termo-ótico no caso da sílica dopada com germânio é $\xi = 8,6 \cdot 10^{-6} \text{ } ^\circ\text{C}^{-1}$. Esses valores quando aplicados na equação 9 resultam em uma sensibilidade típica da ordem de 13 pm/°C, para um comprimento de onda inicial de 1550 nm (OTHONOS e KALLI, 1999).

2.2.4 Processos de gravação de FBGs

Os processos para gravação de FBGs mais amplamente utilizados usam a potencia ótica de um laser que emite no ultravioleta (UV) para produzir a modulação no índice de refração da fibra devido ao efeito da fotossensibilidade do material. No caso das fibras de germânio silicato, a mudança do índice de refração ocorre entre outros fatores pela interação com defeitos pontuais denominados “centros de cor”, explicados pelo modelo de Kramers-Kronig. Inicialmente, os defeitos nesse tipo de fibra aparecem no processo de fabricação. Quando a fibra é fabricada usando a técnica MCVD (*Modified Chemical Vapor Deposition*) aparecem centros de germânio deficitários em oxigênio, conhecidos como GODC (*Germanium Oxygen-Deficient Centers*) que apresentam uma banda de absorção no ultravioleta centrada em 240

nm. Assim, a fotossensibilidade à radiação UV é determinada pela concentração desses centros deficitários em oxigênio (OTHONOS e KALLI, 1999).

A gravação de uma FBG pode ser gerada por uma exposição da fibra a um padrão de interferência intenso no UV (HILL e MELTZ, 1997). Os métodos interferométricos baseiam-se na divisão do feixe laser em dois feixes, com amplitudes idênticas, e subsequente recombinação dos dois sobre a fibra de modo a formar um padrão de interferência.

Por apresentar maior facilidade de uso, a técnica interferométrica mais difundida, é a baseada na iluminação direta de uma máscara de fase com a luz de um laser no UV. As máscaras de fase são redes de difração, que são produzidas por meio da realização de ranhuras no substrato com espaçamento adequado ao comprimento de onda do laser. Geralmente, a ordem 0 do padrão de difração da máscara possui menos de 3% de potência já as ordens -1 e +1 carregam 40% de potência transmitida.

O método de gravação baseado na iluminação direta da máscara de fase apresenta vantagens em relação aos métodos que empregam interferômetros. Esse método não requer uma montagem experimental complexa para gravação, apresenta boa reprodutibilidade e, principalmente, não exige alta coerência temporal e espacial da fonte UV usada na gravação, conforme ilustrado na Figura 6 (HILL et al., 1993).

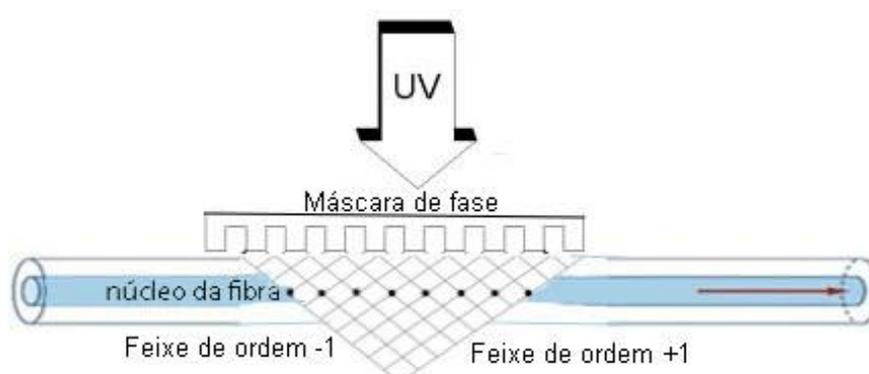


Figura 6 – Representação da gravação da FBG com máscara de fase.

Sob incidência normal na superfície, o período espacial da FBG gravada é igual a metade do período espacial da máscara de fase. Este período juntamente com a modulação de índice gerada define o comprimento de ressonância da rede de Bragg dado pela equação 6, em que Λ é o período espacial da modulação de índice

de refração e Λ_{mf} é a periodicidade espacial da máscara de fase, conforme equação 12 (OTHONOS, 1999; KASHYAP, 1999).

$$\Lambda = \frac{\Lambda_{mf}}{2} \quad (12)$$

2.3 REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais (RNA) integram o campo da ciência ligado à inteligência artificial (HAYKIN, 2008; DA SILVA et al., 2010). Redes neurais artificiais são modelos computacionais inspirados no sistema nervoso dos seres vivos. Tais redes possuem a capacidade de aquisição e manutenção do conhecimento (baseado em informações) e podem ser definidas como um conjunto de unidades de processamento, caracterizadas por neurônios artificiais, que são interligados por um grande número de interconexões (sinapses artificiais), sendo as mesmas representadas por vetores/ matrizes de pesos sinápticos.

No cérebro humano o processamento de informações é regido por elementos processadores biológicos, que operam em paralelo, tendo como objetivo a produção de ações apropriadas para cada uma de suas finalidades, tais como pensar e o memorizar. O neurônio biológico pode ser classificado em três partes principais: os dendritos, o corpo celular e o axônio, conforme ilustrado na Figura 7.

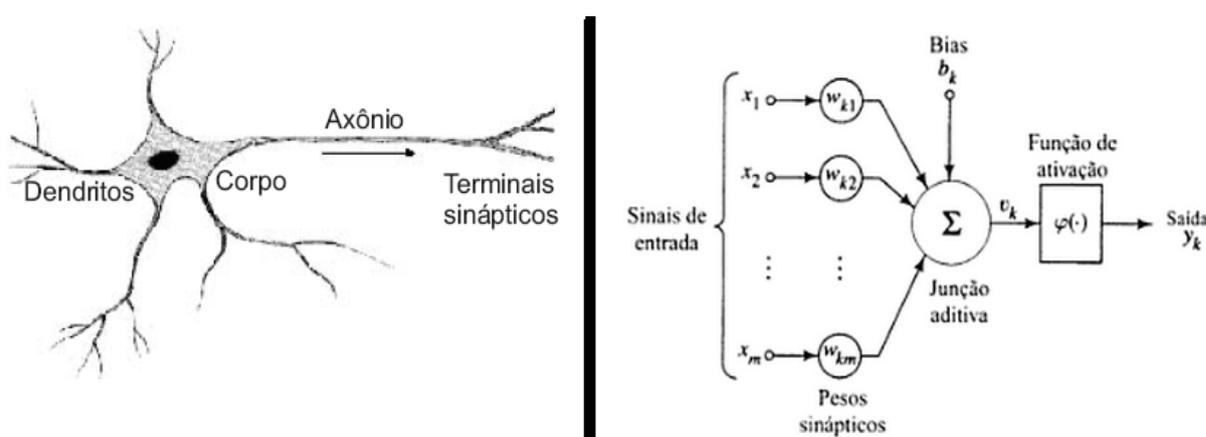


Figura 7 - Diagrama de um neurônio biológico simplificado e um modelo matemático conhecido como neurônio artificial (adaptada de HAYKIN, 2008; DA SILVA et al., 2010).

Os dendritos são constituídos por vários prolongamentos finos que formam a árvore dendrital. Sua principal função consiste em captar, de forma contínua os

estímulos vindos de diversos outros neurônios (conectores), ou do próprio meio externo onde os mesmos podem estar em contato (neurônios sensitivos). O corpo celular é incumbido de processar todas as informações, advindas dos dendritos a fim de produzir um potencial de ativação. A qual indicará se o neurônio poderá disparar um pulso elétrico ao longo de seu axônio, cuja missão é conduzir os pulsos elétricos para outros neurônios conectores, conectados aos dendritos de outra célula por meio de sinapses ou para aqueles que se conectam diretamente com o tecido muscular (neurônios efetadores). As sinapses são conexões que viabilizam a transferência de impulso elétrico do axônio de um neurônio para os dendritos de outros (HAYKIN, 2008; DA SILVA et al., 2010).

Um neurônio artificial, conforme a Figura 7, é constituído por sinais de entrada (x_1, x_2, x_3) , que representam os sinais ou medidas do meio externo, ou seja, o valor assumido pelas variáveis de uma aplicação específica. Os pesos sinápticos $(\omega_{k1}, \omega_{k2}, \omega_{km})$ são um conjunto de elos de conexões (sinapses), da mesma forma que acontece com o neurônio biológico, sendo caracterizados por um peso ou força própria que ponderam cada uma das variáveis de entrada da rede. Isso permite quantificar a relevância em relação à funcionalidade do respectivo neurônio. A junção aditiva (Σ) tem como função agregar todos os k -ésimos sinais de entrada (x_1, x_2, x_3) multiplicados pelos seus respectivos pesos sinápticos, a fim de produzir um valor de potencial de ativação. O termo de polarização (b_k) é uma variável que especifica qual será o valor apropriado para que o resultado produzido pela função aditiva (Σ) possa gerar um valor de disparo em direção à saída do neurônio. O potencial de ativação é a diferença do valor produzido entre a função aditiva (Σ) e o limiar de ativação. O sinal acumulado é apresentado à função de ativação (φ) tendo como objetivo limitar a saída do neurônio dentro de um intervalo de valores razoáveis a serem assumidos, fornecendo-os como sinal de saída (y) (HAYKIN, 2008; DA SILVA et al., 2010).

As RNAs são bastante utilizadas para resolver problemas complexos que não apresentam um padrão linear. Para tanto, faz-se necessário definir uma arquitetura de RNA, escolhendo a forma como seus neurônios serão arranjados. Esses arranjos são estruturados por meio do direcionamento das conexões sinápticas dos neurônios. É necessário também definir uma topologia eficiente de uma RNA escolhendo a quantidade de neurônios e o tipo da função de ativação para resolver

cada problema específico. As RNAs são constituídas, normalmente, por camadas de neurônios artificiais, unidades de armazenamento e de transformação da informação, que são interligadas por meio das conexões sinápticas (HAYKIN, 2008; DA SILVA et al., 2010).

As funções de uma RNA geralmente relacionam as variáveis de entrada (x) e da saída (y) de um sistema, independentemente da linearidade envolvida nas associações, podendo ser úteis, particularmente, em procedimentos de classificação e/ou agrupamentos (HAYKIN, 2008; DA SILVA et al., 2010).

As RNAs apresentam uma capacidade de aprender a partir da apresentação de amostras padrão que exprimem o comportamento do sistema, utilizando um algoritmo cuja tarefa é ajustar, da melhor forma possível, os valores dos pesos sinápticos, após o aprendizado da rede. O relacionamento entre as entradas e as saídas, possibilita a RNA generalizar soluções, sendo capaz de produzir uma saída próxima daquela esperada a partir de quaisquer sinais inseridos em suas entradas (HAYKIN, 2008; DA SILVA et al., 2010).

3 METODOLOGIA

3.1 FABRICAÇÃO DAS FBGs

A gravação das FBGs foi realizada na UTFPR, campus Curitiba, no laboratório de Nanoestruturas (LANOE), utilizando fibra ótica monomodo padrão (Furukawa G-652). O método de gravação foi interferométrico, com iluminação direta da máscara de fase por um laser de excímero KrF (*Coherent, Xantos XS*) que emite radiação UV em comprimento de onda de 248 nm. O padrão de interferência produzido pela máscara de fase foi focalizado no núcleo de uma fibra ótica monomodo padrão, que foi colocada em uma região bem próxima da máscara de fase, resultando em uma modulação periódica do índice de refração da fibra. A Figura 8 ilustra o sistema que foi utilizado para gravar as redes de Bragg.

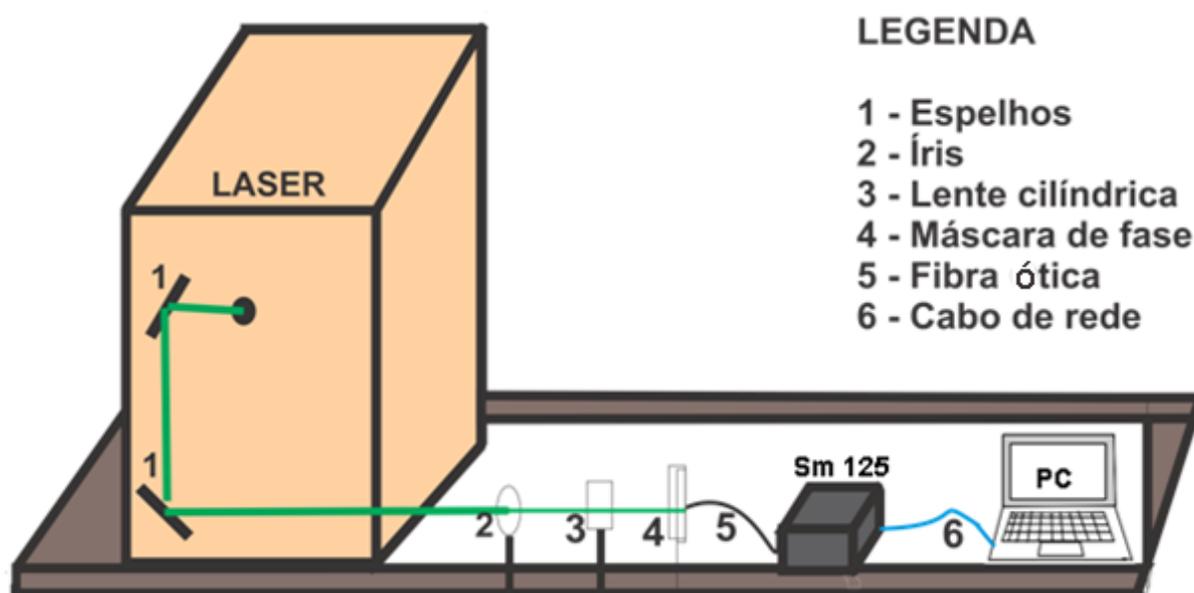


Figura 8 - Desenho esquemático do sistema de gravação de FBGs pelo método de iluminação direta sobre a máscara de fase.

Devido à metodologia proposta usar ao mesmo tempo quatro FBGs centradas em comprimentos de onda diferentes, foram utilizadas quatro máscaras de fase com periodicidades espaciais diferentes no processo de gravação. Foram produzidas redes com ressonâncias centradas em 1534, 1538, 1540 e 1542 nm utilizando máscaras de fase com períodos espaciais de 1060, 1062,5, 1064,5 e 1066,5 nm. A

energia do laser foi de 6 mJ por pulso e a frequência foi de 300 Hz, sendo o tempo de gravação aproximado de 5 minutos.

Durante todo o processo de gravação, o espectro de reflexão da rede em gravação foi acompanhado usando para tanto um interrogador (Micron Optics, sm125, com estabilidade em comprimento de onda de 5 pm), dispositivo utilizado para fazer a aquisição e o processamento dos sinais durante a gravação das FBGs.

3.2 CARACTERIZAÇÃO DA FBG QUANTO À DEFORMAÇÃO LONGITUDINAL MECÂNICA

O procedimento experimental adotado para determinar a sensibilidade da FBG quanto à deformação longitudinal foi realizada com uma FBG dentre um conjunto de 10 FBGs gravadas sob condições similares. O valor de sensibilidade obtido foi adotado para outras FBGs do conjunto. A caracterização foi realizada utilizando um estágio de translação linear, o qual foi acoplado a um relógio comparador analógico (Mitutoyo 2046F), com resolução de 0,01 mm. O estágio de translação linear foi composto por uma base fixa e uma base móvel. A base móvel foi colocada sobre um motor (DC) microposicionador (Macrocontrole, MF 04CC), cujo deslocamento foi controlado eletronicamente.

Nessa técnica, foram fixadas as extremidades da fibra contendo a FBG, conforme Figura 9, sendo que a FBG apresentava um comprimento de onda de Bragg em 1540 nm, a qual serviu de referência para o conjunto de FBGs gravadas. À distância $d_{inicial}$ de 150 mm entre as extremidades coladas da FBG ficou livre para sofrer deformação mecânica. Essa porção da fibra foi distendida até um valor máximo (Δd) de 0,2 mm, em passos de 0,01 mm. Foi utilizado o relógio comparador para mensurar a deformação do transdutor e os ensaios foram realizados em uma temperatura controlada de $(20,0 \pm 0,5)$ °C.

O deslocamento no comprimento de onda de Bragg da FBG, para cada deformação realizada, foi mensurado com o interrogador (IBSEN PHOTONICS IMON-512E, 970 Hz de frequência máxima de medição, resolução de 0,5 pm), sendo utilizada como fonte luminosa um LED superluminescente (Superlum, Pilot-2, 1445-1645 nm). Para cada distensão, foram adquiridos várias vezes, em um intervalo de tempo curto (~4 segundos), verificando a condição de repetibilidade, dos valores do comprimento de onda de pico da FBG.

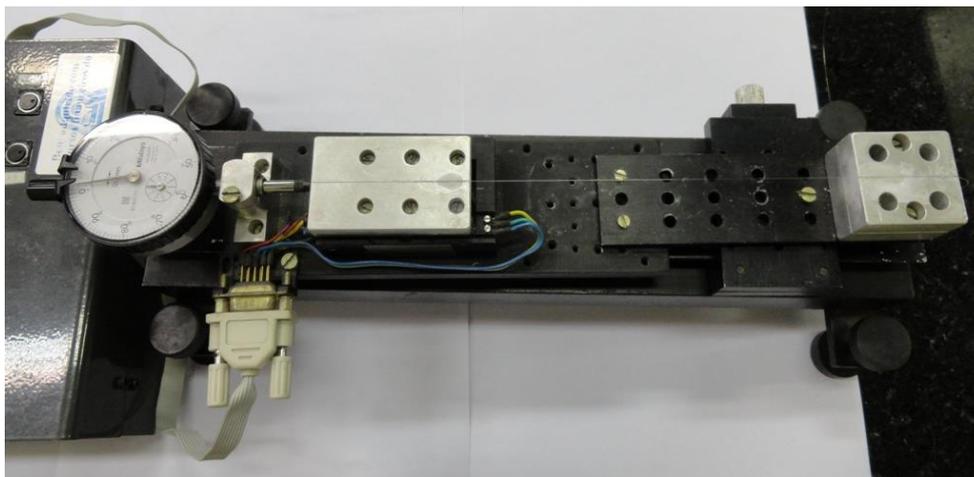


Figura 9 – Foto da montagem experimental para a caracterização da FBG quanto à deformação longitudinal mecânica.

O experimento de caracterização da FBG quando à deformação longitudinal mecânica foi realizado três vezes, sendo cada ciclo completo correspondente a um ciclo de subida e descida controlada com alterações do valor de Δd de 0,01 mm até 0,20 mm.

Com os dados coletados, foi realizado um tratamento estatístico (VUOLO, 1996), verificando a sensibilidade da FBG à deformação e a incerteza correspondente. Para tanto, os valores adquiridos de comprimento de onda de Bragg foram utilizados para calcular a média e o desvio padrão da média (σ_m) em condições de repetibilidade. A incerteza sistemática residual (σ_r) associada com o interrogador de redes foi calculada conforme equação 13, sendo que L_r é o limite de erro do equipamento.

$$\sigma_r = \frac{L_r}{2\sqrt{3}} \quad (13)$$

As incertezas associadas com a medição do deslocamento aplicado à fibra e do comprimento livre da fibra também foram avaliadas. Estas incertezas foram calculadas conforme equações 14 e 15 fazendo uma combinação da incerteza estatística estimada com a incerteza associada ao limite de erro dos equipamentos utilizados calculada pela equação 13. O comprimento livre da fibra foi medido com um paquímetro e o micrômetro foi responsável pelas distensões aplicadas a fibra. Para o cálculo das incertezas associadas ao limite de erro dos equipamentos, foram usados os valores de limite de erro para o paquímetro de 0,05 mm e para o

micrômetro de 0,01 mm. Os valores de incerteza obtidos para estes dois parâmetros medidos são apresentados nas equações 14 e 15.

$$\sigma_{r-paq} = \frac{0,05}{2\sqrt{3}} \quad \sigma_{e-paq} = \frac{0,05}{3} \quad \sigma_{paq} = \sqrt{\sigma_{r-paq}^2 + \sigma_{e-paq}^2} = 0,022mm \quad (14)$$

$$\sigma_{r-micr} = \frac{0,01}{2\sqrt{3}} \quad \sigma_{e-micr} = \frac{0,01}{3} \quad \sigma_{mic} = \sqrt{\sigma_{r-micr}^2 + \sigma_{e-micr}^2} = 0,0044mm \quad (15)$$

Onde σ_r representa a incerteza sistemática residual, σ_e a incerteza estatística estimada e σ é a incerteza combinada. Para caracterizar o sensor, os valores de Δd e $d_{inicial}$ foram usados na determinação da deformação longitudinal relativa para $\mu\epsilon$, relacionando a deformação da fibra com seu estado inicial. Esses valores também foram usados no cálculo da incerteza propagada para esta grandeza, conforme equação 16.

$$\sigma_c = \frac{\Delta d}{d_{inicial}} \sqrt{\left(\frac{(\sigma_{\Delta d})}{\Delta d}\right)^2 + \left(\frac{(\sigma_{d_{inicial}})}{d_{inicial}}\right)^2} \quad (16)$$

No gráfico do levantamento da sensibilidade da FBG à deformação mecânica, os valores de deformação relativa encontram-se no eixo “x” ao passo que os valores correspondentes de posição em comprimento de onda do pico da FBG estão no eixo “y”. Portanto, a incerteza calculada em $\mu\epsilon$ foi transformada em unidade de comprimento de onda (σ'_c) e combinada com a incerteza em comprimento de onda para compor a barra de erros em “y”. O valor de σ'_c foi obtido mediante a multiplicação da incerteza combinada em $\mu\epsilon$ (σ_c) pela sensibilidade inicial $S_{inicial}$ da FBG, a qual foi obtida por meio do ajuste de uma reta angular aos pontos experimentais, sem levar em consideração as incertezas, conforme equação 17.

$$\sigma'_c = \sigma_c \cdot S_{inicial} \quad (17)$$

A incerteza combinada foi calculada com a equação 18, pela combinação do desvio padrão do valor médio σ_m com as incertezas nas medidas de deformações relativas σ'_c e incertezas associadas com o interrogador $\sigma_{interrogador}$.

$$\sigma = \sqrt{\sigma_m^2 + \sigma_c'^2 + \sigma_{interrogador}^2} \quad (18)$$

A sensibilidade quanto à deformação mecânica da FBG foi determinada por meio do coeficiente angular da reta ajustada aos pontos experimentais, sendo uma resposta em comprimento de onda da FBG em função da deformação mecânica. Para tanto, foi utilizado o *software* Origin 8.6, levando em conta o valor de incerteza combinada, a qual foi utilizada como barra de erros para os pontos. A resolução do sensor para uma distribuição de probabilidade retangular que foi definida conforme equação 19.

$$R_{sensor} = \frac{(resolução\ interrogador)}{Sensibilidade} \quad (19)$$

3.3 CARACTERIZAÇÃO TÉRMICA DA FBG

Para determinar a sensibilidade da FBG quanto à temperatura, foi utilizada uma FBG dentre um conjunto de 10 FBGs gravadas sob condições similares. O valor de sensibilidade obtido foi adotado para outras FBGs do conjunto.

Nos ensaios de caracterização térmica, as variações de temperatura foram controladas por meio de um banho térmico (Lauda RE 212) com resolução de 0,01 °C. A FBG foi posicionada dentro de um tubo de ensaio com água para evitar que o fluxo de água do banho térmico ocasionasse vibrações da fibra ótica. O espectro de reflexão da FBG foi medido em diferentes temperaturas obtidas variando a temperatura do banho térmico de $(10,00 \pm 0,01)$ °C até $(70,00 \pm 0,01)$ °C, em passos de 5 °C. Quando a temperatura se estabilizava, o valor de comprimento de onda de Bragg era determinado com o interrogador, sendo utilizado como fonte luminosa um LED superluminescente (Superlum, Pilot-2, 1445-1645 nm).

As medidas em condições de precisão intermediária foram obtidas com a realização de três ciclos térmicos, aumentando e diminuindo a temperatura. Em um mesmo ciclo térmico, para cada valor de temperatura foram realizadas diversas medidas do comprimento de onda de Bragg, em um intervalo de tempo de (~2min) fornecendo assim os dados em condições de repetibilidade.

Com os dados coletados, foi realizado um tratamento estatístico (VUOLO, 1996), verificando a sensibilidade à temperatura da FBG e a incerteza

correspondente. Os valores adquiridos de comprimento de onda de Bragg foram utilizados para calcular a média e o desvio padrão da média (σ_m) em condições de repetibilidade e precisão intermediária. As incertezas sistemáticas residuais (σ_r) associadas com o interrogador de redes e com o banho térmico foram calculadas conforme equação 12. Sendo que L_r , é a maior incerteza associada ao equipamento, para essas medidas L_r , é a resolução de 0,01 °C do banho térmico utilizado e de 0,5 pm para o interrogador. A sensibilidade térmica da FBG foi obtida a partir do gráfico de comprimento de onda de Bragg eixo “y” versus temperatura eixo “x”.

A incerteza na medição da temperatura foi transformada em uma incerteza em comprimento de onda. Isso compõe as barras de erro em “y” juntamente com a incerteza sistemática residual associada com o interrogador e as incertezas estatísticas associadas as medições de comprimento de onda de Bragg. Os valores de incerteza na temperatura σ'_T em comprimento de onda (nm) foram obtidos a partir dos valores de incerteza σ_T em °C e da sensibilidade inicial $S_{inicial}$, a qual foi obtida por meio do coeficiente angular da reta de ajuste à média dos dados experimentais, sem considerar as incertezas experimentais, conforme equação 20.

$$\sigma'_T = \sigma_T \cdot S_{inicial} \quad (20)$$

A incerteza padrão combinada σ que compõe as barras de erro da curva de resposta da FBG foi calculada pela equação 21, levando em conta as incertezas associadas ao desvio padrão da média σ_m^2 , a resolução do interrogador utilizado σ_r^2 , e a incerteza na medição da temperatura σ'^2_T .

$$\sigma = \sqrt{\sigma_m^2 + \sigma_r^2 + \sigma'^2_T} \quad (21)$$

A sensibilidade foi encontrada com um ajuste linear dos pontos experimentais, com o *software* Origin 8.6, levando em conta o valor de incerteza final utilizado como barra de erros. A resolução do sensor foi definida conforme equação 18.

3.4 SISTEMA DE LOCALIZAÇÃO E CARACTERIZAÇÃO DE IMPACTOS

3.4.1 Avaliação da influência de impactos na resposta da FBG

Uma das FBGs gravadas foi colada em uma placa de PMMA, a qual foi submetida a diversos impactos mecânicos. Aquisições de dados foram realizadas com o intuito de verificar o comportamento do espectro de reflexão da FBG, sob alteração de parâmetros como a força e posição angular dos impactos mecânicos gerados na placa. Os testes experimentais realizados estão representados na Figura 10, onde os pontos indicam as 5 diferentes posições de impacto.

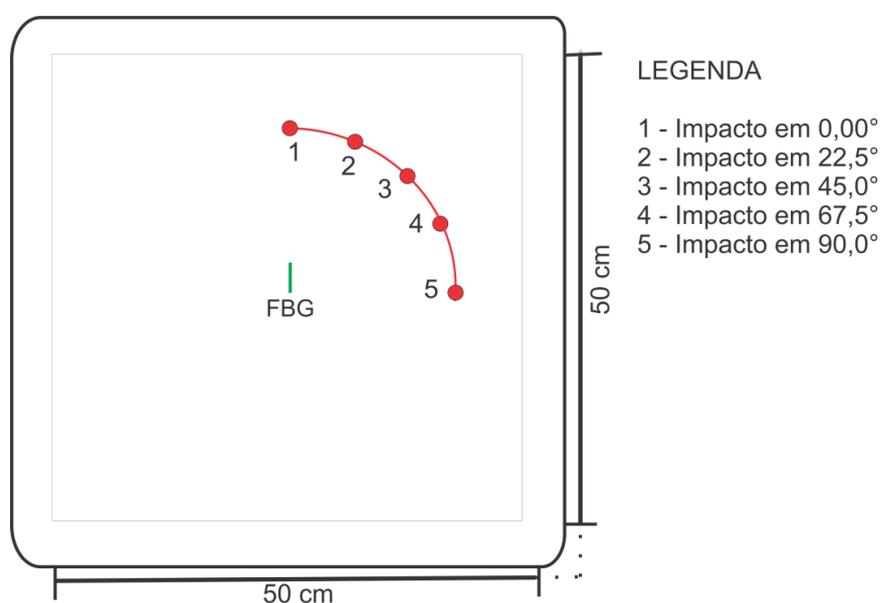


Figura 10 – Diagrama esquemático para caracterização da FBG quanto à posição angular de impacto.

3.4.2 Sistema experimental para mapeamento de impactos

Foi proposto um sistema de caracterização que utiliza uma placa quadrada com dimensões de 60 cm de lado e 5 mm de espessura constituída em (PMMA). As 4 FBGs, chamadas de FBG1, FBG2, FBG3 e FBG4, com comprimentos de onda de Bragg, a $(20,0 \pm 0,5)^\circ\text{C}$, centrados em 1534, 1538, 1540 e 1543 nm, respectivamente, foram fixadas nos quatro cantos da placa quadrada. O segmento de fibra alinhado com as diagonais do quadrado, sendo que a colagem foi realizada com cianoacrilato.

As FBGs foram mantidas sob tensão longitudinal constante até a cura completa do cianoacrilato. Uma matriz bidimensional (50 cm x 50 cm) com separação de 5 cm entre as linhas foi desenhada sobre a superfície da placa, com o intuito de auxiliar na localização dos impactos.

A Figura 11 mostra a geometria da placa de teste utilizada nas medidas, com um sistema de coordenadas cartesianas, cuja origem se encontra no centro da placa. As coordenadas cartesianas (x_i, y_i) em centímetros dos quatro transdutores (FBG1, FBG2, FBG3 e FBG4) foram, respectivamente, $(-27,5; -27,0)$ cm, $(26,0; -26,6)$ cm, $(27,0; 26,6)$ cm e $(-26,5; 26,5)$ cm. O impacto é representado pelo círculo vermelho de menor raio no quadrante Q1, enquanto a frente de onda associada à perturbação é representada pela circunferência de maior raio.

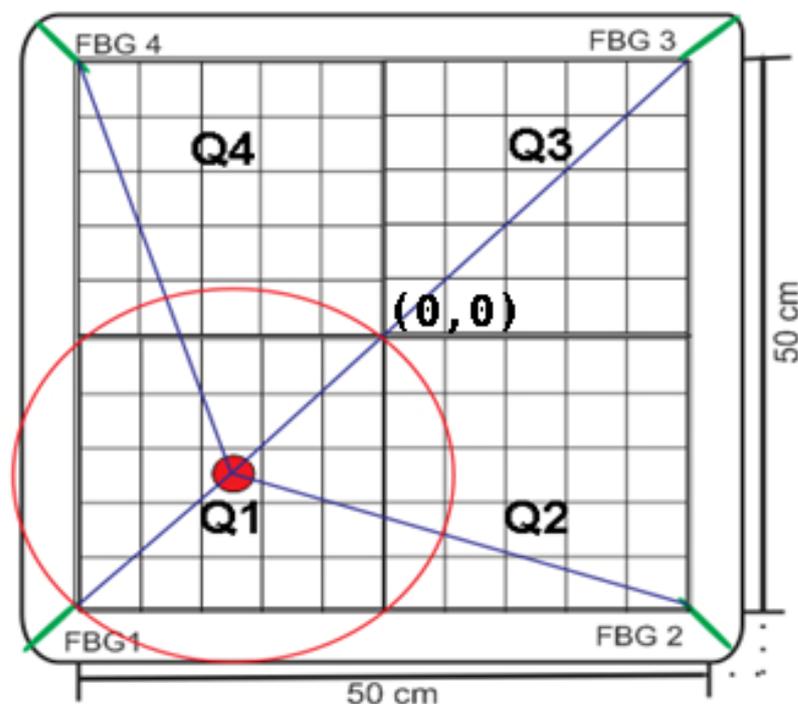


Figura 11 - Sistema de mapeamento de impactos instrumentado com as quatro FBGs.

Um tubo oco cilíndrico, com 8 cm de comprimento mantido na posição vertical foi utilizado para guiar uma bola metálica com uma massa de 34 g, a qual foi responsável pelo impacto sobre a placa de teste. O impacto gerou ondas de alta velocidade que se propagam na placa, mas devido ao equipamento de aquisição não medir ondas de alta velocidade, foi mensurado uma oscilação resultante do momento do impacto. A oscilação que se propagou na placa alcançando as FBGs em diferentes instantes de tempo dependentes da posição da FBG com relação ao ponto de impacto. A perturbação causou tensões de dilatação/contração sobre as

redes, que foram detectadas na forma de deslocamentos em função do tempo no comprimento de onda de Bragg.

Na detecção simultânea dos deslocamentos em comprimento de onda sofridos pelas quatro FBGs, foram utilizados um LED e um interrogador ótico (IBSEN PHOTONICS IMON-512E). Os desvios em comprimento de onda ($\delta\lambda_{FBG1}(t)$, $\delta\lambda_{FBG2}(t)$, $\delta\lambda_{FBG3}(t)$ e $\delta\lambda_{FBG4}(t)$) foram mensurados ao longo de (~0,3 segundos). Os instantes de tempo nos quais a perturbação alcançou cada FBG foram medidos com um *trigger* via *software*, no qual a FBG mais próxima ao ponto de impacto detectou a perturbação, e considerou como o tempo inicial ($t=0$). Foram avaliados impactos produzidos em quatro posições da placa, sendo cada um dos impactos produzidos em um quadrante diferente. Para cada posição de impacto, foram realizadas 20 medições em condições de reprodutibilidade.

Para minimizar os efeitos de sensibilidade cruzada na resposta da FBG, a temperatura ambiente foi mantida em $(20,0 \pm 0,5)^\circ\text{C}$ e em equilíbrio térmico com o sistema de medição. Os dados fornecidos pelas FBGs foram usados como entradas na implementação da rede neural artificial.

3.4.3 Identificação de quadrantes com RNA

Foram escolhidos, inicialmente, quatro posições da placa como pontos experimentais para a aplicação de impactos, sendo que, cada um deles situado em um dos quadrantes. As respostas temporais das FBGs aos impactos foram usadas como sinais de entrada (x) para a construção e teste de diversas arquiteturas de RNAs. Os valores de saída (y) para as RNAs foram atribuídos segundo a posição vetorial de cada sinal medido. Nessa etapa foram avaliados somente os quatro pontos de impacto localizados nos quadrantes Q1, Q2, Q3, e Q4, representados por círculos vermelhos na Figura 12.

Nesse trabalho as RNAs desenvolvidas foram do tipo MLP, sendo utilizado o *software* proprietário Matlab versão 2011. Foi implementada uma RNA com quatro neurônios na camada de entrada (associado com as respostas das quatro FBGs no tempo), três camadas ocultas com trinta neurônios, e uma última camada de saída associada com o quadrante de localização do impacto. Após simulações consecutivas, determinou-se o número de camadas ocultas e o número de neurônios

em cada camada, com o objetivo de obter uma boa capacidade de aprendizagem e generalização.

Foram realizadas vinte medições experimentais para cada quadrante. Um conjunto de quinze medições associados ao comprimento de onda das quatro FBGs no tempo, para cada impacto por quadrante, foi aleatoriamente escolhido como dado de entrada para treinar a RNA. O conjunto restante de cinco medições experimentais de cada quadrante foi empregado para testar a arquitetura da RNA construída. A RNA foi assim testada com dados experimentais não utilizados na etapa de treinamento, permitindo avaliar a sua capacidade de generalização. Os valores de saída da RNA foram utilizados como alvos 1, 2, 3 e 4, associados com os quadrantes Q1, Q2, Q3 e Q4, respectivamente.

A taxa de aprendizagem (ϑ) também foi variada de forma a se obter o menor erro médio quadrático e um bom desempenho. Para tanto, foram testados os seguintes intervalos $1 \leq N \leq 100$ e $0,01 \leq \vartheta \leq 0,20$. A eficiência de cada topologia foi quantificada mediante cálculo da taxa de acerto, a qual compara a diferença entre o valor desejado e o valor calculado pela RNA. Na Figura 12 é representado um diagrama esquemático do princípio de funcionamento e arquitetura da RNA proposta, a qual atua como identificador de quadrantes de impactos, da placa.

A RNA foi treinada durante 30 épocas, de acordo com o algoritmo *back-propagation Levenberg-Marquardt*, com taxa de aprendizagem inicial de 0,10%, com um objetivo de erro médio quadrático de 0,01%. Funções de transferência tangente hiperbólica foram usadas nas camadas ocultas. Por outro lado, uma função de transferência linear foi empregada na camada de saída.

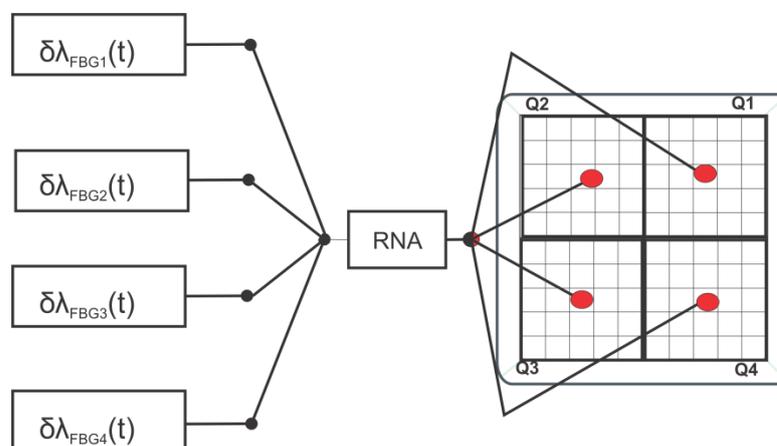


Figura 12 - Diagrama esquemático da RNA utilizada para fornecer o quadrante da placa de ensaio de PMMA, submetido ao impacto mecânico.

O desempenho da RNA foi avaliado em termos da taxa de classificação correta para as etapas de treinamento e de teste. Essas taxas foram calculadas pela relação entre o número de classificações corretas e o número total de saídas desejadas, obtendo o número total de acertos e erros nas etapas de treino e teste. A classificação fornecida pela RNA foi considerada correta, para uma resposta de saída dentro do intervalo de tolerância aceitável ($\pm 0,3$). Sendo assim, foram considerados corretos os seguintes valores de saída da RNA: ($0,7 \geq Q1 \leq 1,3$), ($1,7 \geq Q2 \leq 2,3$), ($2,7 \geq Q3 \leq 3,3$) e ($3,7 \geq Q4 \leq 4,3$), conforme estabelecidos como meta de classificação de padrões.

3.4.4 Localização de impactos com RNA

Utilizando o *software* proprietário Matlab versão 2011, foi implementada uma RNA do tipo MLP, com quatro neurônios na camada de entrada (associado com as respostas das quatro FBGs no tempo), três camadas ocultas com trinta neurônios, e uma camada de saída, com dois neurônios associados com a localização (x, y) do impacto. O número de camadas ocultas e o número de neurônios em cada camada só foram determinados após simulações consecutivas.

Foram realizadas vinte medições experimentais para cada posição vetorial de impacto. Um conjunto de quinze medições, correspondentes a posição em comprimento de onda das quatro FBGs no tempo, foi aleatoriamente escolhido para ser aplicado na etapa de treinamento da RNA. O conjunto restante de cinco medições experimentais de cada posição vetorial de impacto foi usado para testar a arquitetura da RNA construída. Assim, a RNA foi testada com dados experimentais não utilizados na etapa de treinamento, permitindo avaliar a sua capacidade de generalização. Algumas posições vetoriais (x, y) tais como (1,1; 1,9; 9,1; 9,9; 5,5) foram usadas como alvo na saída da RNA.

O número de neurônios artificiais na camada oculta N e a taxa de aprendizagem (∂) foram variados de forma a se obter o menor erro médio quadrático. Para tanto, foram testados os seguintes intervalos: $1 \leq N \leq 100$ e $0,01 \leq \partial \leq 0,20$. A eficiência de cada topologia foi quantificada mediante cálculo do erro médio, dado pela subtração entre o valor desejado e o valor calculado pela RNA. A Figura 13 demonstra o princípio de funcionamento e arquitetura da RNA proposta, que atua como identificador de posições de impactos em um plano.

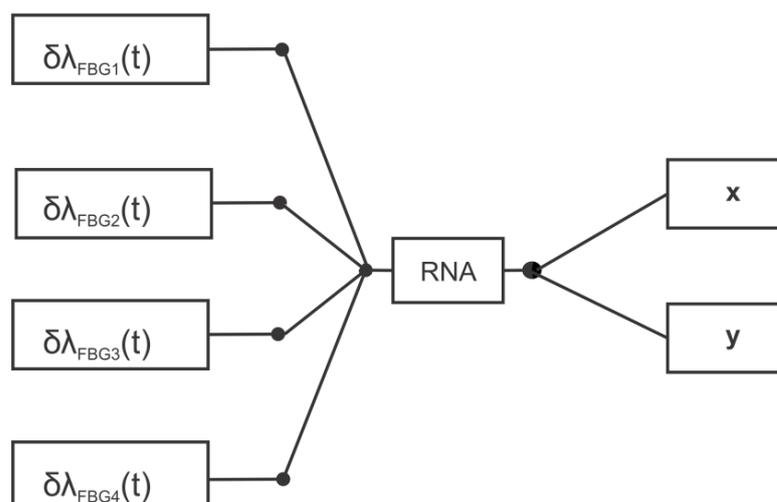


Figura 13 - Diagrama esquemático da RNA utilizada para fornecer a localização (x, y) do impacto produzido na placa de ensaio de PMMA.

A RNA foi treinada durante 30 épocas de acordo com o algoritmo *back-propagation* Levenberg-Marquardt com taxa de aprendizagem inicial de 0,10%, e com um objetivo de erro médio quadrático de 0,01%. Funções de transferência tangente hiperbólica foram usadas em camadas ocultas. Por outro lado, uma função de transferência linear foi empregada na camada de saída.

O desempenho da RNA foi avaliado em termos da taxa de erro para etapas de treinamento e de teste. Essas taxas foram calculadas pela relação entre a saída de RNA e o valor desejado, obtendo-se os erros na determinação das coordenadas (x, y) nas etapas de treinamento e teste. Depois a RNA foi avaliada quantitativamente com intuito de verificar o erro associado com a resposta desejada e o valor de saída da RNA.

4 RESULTADOS E DISCUSSÕES

4.1 RESPOSTA DA FBG À DEFORMAÇÃO LONGITUDINAL MECÂNICA

Os resultados das caracterizações à deformação longitudinal mecânica permitiram confirmar a linearidade na resposta das FBGs, quando sujeitas a variações de deformação. Os dados de deformação provocados pelo estágio de translação foram divididos pelo comprimento inicial de 150,00 mm, medido com o paquímetro, fornecendo o deslocamento relativo $\Delta d/d_{inicial}$ que provoca a deformação. Em cada ciclo, cada ponto experimental corresponde ao valor médio de 100 medições independentes.

A sensibilidade inicial obtida por meio do coeficiente angular do ajuste linear dos valores médios, foi de $(1,05 \pm 0,05)$ pm/ $\mu\epsilon$. A equação 17 foi usada para converter a incerteza na medida da deformação, associada com a resolução dos equipamentos, para as barras de erro na vertical, conforme metodologia apresentada por Vuolo (1996). A incerteza total, que é obtida pela equação 18, representa as barras de erro da Figura 14. A sensibilidade final do sensor foi de $(1,06 \pm 0,05)$ pm/ $\mu\epsilon$. A resolução do sensor foi de $0,5 \mu\epsilon$, conforme equação 19.

A Figura 14 mostra a resposta a deformações mecânicas das FBGs. Os pontos experimentais correspondem a três ciclos de variação de deformação.

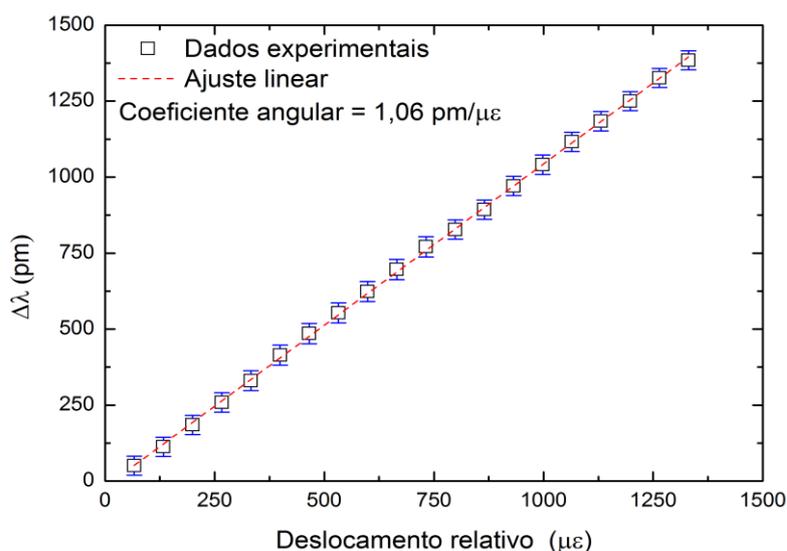


Figura 14 – Representação da variação do comprimento de onda central da FBG em função da deformação relativa.

4.2 RESPOSTA TÉRMICA DA FBG

Os resultados das caracterizações térmicas permitiram confirmar a linearidade na resposta da FBG sob variações de temperatura. A sensibilidade térmica da FBG foi determinada por meio do coeficiente angular da reta de ajuste aos pontos experimentais.

O gráfico da Figura 15 demonstra a resposta da FBG em comprimento de onda em função da temperatura, levando em conta as barras de erro. Para tanto, uma FBG foi escolhida para servir de referência a todas as FBG gravadas em condições idênticas. As medidas foram realizadas em condições de repetibilidade. Os pontos experimentais correspondem aos valores médios de três ciclos de variação de temperatura, sendo que em cada ciclo cada ponto experimental corresponde ao valor médio de 100 medições independentes.

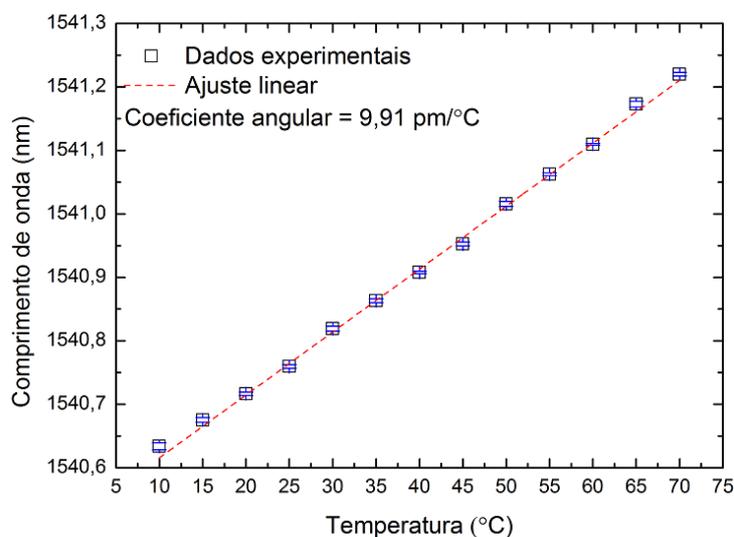


Figura 15 - Representação da variação do comprimento de onda central da FBG em função da temperatura

O maior valor obtido para o desvio padrão do valor médio destes pontos representou a incerteza do tipo A. Para a incerteza de tipo B, incertezas relacionadas aos equipamentos, duas componentes foram calculadas. Utilizando a equação 12, foram obtidas incertezas para o interrogador de $1,4 \times 10^{-4}$ nm e de $2,9 \times 10^{-3}$ °C para o banho térmico. A incerteza no eixo 'x' foi transferida para o eixo 'y', conforme equação 20. A sensibilidade inicial foi obtida por meio do coeficiente angular do ajuste linear dos valores médios, sendo de $(9,85 \pm 0,05)$ pm/°C.

A equação 20 converte a incerteza na medida da temperatura, associada com a resolução do banho térmico, para as barras de erro na vertical, conforme metodologia apresentada por Vuolo (1996). A incerteza combinada, que é obtida pela equação 21, representa as barras de erro da Figura 15. A sensibilidade final do sensor foi de $(9,91 \pm 0,05)$ pm/°C e a sua resolução foi de 0,05 °C, conforme equação 19.

4.3 RESPOSTA DA FBG QUANTO À DEFORMAÇÃO GERADA POR IMPACTOS EM DIFERENTES POSIÇÕES ANGULARES

A Figura 16 mostra que a FBG apresenta uma maior sensibilidade quando o impacto acontece em 0°, referente à direção de propagação. Assim sendo, devido à geometria quadrada do sistema proposto, foi melhor fixar as FBGs em uma posição de 45° com as bordas da placa, sendo que no sistema proposto, foi utilizado apenas quatro FBGs apontando para o centro da placa. Assim, o sistema apresenta uma eficiência em todos os pontos da placa, quando uma aquisição dos sinais é realizada, simulando impactos mecânicos na placa.

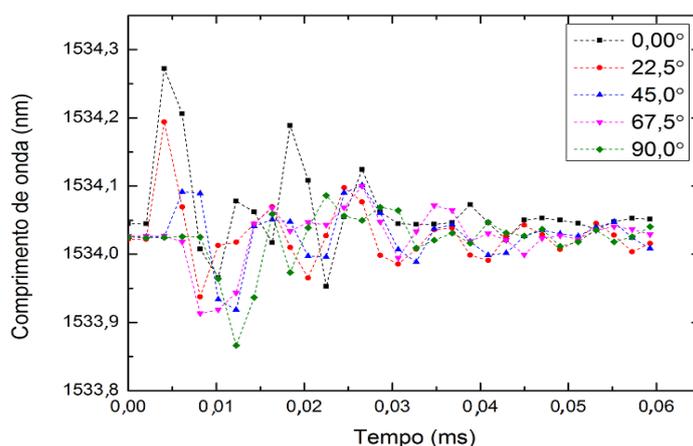


Figura 16 – Resposta de uma FBG conforme posição angular da onda de choque mecânica, com impactos simulados em diferentes posições angulares em relação à direção de propagação da FBG.

Os resultados demonstraram que para o sistema responder de maneira eficiente em todos os pontos de impactos mecânicos gerados, utilizando apenas quatro sensores FBGs, as mesmas deveriam ser fixadas em uma posição de 45° com as bordas da placa quadrada.

4.4 SISTEMA DE MEDIÇÃO DE IMPACTOS COM AS FBGs

Na Figura 17 é possível visualizar a resposta temporal das quatro FBGs, quando submetidas a um impacto mecânico nas coordenadas (-27,5; -27,0) cm. Um conjunto semelhante de dados foi utilizado como entrada para a RNA, resultante dos outros impactos produzidos, com a frequência do equipamento de aquisição de dados fixado em 948,8 Hz.

A matriz bidimensional desenhada sobre a placa de PMMA foi usada na localização das coordenadas do impacto. O impacto foi detectado pelas quatro FBGs por meio de alterações nos seus espectros de reflexão. Devido ao posicionamento dos sensores nos cantos do quadrado, as diferentes distâncias entre cada uma das FBGs e o ponto de impacto, os sinais detectados pelas FBGs apresentam diferentes amplitudes e um atraso temporal.

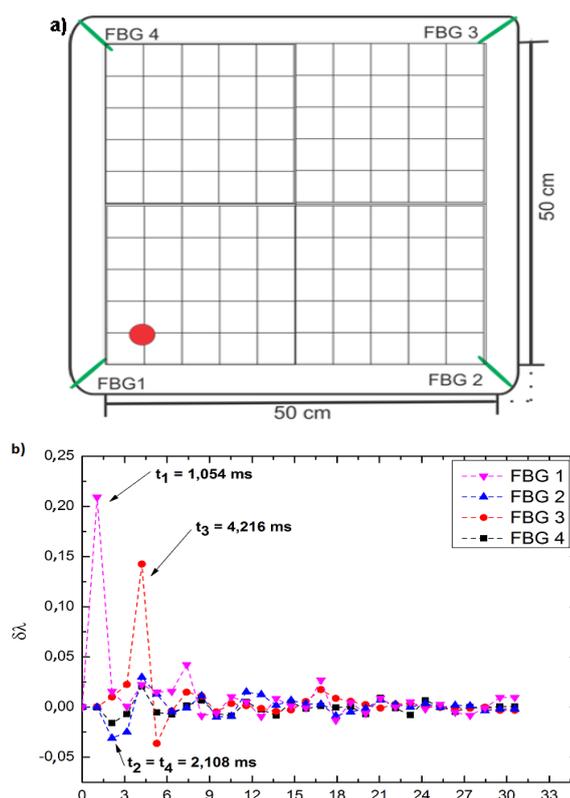


Figura 17 – a) Montagem experimental com impacto simulado na posição (27,5; 27,0) cm, próximo da FBG 1; b) Espectro de quatro FBGs devido impacto mecânico simulado nas coordenadas (27,5; 27,0) cm, próximo da FBG 1.

As FBGs, demonstraram uma diferença temporal de resposta, sendo $\Delta t_{t_1-t_2} = -1,054$ ms, $\Delta t_{t_1-t_3} = -3,162$ ms e $\Delta t_{t_1-t_4} = -1,054$ ms. Devido à diferença espacial e angular entre as FBG2 e FBG4 fixadas na placa serem as mesmas, para um

impacto simulado na coordenadas (-27,5; -27,0) cm, próximo da FBG1, os sensores respondem na mesma escala temporal. Por isso, $\Delta t_{t_1-t_2} = \Delta t_{t_1-t_4}$.

Foi analisada a repetibilidade e reprodutibilidade do sistema de detecção quanto à detecção de impactos produzidos em uma posição na chapa de acrílico. Para isso foram produzidos impactos nas seguintes coordenadas: (-27,5; -27,0) cm, próximo da FBG 1; (26,0; -26,6) cm próximo da FBG 2; (27,0; 26,6) cm próximo da FBG 3; (-26,5; 26,5) cm próximo da FBG 4; e (0,00; 0,00) cm no centro da placa, conforme representado na Figura 18.

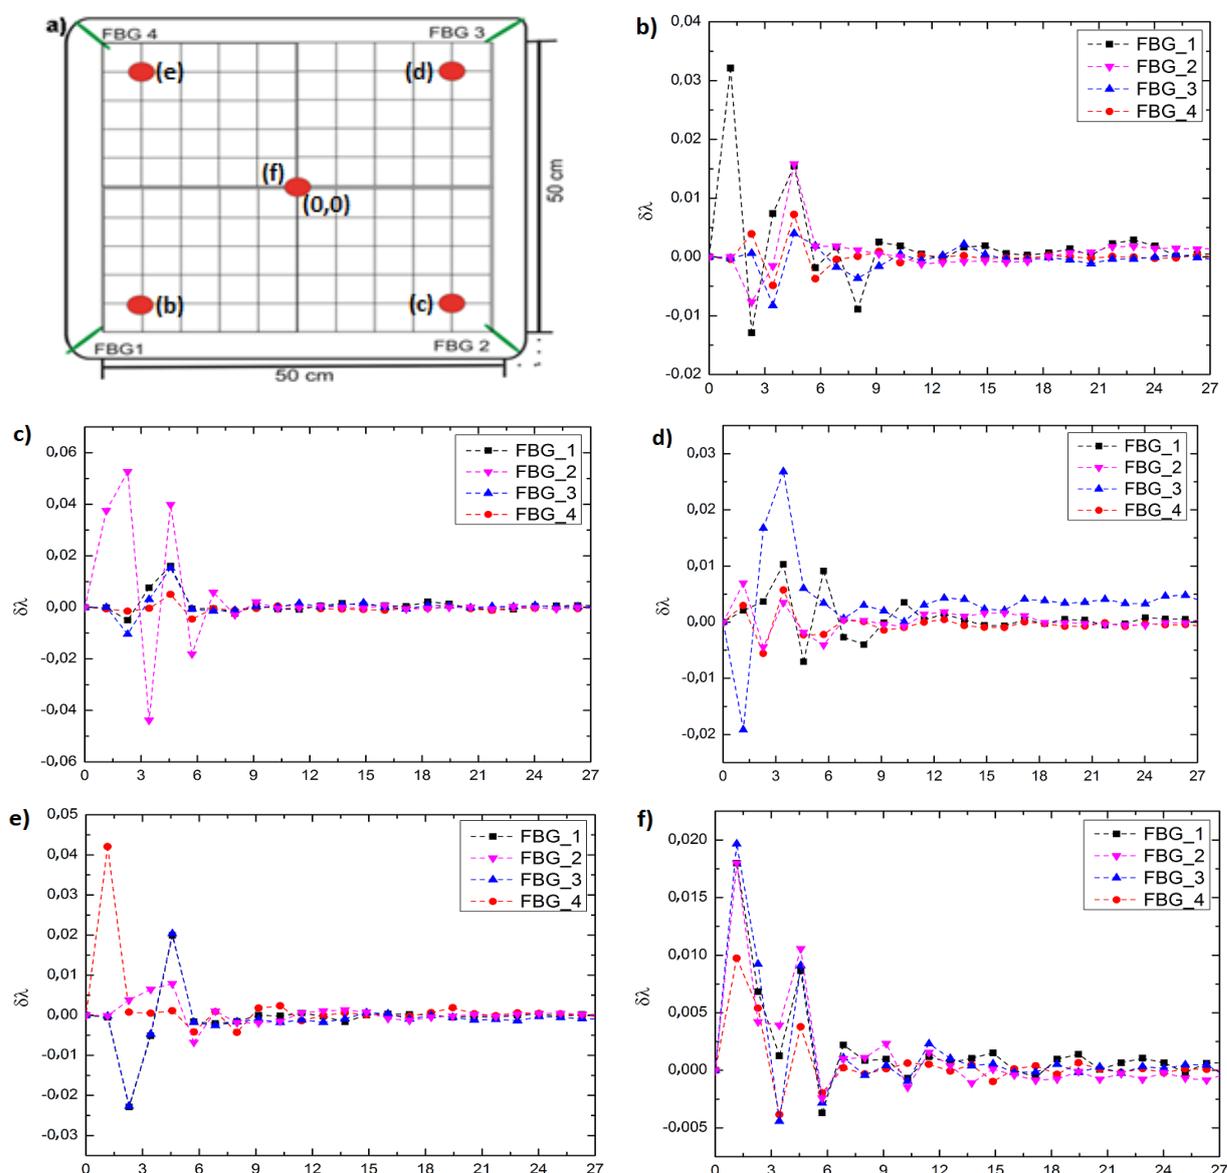


Figura 18 – a) Indicação das posições de impactos induzidos na placa; b) impacto gerado na posição (-27,5; -27,0) cm, próximo da FBG 1; c) impacto gerado na posição (26,0; -26,6) cm, próximo da FBG 2; d) impacto gerado na posição (27,0; 26,6) cm, próximo da FBG 3; e) impacto gerado na posição (-26,5; 26,5) cm, próximo da FBG 4; f) impacto gerado na posição (0; 0), no centro da placa.

As FBGs apresentaram respostas temporais complexas, não sendo possível identificar de maneira fácil um padrão bem definido que possa ser utilizado na determinação da localização do impacto. Dessa maneira, torna-se viável usar os sinais medidos para treinar uma RNA do tipo MLP que se apresenta como uma ferramenta útil na classificação e reconhecimento de padrões.

4.5 DETERMINAÇÃO DO QUADRANTE DE IMPACTO

A RNA implementada que apresentou um desempenho satisfatório foi configurada com 2 camadas ocultas, com 30 neurônios nas respectivas camadas, e com uma taxa de aprendizagem de 0,10. Durante o treinamento da RNA, o erro médio quadrático, que é a diferença entre o valor alvo e a resposta fornecida pela RNA, decresceu em forma exponencial, na medida em que foi realizada uma nova iteração (época). Na etapa de treinamento da RNA foram utilizadas apenas 30 épocas sendo obtido um erro médio quadrático de 0,0247.

Um conjunto de dados, não utilizados na etapa de treinamento da RNA, foi utilizado na etapa de teste, e os valores alvo foram comparados com as respostas oriundas da RNA. A fim de avaliar o desempenho da RNA proposta, a taxa de acerto (TA%) foi definida como a razão entre a quantidade de amostras apresentadas para classificação e a quantidade classificada corretamente.

Foram medidas as respostas temporais das quatro FBGs resultantes de impactos produzidos em quatro regiões da placa de (PMMA) definidas pelos quadrantes Q1, Q2, Q3, e Q4, representados na saída da RNA por 1, 2, 3, e 4. Quando os valores de saída fornecidos pela RNA encontram-se dentro do limite de tolerância, a saída é classificada como “correta”. O limite de tolerância é considerado como flutuação da RNA. Quando ocorrer valores na saída da RNA, fora do limite de tolerância, a classificação será considerada como “incorreta”.

Os resultados obtidos na etapa de treinamento da RNA proposta são representados na Figura 19. Para o limite de tolerância de 0,3, a taxa de acerto na etapa de treinamento foi de 92,85%, ou seja, das 60 amostras treinadas, 56 foram classificadas como corretas. O erro médio (E_m) foi de 0,0986 e o desvio padrão (σ_{E_m}) foi de 0,1285.

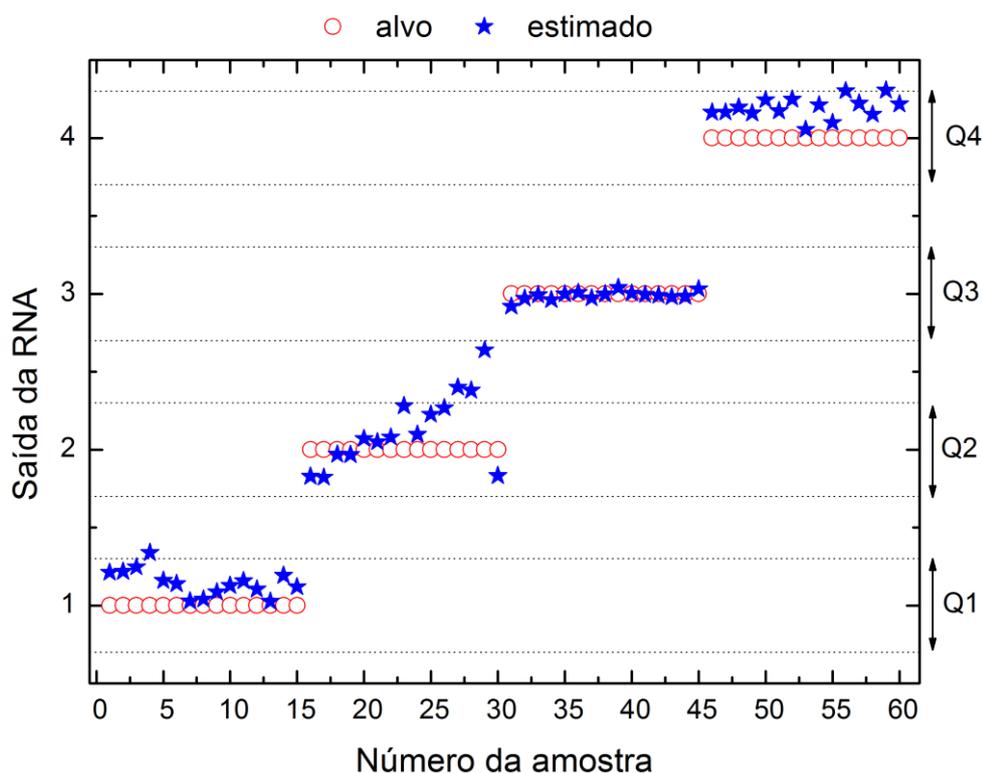


Figura 19 - Respostas da RNA e valores alvos para os dados de treinamento.

Pode-se observar na Figura 20, que apenas 2 impactos foram classificados incorretos na etapa de teste, os quais ficaram fora da faixa de tolerância estimada. Entretanto, esses 2 impactos não prejudicaram a eficiência do sistema, pois não podem ser classificados em nenhuma classe, assim não são considerados como os “falsos positivos”. Nesse Caso, eles não podem ser classificados, mas como não pertencem a nenhuma classe, são considerados como incorretos. Com a técnica proposta, a taxa de acerto da RNA na etapa de validação foi de 90,00%, sendo classificados de maneira correta 18 dos 20 sinais resultantes de impactos apresentados a RNA, com erro médio quadrático (E_m) em relação ao valor alvo de 0,0754%, e desvio padrão (σ_{E_m}) de 0,1193%. Assim, pode-se considerar que a topologia é eficiente, pois apresenta uma boa generalização, sendo que a maioria dos impactos foram classificados como corretos na etapa de validação, ocorrendo um pequeno aumento do erro médio (E_m) e desvio padrão (σ_{E_m}).

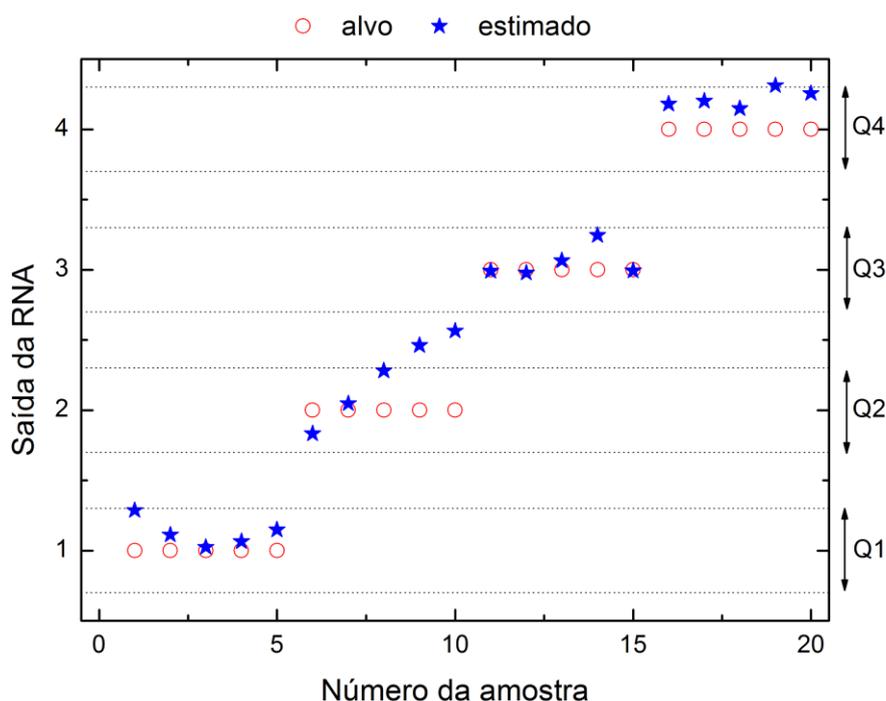


Figura 20 - Respostas da RNA e valores alvos para os dados de validação.

4.6 LOCALIZAÇÃO DE IMPACTOS EM UM PLANO COM RNA

Realizou-se a aquisição de dados com as quatro FBGs quando da produção de impactos em diferentes posições da placa. Foram escolhidas cinco posições de impactos para servir de dados de entrada para uma RNA, a qual foi implementada e testada. Tais impactos foram produzidos nas coordenadas (1,1), (1,9), (9,1), (9,9) e (5,5), conforme ilustrado na Figura 21. Os valores fornecidos pela RNA foram utilizados para fazer uma análise quantitativa do erro entre o valor desejado e o valor de saída da RNA.

A Figura 21 apresenta o resultado da etapa de treinamento da RNA proposta para identificar impactos em uma placa, a qual permitiu determinar o erro associado com a localização das coordenadas “x” e “y” dos pontos de impacto. As respostas temporais das FBGs foram usadas como entradas durante a etapa de treinamento da topologia proposta. Os resultados são promissores, os quais possibilitam fazer uma análise da taxa de erro no sistema. O maior erro quadrático médio (E_m) em relação aos valores alvo foi de 0,0321% na coordenada x, e 0,0332% em y, com um desvio padrão (σ_{E_m}) de 0,1246% na coordenada x, e 0,1287% na coordena y, sendo

que, isso foi para todo o sistema, ou seja, para as cinco coordenadas de impacto. A Tabela 2 apresenta os valores absolutos de erro na etapa de treinamento, para os valores alvo da Figura 21.

Tabela 2 – Valores absolutos de erro na etapa de treinamento da RNA

| Posição do impacto | (1,1) | | (1,9) | | (5,5) | | (9,1) | | (9,9) | |
|--------------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| | x | y | x | Y | x | y | X | Y | x | Y |
| Erro médio | 0,0194 | 0,0309 | 0,0176 | 0,0261 | 0,0156 | 0,0196 | 0,0018 | 0,0011 | 0,0321 | 0,0332 |
| Desvio padrão | 0,0752 | 0,1199 | 0,0684 | 0,1012 | 0,0681 | 0,1134 | 0,0071 | 0,0044 | 0,1246 | 0,1287 |
| Erro mínimo | 0,0193 | 0,0794 | 0,0056 | 0,0020 | 0,0143 | 0,0152 | 0,0366 | 0,0202 | 0,0647 | 0,0068 |
| Erro máximo | 0,2437 | 0,4386 | 0,2354 | 0,3907 | 0,3332 | 0,2633 | 0,0627 | 0,0353 | 0,4999 | 0,4790 |

Percebe-se que as respostas fornecidas pela RNA, as quais fazem referência às posições dos impactos, possibilitou fazer uma análise quantitativa desses erros. Portanto, a RNA apresentou uma capacidade de generalização bastante eficiente, uma vez que a maioria das amostras de treinamento obtiveram um erro aceitável comparando o valor desejado com a resposta da RNA.

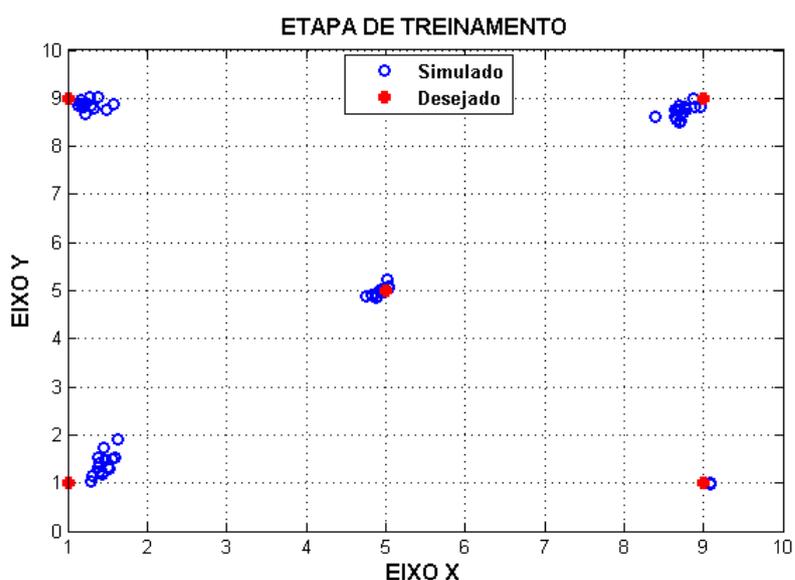


Figura 21 - Respostas da RNA e valores alvos para os valores de treinamento de uma RNA implementada pra determinar posições de impactos em um plano.

A Figura 22 apresenta o resultado da etapa de teste da RNA proposta para determinar o erro associado com a localização de impactos nas coordenadas x e y. O maior erro quadrático médio (E_m) em relação ao valor alvo foi de 0,0802% em x, e 0,1406% em relação à y, sendo que, o maior desvio padrão (σ_{Em}) foi de 0,1793% em x, e 0,3144% em y para todo o sistema, ou seja, para as cinco coordenadas de impacto. A Tabela 3 apresenta os valores absolutos de erro na etapa de teste, para os valores alvos da Figura 22.

Tabela 3 - Valores absolutos de erro na etapa de teste da RNA

| Posição do impacto | (1,1) | | (1,9) | | (5,5) | | (9,1) | | (9,9) | |
|--------------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| | x | y | x | y | x | y | X | Y | x | Y |
| Erro médio | 0,0347 | 0,1406 | 0,0389 | 0,0221 | 0,0573 | 0,0567 | 0,0029 | 0,0038 | 0,0802 | 0,0525 |
| Desvio padrão | 0,0776 | 0,3144 | 0,0871 | 0,0494 | 0,1283 | 0,1268 | 0,0066 | 0,0086 | 0,1793 | 0,1175 |
| Erro mínimo | 0,1029 | 0,3683 | 0,0246 | 0,0013 | 0,1035 | 0,0164 | 0,0359 | 0,0211 | 0,1380 | 0,0387 |
| Erro máximo | 0,2973 | 1,1434 | 0,2423 | 0,1135 | 0,4321 | 0,3567 | 0,0541 | 0,0439 | 0,5908 | 0,3417 |

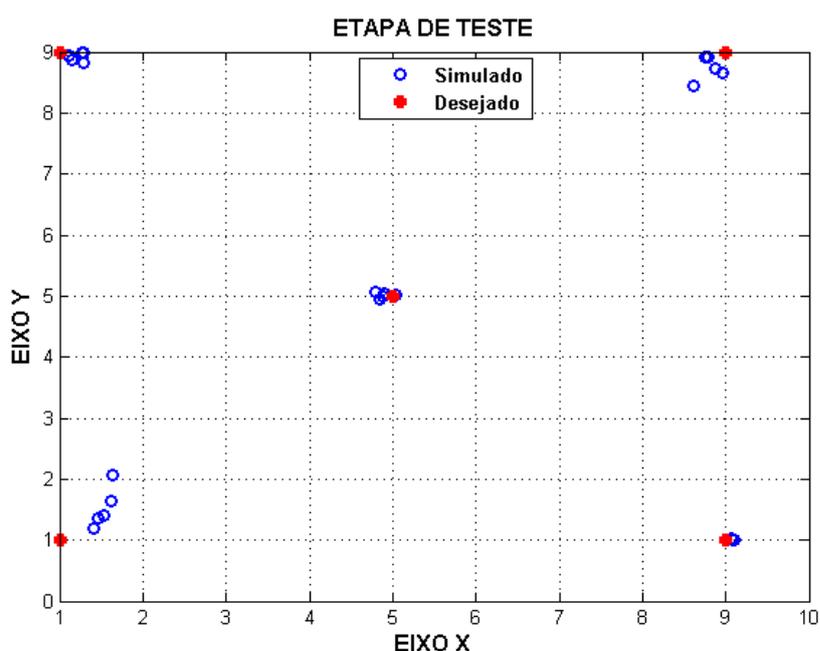


Figura 22 - Respostas da RNA e valores alvos para os valores de teste de uma RNA implementada para determinar posições de impactos em um plano.

As respostas da RNA, as quais fazem referência às posições dos impactos, foram testadas para verificar o erro da resposta desejada em comparação ao valor alvo da RNA. Portanto, a RNA apresentou uma capacidade de generalização bastante eficiente, uma vez que a maioria dos valores testados apresentou uma taxa de erro aceitável.

5 CONSIDERAÇÕES FINAIS

5.1 CONCLUSÕES

As FBGs produzidas foram aplicadas como transdutores de deformação mecânica para avaliar impactos produzidos em uma placa, atendendo aos requisitos propostos na metodologia. Sendo que, foi necessário o levantamento das características metrológicas desses sensores FBG, realizando uma caracterização da FBG quanto à temperatura e deformação mecânica. Assim, obtendo-se características metrológicas como: sensibilidade, resolução e repetibilidade. Essas características metrológicas levantadas foram importantes para a etapa de localização de quadrante com RNA.

Após a realização de experimentos, foi observado que as FBGs apresentam uma sensibilidade maior na sua direção de propagação em 0° , quando simulados impactos mecânicos na placa, por isso o sistema foi instrumentado com quatro FBGs coladas em 45° com as bordas da placa.

Após foi verificado a repetibilidade e reprodutibilidade do sistema de detecção quanto à detecção de impactos produzidos em uma mesma posição da placa instrumentada com quatro FBGs. O sistema apresentou respostas temporais complexas, por se tratar de um evento dinâmico, assim não foi possível identificar com facilidade um padrão bem definido, que pudesse ser utilizado na determinação da localização de impactos mecânicos.

Dessa maneira, a identificação dos quadrantes de impacto foi realizada a partir da resposta temporal de quatro FBGs. Os sinais foram utilizados para treinar uma RNA do tipo MLP, que se mostrou capaz de determinar o quadrante onde ocorreu o impacto sobre a estrutura, sem a necessidade de modelagem física. Na etapa de teste, a RNA proposta mostrou uma boa aprendizagem e capacidade de generalização, com uma taxa de classificação correta de 90%.

Outra RNA foi implementada, a qual se mostrou apropriada em determinar o erro associado com a comparação do valor desejado e o valor de saída da RNA na localização de um impacto em um plano. Sendo que, foi possível fazer uma análise quantitativa dos erros. O maior erro quadrático médio (E_m) em relação ao valor alvo foi de 0,0802% na coordenada x, e 0,1406% para y, sendo que, o maior desvio

padrão (σ_{Em}) foi de 0,1793% para a coordenada x, e 0,3144% em y para todo o sistema, ou seja, as cinco coordenadas de impacto na etapa de teste da RNA.

O sistema é simples e de fácil utilização e comprova a eficiência das FBGs para mensurar deformação mecânica. Sendo que em conjunto com as RNAs foi desenvolvido um sistema inteligente para o monitoramento da integridade estrutural, o qual permite detectar a existência de um dano e localizá-lo na estrutura já em fase de implementação.

O sistema proposto de monitoramento pode tornar o processo de manutenção mais rápido, pois sabendo a localização do impacto é possível detectar um dano ainda no estágio inicial, diminuindo o tempo que a estrutura fica parada e acarretando em um custo menor de manutenção, sendo que ainda proporciona um maior grau de segurança.

5.2 TRABALHOS FUTUROS

Aprimorar a montagem experimental com a utilização de um sistema controlado, capaz de fornecer a força dos impactos produzidos, e utilizar no sistema de detecção um interrogador de redes com maior frequência de amostragem.

Com o objetivo de classificar qualquer posição de impacto na placa, isto é, posições de impactos totalmente desconhecidos pela RNA, treinar outras redes neurais artificiais com arquiteturas e topologias mais complexas e que façam uso de um maior número de variáveis de entrada.

Desenvolver um tratamento estatístico com valores de incerteza, podendo assim afirmar com precisão qual é a eficiência e a dispersão máxima aceitável no reconhecimento de impactos.

Desenvolver novas técnicas para estudar a integridade estrutural de materiais, com intuito de prever estragos no material como rachaduras.

Propor uma RNA que possa detectar a existência do dano, localizá-lo na estrutura, classificar os danos causados a estrutura, ponderar a sua extensão, e prever o tempo de funcionamento para essa estrutura afetada.

REFERÊNCIAS

AGRAWAL, G. P. Fiber-Optic Communication Systems, ed. 2. John Wiley & Sons, 1997

ANTUNES P.F.C., ALMEIDA P.A.M., PINTO J.L., ANDRÉ P.S.B., Fiber Bragg grating accelerometer for dynamic vibration measuring, **Physics Teaching in Engineering Education PTEE 2007**, Delft University of Technology, Delft, The Netherlands, October 25-27, 2007.

ATOBE S; KOBAYASHI H; HU N; AND FUKUNAGA H, Real-Time Impact Force Identification of CFRP Laminated Plates Using Sound Waves, **ICCM18,CD-ROM**, p. 1-6, 2011.

B. S. KAWASAKI, K. O. HILL, D. C. JOHNSON, and Y. FUJII, Narrow-band Bragg reflectors in optical fibers, **Optics Letters 3**, p. 66-68, 1978.

BHATIA, V; VENGSARKAR, A, M. Optical Fiber Long-Period Grating Sensors.**OpticalLetters**, v. 21, p. 692-694, 1996.

CALLISTER W.D. **Ciência e Engenharia dos Materiais: Uma Introdução**. LTC Editoras.

CAWLEY, P. Long range inspection of structures using low frequency ultrasound. In: STRUCTURAL DAMAGE ASSESSMENT USING ADVANCED SIGNAL PROCESSING PROCEDURES, 1997, Sheffield. **Proceedings Sheffield**: University of Sheffield, 1997. p. 1-17.

CHAN, C.; SUN, J.; TAN, K. M.; DONG, X.; SHUM, P. Application of an artificial neural network for simultaneous measurement of bending curvature and temperature with long period fiber gratings. *Sensors and Actuators A: Physical*, v. 137, n. 2, p. 262-267, 2007.

COSTA, R.Z.V., POSSETTI, G.R.C., DE ARRUDA, L.V.R., MULLER, M., FABRIS, J.L. Curvature vector smart sensing with a long-period fibre grating probed by artificial intelligence. **Meas. Sci. Technol**, 2010.

COWIE, B. M., MAIN, A. S., WEBB, D. J., BRETT, P. N. Distributive tactile sensing using fibre Bragg grating sensors. **Proceedings of SPIE**, n. 6619, p. 66193T, 2007.

DA SILVA, I.N., SPATTI D., e FLAUZINO, R. (2010). **Redes neurais artificiais para engenharia e ciências aplicadas**: curso prático, Artliber Editora Ltda, São Paulo, SP, Brasil. ISBN978-85-88098-53-4.

DAI, Y., CHEN, X., SUN, J., YAO, Y., XIE, S., Dispersion compensation based on sampled fiber grating fabricated with reconstruction equivalent-chirp method, **IEEE Photonics Technol Letters**, v. 18, n. 8, p. 941-943, 2006

DE LOURENÇO, I., Jr.; 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, p. 4761-4776, 2010.

GARCIA, A. (2000). **Ensaio dos materiais**. Livros técnicos e científicos Editora.

GOWAR, J. Optical Communication Systems, Prantice-Hall, 1984.

HAYKIN, S. Neural Networks: a Comprehensive Foundation, ed. 4, Prentice-Hall, 2008.

HILL, K. O., FUJII, Y., JOHNSON, D. C., KAWASAKI, B. S. Photosensitivity in opticalfiber waveguides: Application to reflection filter fabrication. **Appl. Phys. Lett.**, v. 32, p. 647-649, 1978.

HILL, K. O., MELTZ, G., Fiber Bragg grating technology fundamentals and overview, **J. Light. Technol.**, v.15, n. 8, p. 1263-1276, 1997.

HILL, K.O., MALO, B., BILODEAU, F., JOHNSON, D.C., Bragg gratings fabricated in monomode photosensitive optical fiber by UV exposure through a phase mask, **Applied Physics Letters**, vol. 62, p. 1035-1037, 1993.

J.D. PEARSON; D. LABARBERA; M. PRABHUGOUD; K. PETERS; and M. A. ZIKRY. Experimental and computaionalinverstigation of low-impact velocity and quasi-static failure o pmma .**Experimental Mechanics**, vol. 53, pp. 53–66, 2013.

KASHYAP, R. Fiber Bragg Gratings, Academic Press, 1999.

KESSLER, S. S.; SPEARING, S. M.; ATALA, M. J.; CESNIK, C. E. S.; SOUTIS, C. Damage detection in composite materials using frequency response methods. Composites Part B: **Engineering**, Oxford, v. 33, n. 1, p. 87-95, 2002.

LAUDATTI, A., MENNELLA, F., GIORDANO, M., D'ALTRUI, G., TASSINI, C. C., CUSANO, A., A fiber-optic Bragg grating seismic sensor, **Photonics Technol. Letters**, v. 19, n. 24, p 1991-1993, 2007.

LEMAIRE, P. J., ATKINS, R. M., MIZRAHI, V., REED, W. A., **Electronics Letters**, vol. 29, p. 1191-1198, 1993, citado por (Othonos, 1997).

LÓPEZ-HIGUERA, J. M. *Optical Sensors*, Universidad de Cantabria, 1998.

LOURENÇO, I. J., 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**, 10, p. 4761-4776; doi:10.3390/s100504761, 2010.

LOUTAS, T.H., PANOPOULOU. A., ROULIAS, D., KOSTOPOULOS, V., Intelligent health monitoring of aerospace composite structures based on dynamic strain measurements, **Expert Systems with Applications**, vol. 39, p 8412 – 8422, 2012.

M. LIU, Z. ZHOU, Y. TAN, A. LING, and M. KE, Fiber bragg grating sensors based mechanical structure damage identification, **Mechanika**, vol. 18, pp. 108–112, 2012.

MAIN, A. S., COWIE, B. M., WEBB, D. J. Low cost distributive sensing smart **Surface.Proceedings of SPIE**, p. FA5, 2006.

MARK, J.E. *Physical Properties of Polymers Handbook*, 2nd ed. University of Cincinnati, Springer Science + Business Media, LLC: New York. 2007

MELTZ, G., MOREY, W.W., GLENN, W. H., Formation of Bragg gratings in optical fibers by a transverse holographic method, **Optics Letters**, vol. 14, p. 823-825, 1989.

OKAMOTO, K. *Fundamentals of Optical Waveguides*, Academic Press, 2000.

OTHONOS, A., KALLI, K., *Fiber Bragg Gratings: Fundamental and Applications in Telecommunications and sensing*, Artech House, 1999.

PATERNO, A. S., ARRUDA, L. V. R., KALINOWSKI, H. J. Approximation methods of optical spectra: an analysis of the application of constructive RBF networks in fiber optic sensing. **Learning and Nonlinear Models**, v. 3, n. 2, p. 61-70, 2005.

POSSETTI, G. R. C., CAMILOTTI, E., CÔCCO, L. C., YAMAMOTO, C. I., FALATE, R., DE ARRUDA, L. V. R., MULLER, M., FABRIS, J. L. Sensor Inteligente a Fibra Ótica para Análise da Conformidade da Gasolina Brasileira. In: Rio Oil&Gas Expo and Conference 2008, 2008, Rio de Janeiro. **Technical Papers**, IBP1973_08, 2008.

RYTTER, A. Vibration based inspection of civil engineering structures. 1993. 193 f. **Tese de Doutorado**, Dept. of Building Technology and Structural Eng, Aalborg University, Denmark, 1993.

SOHN, H.; FARRAR, C. R.; HEMEZ, F. M.; SHUNK, D. D.; STINEMATES, D. W.; NADLER, B. R.; CZARNECKI, J. J. **A review of structural health monitoring literature**: 1996–2001. Los Alamos National Laboratory Report, LA-13976-MS, 2004.

STONE, J., Photorefractivity in GeO₂-doped silica fibers, **Journal Applied Physics**, vol. 62, p. 4371-4376, 1987.

TODD, M., JOHNSON, G., AND VOHRA, S. Progress Towards Deployment of Bragg Grating-Based Fiber Optic Systems in Structural Monitoring Applications, **European COST F3 Conference on System Identification and Structural Health Monitoring**, Madrid, Spain, pp. 521–530, 2000.

TODD, M.D., JOHNSON, G., AND VOHRA, S., CHEN-CHANG, C., DANVER, B., AND MALSAWMA, L. (1999) Civil Infrastructure Monitoring with Fiber Optic Bragg Grating Sensor Arrays, *Structural Health Monitoring 2000*, Stanford University, Palo Alto, California, pp. 359–368.

UDD, Eric et al., *Fiber optic sensors: an introduction for engineers and scientists*. USA: Edited by Eric Udd, 1990.

VUOLO, José. H. *Fundamentos da teoria de erros*, 2ed. São Paulo: EdgardBlücher, 1996.

XU, M.G., REEKIE, L., CHOW, Y. T., DAKIN, J. P., Optical in-fiber grating high pressure sensor, **Electron.Lett.**, v. 29, n. 4, p. 398-399, 1993.

YARIV, A., YEH, P., **Optical Waves in Crystals**, New York: John Wiley & Sons, 1984.

APÊNDICES

APÊNDICE I - CÓDIGO-FONTE UTILIZADO PARA TRATAMENTO DOS DADOS EXPERIMENTAIS COM RNA PARA CLASSIFICAR QUADRANTE

APÊNDICE II - CÓDIGO-FONTE UTILIZADO PARA TRATAMENTO DOS DADOS EXPERIMENTAIS COM RNA PARA LOCALIZAR IMPACTOS EM UM PLANO

APÊNDICE III – PUBLICAÇÃO RESULTANTE DESTE TRABALHO

APÊNDICE I - CÓDIGO-FONTE UTILIZADO PARA TRATAMENTO DOS DADOS EXPERIMENTAIS COM RNA PARA CLASSIFICAR QUADRANTES

```

% INICIALIZAÇÕES
clear all;
close all;
clc;

extensoes={'*.dat'};

% ARQUIVO DE ENTRADA PARA TREINO 1
label_1='Escolha os dados do treinamento canto 1';
pasta_1 = 'E:\experimentais_12_07_12\20_02_13\X1_Y1\Matlab_X1_Y1';
[busca_1,pastaRaiz_1]=uigetfile(extensoes,label_1,pasta_1);
[tempo_1, lambda1_1, lambda1_2, lambda1_3, lambda1_4]=textread
(busca_1;%n %n %n %n %n %*[^n]';'delimiter';'\t';'headerlines'; 1)
X1_Y1_out = ones(1,numel (tempo_1)); % cria a saida de validação desejada

% ARQUIVO DE ENTRADA PARA TREINO 2
label_2 = 'Escolha os dados do treinamento canto 2';
pasta_2 = 'E:\experimentais_12_07_12\20_02_13\X1_Y1\Matlab_X1_Y1';
[busca_2,pastaRaiz_2]=uigetfile(extensoes,label_2,pasta_2);
[tempo_2, lambda2_1, lambda2_2, lambda2_3, lambda2_4] = textread
(busca_2;%n %n %n %n %n %*[^n]';'delimiter';'\t';'headerlines'; 1)
X1_Y9_out = 2*ones(1,numel (tempo_2)); % cria a saida de validação desejada

% % ARQUIVO DE ENTRADA PARA TREINO 3
label_3='Escolha os dados do treinamento canto 3';
pasta_3 = 'E:\experimentais_12_07_12\20_02_13\X1_Y1\Matlab_X1_Y1';
[busca_3,pastaRaiz_3]=uigetfile(extensoes,label_3,pasta_3);
[tempo_3, lambda3_1, lambda3_2, lambda3_3, lambda3_4] = textread
(busca_3;%n %n %n %n %n %*[^n]';'delimiter';'\t';'headerlines'; 1)
X9_Y1_out = 3*ones(1,numel (tempo_3)); % cria a saida de validação desejada

% % ARQUIVO DE ENTRADA PARA TREINO 4
label_4='escolha os dados do treinamento canto 4';
pasta_4 = 'e:\experimentais_12_07_12\20_02_13\x1_y1\matlab_x1_y1';
[busca_4,pastaraiz_4]=uigetfile(extensoes,label_4,pasta_4);
[tempo_4, lambda4_1, lambda4_2, lambda4_3, lambda4_4] = textread
(busca_4;%n %n %n %n %n %*[^n]';'delimiter';'\t';'headerlines'; 1)
x9_y9_out = 4*ones(1,numel (tempo_4)); % cria a saida de validação desejada

% ARQUIVO DE ENTRADA PARA TESTE DE VALIDACAO

```

```

label_test='Escolha os dados do treinamento canto 5';
pasta_test = 'E:\experimentais_12_07_12\20_02_13\X1_Y1\Matlab_X1_Y1';
[busca_test,pastaRaiz_test]=uigetfile(extensoes,label_test,pasta_test);
[tempo_test, lambda_test_1, lambda_test_2, lambda_test_3, lambda_test_4] = textread
(busca_test;%n %n %n %n %n %*[\n]';'delimiter';'\t';'headerlines'; 1);
test_out = 5*ones(1,numel (tempo_test)); % cria a saida de validação desejada

% ARQUIVO DE ENTRADA PARA TREINO 1
Val_label_1='Escolha os dados de validacao canto 1';
Val_pasta_1 = 'E:\experimentais_12_07_12\20_02_13\X1_Y1\Matlab_X1_Y1';
[Val_busca_1,Val_pastaRaiz_1]=uigetfile(extensoes,Val_label_1,Val_pasta_1);
[Val_tempo_1, Val_lambda1_1, Val_lambda1_2, Val_lambda1_3, Val_lambda1_4]=textread
(Val_busca_1;%n %n %n %n %n %*[\n]';'delimiter';'\t';'headerlines'; 1);
Val_X1_Y1_out = ones(1,numel (Val_tempo_1)); % cria a saida de validação desejada

% ARQUIVO DE ENTRADA PARA TREINO 2
Val_label_2 = 'Escolha os dados do validacao canto 2';
Val_pasta_2 = 'E:\experimentais_12_07_12\20_02_13\X1_Y1\Matlab_X1_Y1';
[Val_busca_2,Val_pastaRaiz_2]=uigetfile(extensoes,Val_label_2,Val_pasta_2);
[Val_tempo_2, Val_lambda2_1, Val_lambda2_2, Val_lambda2_3, Val_lambda2_4] = textread
(Val_busca_2;%n %n %n %n %n %*[\n]';'delimiter';'\t';'headerlines'; 1);
Val_X1_Y9_out = 2*ones(1,numel (Val_tempo_2)); % cria a saida de validação desejada

% % ARQUIVO DE ENTRADA PARA TREINO 3
Val_label_3='Escolha os dados do validacao canto 3';
Val_pasta_3 = 'E:\experimentais_12_07_12\20_02_13\X1_Y1\Matlab_X1_Y1';
[Val_busca_3,Val_pastaRaiz_3]=uigetfile(extensoes,Val_label_3,Val_pasta_3);
[Val_tempo_3, Val_lambda3_1, Val_lambda3_2, Val_lambda3_3, Val_lambda3_4] = textread
(Val_busca_3;%n %n %n %n %n %*[\n]';'delimiter';'\t';'headerlines'; 1);
Val_X9_Y1_out = 3*ones(1,numel (Val_tempo_3)); % cria a saida de validação desejada

% % ARQUIVO DE ENTRADA PARA TREINO 4
Val_label_4='escolha os dados do validacao canto 4';
Val_pasta_4 = 'e:\experimentais_12_07_12\20_02_13\x1_y1\matlab_x1_y1';
[Val_busca_4,Val_pastaraiz_4]=uigetfile(extensoes,Val_label_4,Val_pasta_4);
[Val_tempo_4, Val_lambda4_1, Val_lambda4_2, Val_lambda4_3, Val_lambda4_4] = textread
(Val_busca_4;%n %n %n %n %n %*[\n]','delimiter','\t','headerlines', 1);
Val_x9_y9_out = 4*ones(1,numel (Val_tempo_4)); % cria a saida de validação desejada

% ARQUIVO DE ENTRADA PARA TESTE DE VALIDACAO
Val_label_test='Escolha os dados do validacao canto 5';

```

```

Val_pasta_test = 'E:\experimentais_12_07_12\20_02_13\X1_Y1\Matlab_X1_Y1';
[Val_busca_test,Val_pastaRaiz_test]=uigetfile(extensoes,Val_label_test,Val_pasta_test);
[Val_tempo_test, Val_lambda_test_1, Val_lambda_test_2, Val_lambda_test_3, Val_lambda_test_4] = textread
(Val_busca_test,'%n %n %n %n %n %*[\n]','delimiter','\t','headerlines', 1);
Val_test_out = 5*ones(1,numel (Val_tempo_test)); % cria a saida de validação desejada

treinamento = 450; % numero de amostras conformes selecionadas para treinamento
qtde_treinamento = numel(lambda1_1) - treinamento; % numero de amostras selecionadas para teste

validacao = 150; % numero de amostras selecionadas para treinamento
qtde_validacao = numel(Val_lambda1_1) - validacao; % numero de amostras selecionadas para teste

% CRIAÇÃO DAS MATRIZES DE TREINAMENTO
X1_Y1_ent =[ lambda1_1'; lambda1_2'; lambda1_3'; lambda1_4' ];% matriz de entrada amostras
X1_Y1_aux = X1_Y1_ent;

X1_Y9_ent =[ lambda2_1'; lambda2_2'; lambda2_3'; lambda2_4' ];% matriz de entrada amostras
X1_Y9_ent_aux = X1_Y9_ent;

X9_Y1_ent =[ lambda3_1'; lambda3_2'; lambda3_3'; lambda3_4' ];% matriz de entrada amostras
X9_Y1_ent_aux = X9_Y1_ent;

X9_Y9_ent =[ lambda4_1'; lambda4_2'; lambda4_3'; lambda4_4' ];% matriz de entrada amostras
X9_Y9_ent_aux = X9_Y9_ent;

X5_Y5_ent =[ lambda_test_1'; lambda_test_2'; lambda_test_3'; lambda_test_4' ];% matriz de entrada amostras
X5_Y5_ent_aux = X5_Y5_ent;

% CRIAÇÃO DAS MATRIZES DE VALIDACAO
Val_X1_Y1_ent =[ Val_lambda1_1'; Val_lambda1_2'; Val_lambda1_3'; Val_lambda1_4' ];
Val_X1_Y1_aux = Val_X1_Y1_ent;% matriz de entrada amostras

Val_X1_Y9_ent =[ Val_lambda2_1'; Val_lambda2_2'; Val_lambda2_3'; Val_lambda2_4' ];
Val_X1_Y9_ent_aux = Val_X1_Y9_ent;% matriz de entrada amostras

Val_X9_Y1_ent =[ Val_lambda3_1'; Val_lambda3_2'; Val_lambda3_3'; Val_lambda3_4' ];
Val_X9_Y1_ent_aux = Val_X9_Y1_ent;% matriz de entrada amostras

```

```

Val_X9_Y9_ent =[ Val_lambda4_1'; Val_lambda4_2'; Val_lambda4_3'; Val_lambda4_4' ];
Val_X9_Y9_ent_aux = Val_X9_Y9_ent;% matriz de entrada amostras

Val_X5_Y5_ent =[ Val_lambda_test_1'; Val_lambda_test_2'; Val_lambda_test_3'; Val_lambda_test_4' ];
Val_X5_Y5_ent_aux = Val_X5_Y5_ent;% matriz de entrada amostras

% selecao dos dados para treinamento por meio da criacao de vetores
in_X_Treinamento = X1_Y1_aux(:,1:treinamento);
out_X_treinamento = ones(1,treinamento);

in_X_Treinamento_x1_y9 = X1_Y9_ent_aux(:,1:treinamento);
out_X_treinamento_x1_y9 = 2*ones(1,treinamento);

in_X_Treinamento_x9_y1 = X9_Y1_ent_aux(:,1:treinamento);
out_X_treinamento_x9_y1 = 3*ones(1,treinamento);

in_X_Treinamento_x9_y9 = X9_Y9_ent_aux(:,1:treinamento);
out_X_treinamento_x9_y9 = 4*ones(1,treinamento);

in_X_Treinamento_x5_y5 = X5_Y5_ent_aux(:,1:treinamento);
out_X_treinamento_x5_y5 = 5*ones(1,treinamento);

in_X_valicacao = Val_X1_Y1_aux(:,1:validacao);
out_X_valicacao = ones(1,validacao);

in_X_valicacao_x1_y9 = Val_X1_Y9_ent_aux(:,1:validacao);
out_X_valicacao_x1_y9 = 2*ones(1,validacao);

in_X_valicacao_x9_y1 = Val_X9_Y1_ent_aux(:,1:validacao);
out_X_valicacao_x9_y1 = 3*ones(1,validacao);

in_X_valicacao_x9_y9 = Val_X9_Y9_ent_aux(:,1:validacao);
out_X_valicacao_x9_y9 = 4*ones(1,validacao);

in_X_valicacao_x5_y5 = Val_X5_Y5_ent_aux(:,1:validacao);
out_X_valicacao_x5_y5 = 5*ones(1,validacao);

% concatenacao dos vetores anteriormente criados para criacao das matrizes de treinamento e de teste

```

```

matriz_treinamento_in_X = [in_X_Treinamento,in_X_Treinamento_x1_y9,in_X_Treinamento_x9_y1,in_X_Treinamento_x9_y9,
    in_X_Treinamento_x5_y5];%matriz de entrada em X
vetor_treinamento_out_X = [out_X_treinamento,out_X_treinamento_x1_y9,out_X_treinamento_x9_y1,out_X_treinamento_x9_y9,
    out_X_treinamento_x5_y5];% matriz de saida em X
matriz_validacao_in_X = [in_X_valicacao,in_X_valicacao_x1_y9,in_X_valicacao_x9_y1,in_X_valicacao_x9_y9,
    in_X_valicacao_x5_y5];% matriz de entrada de validacao em X
vetor_validacao_out_X = [out_X_validacao,out_X_validacao_x1_y9,out_X_validacao_x9_y1,out_X_validacao_x9_y9,
    out_X_validacao_x5_y5];% matriz de saida de validacao em X

% MLP PARA CLASSIFICAR QUADRANTES
% INICIALIZACOES E CONSTRUCAO DA MLP
net = newff(matriz_treinamento_in_X,vetor_treinamento_out_X,[30,30],{'tansig','tansig'},'trainlm');
%net.layers{1}.initFcn = 'initwb';
net.divideFcn = '';
net.trainParam.show = 10;
net.trainParam.lr = 0.10;
net.trainParam.epochs = 30;
net.trainParam.goal = 0.100;

% simula saIda da MLP alimentada com dados de teste para treinamento
net = train(net,matriz_treinamento_in_X,vetor_treinamento_out_X);
outputs_train = net(matriz_treinamento_in_X);
errors = outputs_train - vetor_treinamento_out_X;
perf = perform(net,outputs_train,vetor_treinamento_out_X);

% simula saIda da MLP alimentada com dados de teste de validacao
vetor_outputs_simula_MLP = sim (net, matriz_validacao_in_X);

% VERIFICACAO DA RESPOSTA DA RBF ALIMENTADA COM OS DADOS DE TREINAMENTO
% plota comparacao entre valor esperado e valor de saida da RNA alimentada com os dados de treinamento
figure(1)
plot(outputs_train,'*')
hold
plot(vetor_treinamento_out_X, '.')
grid;
xlabel('AMOSTRA MLP')
ylabel('CLASSE PERTENCENTE')
title('CLASSIFICACAO DAS AMOSTRAS DE TREINAMENTO')
legend('Simulado', 'Desejado')

% plota comparacao entre valor esperado e valor de saida da RNA alimentada com os dados de teste
figure(2)
plot(vetor_outputs_simula_MLP,'*')
hold
plot(vetor_validacao_out_X, '.')
grid;
xlabel('AMOSTRA MLP')
ylabel('CLASSE PERTENCENTE')
title('CLASSIFICAÇÃO DAS AMOSTRAS DE TESTE')
legend('Simulado', 'Desejado')

```

APÊNDICE II - CÓDIGO-FONTE UTILIZADO PARA TRATAMENTO DOS DADOS EXPERIMENTAIS COM RNA PARA LOCALIZAR IMPACTOS EM UM PLANO

```

% inicializacoes
clear all;
close all;
clc;
extensoes={'*.dat'};

% ARQUIVO DE ENTRADA PARA TREINO 1
label_1='Escolha os dados do treinamento canto 1';
pasta_1 = 'E:\experimentais_12_07_12\18_09_13_nova_mtge\rna_cantos\rna_nova';
[busca_1,pastaRaiz_1]=uigetfile(extensoes,label_1,pasta_1);
[tempo_1, lambda1_1, lambda1_2, lambda1_3, lambda1_4]=
textread(busca_1,'%n %n %n %n %n %*[\n]','delimiter','\t','headerlines', 1);

% ARQUIVO DE ENTRADA PARA TREINO 2
label_2 = 'Escolha os dados do treinamento canto 2';
pasta_2 = 'E:\experimentais_12_07_12\18_09_13_nova_mtge\rna_cantos\rna_nova';
[busca_2,pastaRaiz_2]=uigetfile(extensoes,label_2,pasta_2);
[tempo_2, lambda2_1, lambda2_2, lambda2_3, lambda2_4] =
textread(busca_2,'%n %n %n %n %n %*[\n]','delimiter','\t','headerlines', 1);

% ARQUIVO DE ENTRADA PARA TREINO 3
label_3='Escolha os dados do treinamento canto 3';
pasta_3 = 'E:\experimentais_12_07_12\18_09_13_nova_mtge\rna_cantos\rna_nova';
[busca_3,pastaRaiz_3]=uigetfile(extensoes,label_3,pasta_3);
[tempo_3, lambda3_1, lambda3_2, lambda3_3, lambda3_4] =
textread(busca_3,'%n %n %n %n %n %*[\n]','delimiter','\t','headerlines', 1);

% ARQUIVO DE ENTRADA PARA TREINO 4
label_4='escolha os dados do treinamento canto 4';
pasta_4 = 'E:\experimentais_12_07_12\18_09_13_nova_mtge\rna_cantos\rna_nova';
[busca_4,pastaraiz_4]=uigetfile(extensoes,label_4,pasta_4);
[tempo_4, lambda4_1, lambda4_2, lambda4_3, lambda4_4] =
textread(busca_4,'%n %n %n %n %n %*[\n]','delimiter','\t','headerlines', 1);

% ARQUIVO DE ENTRADA PARA Treino 5
label_test='Escolha os dados do treinamento canto 5';
pasta_test = 'E:\experimentais_12_07_12\18_09_13_nova_mtge\rna_cantos\rna_nova';
[busca_test,pastaRaiz_test]=uigetfile(extensoes,label_test,pasta_test);
[tempo_5, lambda5_1, lambda5_2, lambda5_3, lambda5_4] =
textread(busca_test,'%n %n %n %n %n %*[\n]','delimiter','\t','headerlines', 1);

% ARQUIVO DE ENTRADA PARA TESTE 1
Val_label_1='Escolha os dados de validacao canto 1';
Val_pasta_1 = 'E:\experimentais_12_07_12\18_09_13_nova_mtge\rna_cantos\rna_nova';
[Val_busca_1,Val_pastaRaiz_1]=uigetfile(extensoes,Val_label_1,Val_pasta_1);
[Val_tempo_1, Val_lambda1_1, Val_lambda1_2, Val_lambda1_3, Val_lambda1_4]=
textread(Val_busca_1,'%n %n %n %n %n %*[\n]','delimiter','\t','headerlines', 1);

% ARQUIVO DE ENTRADA PARA TESTE 2
Val_label_2 = 'Escolha os dados do validacao canto 2';
Val_pasta_2 = 'E:\experimentais_12_07_12\18_09_13_nova_mtge\rna_cantos\rna_nova';
[Val_busca_2,Val_pastaRaiz_2]=uigetfile(extensoes,Val_label_2,Val_pasta_2);

```

```

[Val_tempo_2, Val_lambda2_1, Val_lambda2_2, Val_lambda2_3, Val_lambda2_4] =
textread(Val_busca_2, '%n %n %n %n %n %*[\n]', 'delimiter', '\t', 'headerlines', 1);

% % ARQUIVO DE ENTRADA PARA TESTE 3
Val_label_3='Escolha os dados do validacao canto 3';
Val_pasta_3 = 'E:\experimentais_12_07_12\18_09_13_nova_mtge\RNA_cantos\RNA_nova';
[Val_busca_3,Val_pastaRaiz_3]=uigetfile(extensoes,Val_label_3,Val_pasta_3);
[Val_tempo_3, Val_lambda3_1, Val_lambda3_2, Val_lambda3_3, Val_lambda3_4] =
textread(Val_busca_3, '%n %n %n %n %n %*[\n]', 'delimiter', '\t', 'headerlines', 1);

% % ARQUIVO DE ENTRADA PARA TESTE 4
Val_label_4='escolha os dados do validacao canto 4';
Val_pasta_4 = 'e:\experimentais_12_07_12\18_09_13_nova_mtge\RNA_cantos\RNA_nova';
[Val_busca_4,Val_pastaraiz_4]=uigetfile(extensoes,Val_label_4,Val_pasta_4);
[Val_tempo_4, Val_lambda4_1, Val_lambda4_2, Val_lambda4_3, Val_lambda4_4] =
textread(Val_busca_4, '%n %n %n %n %n %*[\n]', 'delimiter', '\t', 'headerlines', 1);

% ARQUIVO DE ENTRADA PARA TESTE 5
Val_label_test='Escolha os dados do validacao canto 5';
Val_pasta_test = 'e:\experimentais_12_07_12\18_09_13_nova_mtge\RNA_cantos\RNA_nova
[Val_busca_test,Val_pastaRaiz_test]=uigetfile(extensoes,Val_label_test,Val_pasta_t
[Val_tempo_5, Val_lambda5_1, Val_lambda5_2, Val_lambda5_3, Val_lambda5_4] =
textread(Val_busca_test, '%n %n %n %n %n %*[\n]', 'delimiter', '\t', 'headerlines', 1

treinamento = 450; % numero total de colunas
% numero de colunas selecionadas para treinamento
qtde_treinamento = numel(lambdal_1) - treinamento;

validacao = 150; % numero total de colunas
% numero de colunas selecionadas para teste
qtde_validacao = numel(Val_lambdal_1) - validacao;

% CRIAÇÃO DAS MATRIZES DE TREINAMENTO
X1_Y1_ent =[ lambdal_1'; lambdal_2'; lambdal_3'; lambdal_4' ];
X1_Y1_aux = X1_Y1_ent;% matriz de entrada FBG1

X1_Y9_ent =[ lambda2_1'; lambda2_2'; lambda2_3'; lambda2_4' ];
X1_Y9_ent_aux = X1_Y9_ent;% matriz de entrada FBG2

X9_Y1_ent =[ lambda3_1'; lambda3_2'; lambda3_3'; lambda3_4' ];
X9_Y1_ent_aux = X9_Y1_ent;% matriz de entrada FBG3

X9_Y9_ent =[ lambda4_1'; lambda4_2'; lambda4_3'; lambda4_4' ];
X9_Y9_ent_aux = X9_Y9_ent;% matriz de entrada FBG4

X5_Y5_ent =[ lambda5_1'; lambda5_2'; lambda5_3'; lambda5_4' ];
X5_Y5_ent_aux = X5_Y5_ent;% matriz de entrada FBG5

% CRIAÇÃO DAS MATRIZES DE VALIDACAO
Val_X1_Y1_ent =[ Val_lambdal_1'; Val_lambdal_2'; Val_lambdal_3'; Val_lambdal_4' ];
Val_X1_Y1_aux = Val_X1_Y1_ent;% matriz de entrada FBG1

Val_X1_Y9_ent =[ Val_lambda2_1'; Val_lambda2_2'; Val_lambda2_3'; Val_lambda2_4' ];
Val_X1_Y9_ent_aux = Val_X1_Y9_ent;% matriz de entrada FBG2

```

```

Val_X9_Y1_ent =[ Val_lambda3_1'; Val_lambda3_2'; Val_lambda3_3'; Val_lambda3_4' ];
Val_X9_Y1_ent_aux = Val_X9_Y1_ent;% matriz de entrada FBG3

Val_X9_Y9_ent =[ Val_lambda4_1'; Val_lambda4_2'; Val_lambda4_3'; Val_lambda4_4' ];
Val_X9_Y9_ent_aux = Val_X9_Y9_ent;% matriz de entrada FBG4

val_x5_y5_ent =[Val_lambda5_1'; Val_lambda5_2'; Val_lambda5_3'; Val_lambda5_4'];
Val_x5_y5_ent_aux = val_x5_y5_ent;% matriz de entrada FBG5

% criacao de vetores com os dados selecionados para treinamento
in_X_Treinamento = X1_Y1_aux(:,1:treinamento);
out_X_treina1 = ones(1,treinamento);
out_X_treina2 = ones (1,treinamento);
out_x_total1 = [out_X_treina1;out_X_treina2];

in_X_Treinamento_x1_y9 = X1_Y9_ent_aux(:,1:treinamento);
out_X_treina3 = ones(1,treinamento);
out_X_treina4 = 9*ones(1,treinamento);
out_x_total2 = [out_X_treina3;out_X_treina4];

in_X_Treinamento_x9_y1 = X9_Y1_ent_aux(:,1:treinamento);
out_X_treina5 = 9*ones(1,treinamento);
out_X_treina6 = ones(1,treinamento);
out_x_total3 = [out_X_treina5;out_X_treina6];

in_X_Treinamento_x9_y9 = X9_Y9_ent_aux(:,1:treinamento);
out_X_treina7 = 9*ones(1,treinamento);
out_X_treina8 = 9*ones(1,treinamento);
out_x_total4 = [out_X_treina7;out_X_treina8];

in_X_Treinamento_x5_y5 = X5_Y5_ent_aux(:,1:treinamento);
out_X_treina9 = 5*ones(1,treinamento);
out_X_treina10 = 5*ones(1,treinamento);
out_x_total5 = [out_X_treina9;out_X_treina10];

% criacao de vetores com os dados selecionados para validacao
in_X_valicacao = Val_X1_Y1_aux(:,1:validacao);
out_X_valida1 = ones(1,validacao);
out_X_valida2 = ones(1,validacao);
out_X_VTotal1 = [out_X_valida2;out_X_valida1];

in_X_valicacao_x1_y9 = Val_X1_Y9_ent_aux(:,1:validacao);
out_X_valida3 = ones(1,validacao);
out_X_valida4 = 9*ones(1,validacao);
out_X_VTotal2 = [out_X_valida3;out_X_valida4];

in_X_valicacao_x9_y1 = Val_X9_Y1_ent_aux(:,1:validacao);
out_X_valida5 = 9*ones(1,validacao);
out_X_valida6 = ones(1,validacao);
out_X_VTotal3 = [out_X_valida6;out_X_valida5];

in_X_valicacao_x9_y9 = Val_X9_Y9_ent_aux(:,1:validacao);
out_X_valida7 = 9*ones(1,validacao);

```

```

out_X_valida8 = 9*ones(1,validacao);
out_X_VTotal4 = [out_X_valida7;out_X_valida8];

in_X_valicacao_x5_y5 = Val_x5_y5_ent_aux(:,1:validacao);
out_X_valida9 = 5*ones(1,validacao);
out_X_valida10 = 5*ones(1,validacao);
out_X_VTotal5 = [out_X_valida9;out_X_valida10];

% concatenacao dos vetores para criacao das matrizes de treinamento e de teste
matriz_treinamento_in_X = [in_X_Treinamento,in_X_Treinamento_x1_y9,
in_X_Treinamento_x9_y9,in_X_Treinamento_x5_y5];%matriz de entrada em X
vetor_treinamento_out_X = [out_x_total1,out_x_total2,out_x_total3,
out_x_total4,out_x_total5];% matriz de saida em X

matriz_validacao_in_X = [in_X_valicacao,in_X_valicacao_x1_y9,in_X_valicacao_x9_y1
in_X_valicacao_x9_y9,in_X_valicacao_x5_y5];% matriz de entrada de validacao em Y
vetor_validacao_out_X = [out_X_VTotal1,out_X_VTotal2,out_X_VTotal3,
out_X_VTotal4,out_X_VTotal5];% matriz de saida de validacao em Y

% VERIFICACAO DA RESPOSTA DA MLP ALIMENTADA COM OS DADOS DE TESTE
% INICIALIZACOES E CONSTRUCAO DA MLP
net = newff(matriz_treinamento_in_X,vetor_treinamento_out_X,[40,40,40],
{'tansig','tansig','tansig'},'trainlm');
net.layers(1).initFcn = 'initwb';
net.divideFcn = '';
net.trainParam.show = 22;
net.trainParam.lr = 0.5;
net.trainParam.epochs = 60;
net.trainParam.goal = 0.001;

% simula saida da MLP alimentada com dados de teste para treinamento
net = train(net,matriz_treinamento_in_X,vetor_treinamento_out_X);
outputs_train = net(matriz_treinamento_in_X);
errors = outputs_train - vetor_treinamento_out_X;
perf = perform(net,outputs_train,vetor_treinamento_out_X);
save ('impacto_net.mat', 'net');

% VERIFICACAO DA RESPOSTA DA MLP ALIMENTADA COM OS DADOS DE TESTE
% simula saida da MLP alimentada com dados de teste de validacao
vetor_outputs_simula_MLP = sim (net, matriz_validacao_in_X);

% VERIFICACAO DA RESPOSTA DA RBF ALIMENTADA COM OS DADOS DE TREINAMENTO
% plota comparacao entre valor esperado e valor simulado com a RNA
%alimentada com os dados de treinamento
figure(1)
plot (outputs_train(1,1:end), outputs_train(2,1:end),'.'); hold on;
plot (vetor_treinamento_out_X(1,1:end), vetor_treinamento_out_X(2,1:end),'*', 'col
grid;
xlabel('PANO X')
ylabel('PLANO Y')
title('CLASSIFICACAO DOS IMPACTOS NA ETAPA DE TREINAMENTO')
legend('Simulado', 'Desejado')

% plota comparacao entre valor esperado e valor simulado com a

```

```
%RNA alimentada com os dados de teste
figure(2)
plot (vetor_outputs_simula_MLP(1,1:end), vetor_outputs_simula_MLP(2,1:end), '**');
hold on;
plot (vetor_validacao_out_X(1,1:end), vetor_validacao_out_X(2,1:end), '**', 'color'
grid;
xlabel('PLANO X')
ylabel('PLANO Y')
title('CLASSIFICACAO DOS IMPACTOS NA ETAPA DE TREINAMENTO')
legend('Simulado', 'Desejado')
```

APENDICE III – PUBLICAÇÃO RESULTANTE DESTE TRABALHO

TRABALHO COMPLETO PUBLICADO EM ANAIS DE CONGRESSOS

RIBEIRO, F.; POSSETTI, G R C; FABRIS, J. L; MULLER, M. Smart optical fiber sensor for impact localization on planar structures. In: SBMO/IEEE MTT-S International Microwave and Optoelectronics Conference, 2013, Rio de Janeiro. SBMO/IEEE MTT-S International Microwave and Optoelectronics Conference, 2013. v. 1. p. 1-3.