

Universidade Federal de Juiz de Fora
Faculdade de Engenharia
Programa de Pós-Graduação em Engenharia Elétrica

Marco Aurélio Jucá da Silva Junior

Interrogação de Sensores a Fibra Óptica através de Métodos Computacionais

Juiz de Fora

2018

Marco Aurélio Jucá da Silva Junior

Interrogação de Sensores a Fibra Óptica através de Métodos Computacionais

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Alexandre Bessa dos Santos

Juiz de Fora

2018

Ficha catalográfica elaborada através do Modelo Latex do CDC da UFJF
com os dados fornecidos pelo(a) autor(a)

Jucá, Marco Aurélio.

Interrogação de Sensores a Fibra Óptica através de Métodos Computacionais / Marco Aurélio Jucá da Silva Junior. – 2018.

60 f. : il.

Orientador: Alexandre Bessa dos Santos

Dissertação (Mestrado) – Universidade Federal de Juiz de Fora, Faculdade de Engenharia. Programa de Pós-Graduação em Engenharia Elétrica, 2018.

1. Interrogação de Sensores Ópticos. 2. Métodos Computacionais. 3. Técnicas Inteligentes. I. Santos, Alexandre B., orient. II. Título.

Marco Aurélio Jucá da Silva Junior

Interrogação de Sensores a Fibra Óptica através de Métodos Computacionais

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica.

Aprovada em 11 de setembro de 2018.

BANCA EXAMINADORA

Prof. Dr. Alexandre Bessa dos Santos - Orientador
Universidade Federal de Juiz de Fora

Prof. Dr. Marcelo Eduardo Vieira Segatto
Universidade Federal do Espírito Santo

Prof. Dr. Diego Barreto Haddad
Centro Federal de Educação Tecnológica Celso Suckow
da Fonseca

Prof. Dr. Thiago Vieira Nogueira Coelho
Universidade Federal de Juiz de Fora

Prof. Dr. Leonardo Rocha Olivi
Universidade Federal de Juiz de Fora

AGRADECIMENTOS

A Deus, por todas as oportunidades que me foram oferecidas.

Aos meus pais, Adriana e Marco, que sempre me incentivaram e possibilitaram que eu aprofundasse meus estudos.

À minha esposa, Laís, por estar sempre ao meu lado e me apoiar e, especialmente, pela compreensão ao longo da realização deste trabalho. Também pelas valiosas contribuições ao texto.

Ao meu irmão, Bruno, à minha família e aos meus amigos, cujos constantes suporte e incentivo me ajudaram a continuar.

Ao professor Alexandre Bessa, pelos conselhos e orientações e, especialmente, pela confiança e pela oportunidade de participar de um grupo de trabalho tão especial como é o Laboratório de Instrumentação e Telemetria.

A todos os demais professores que contribuíram para minha formação.

À CAPES, pelos recursos recebidos durante parte deste trabalho.

“Engineering stimulates the mind.”
(Bruce Dickinson)

RESUMO

Sensores a fibra óptica tornaram-se uma alternativa popular aos sensores eletrônicos tradicionais devido às suas inúmeras vantagens. Um desafio importante no emprego de sensores ópticos é a interrogação do sensor, isto é, recuperar o valor da medição a partir da saída do sensor. Este trabalho visa a apresentar uma forma simples e eficaz de interrogar um sensor baseado em grade de Bragg em fibra (FBG) utilizando filtros ópticos e métodos computacionais convenientes. Como exemplo, foi escolhido um sensor de temperatura, embora o sistema de interrogação possa lidar com qualquer medição, sendo calibrado adequadamente. Esse sistema de interrogação é capaz de fornecer o valor preciso da temperatura sem medir diretamente o deslocamento do comprimento de onda de ressonância ou realizar qualquer cálculo de Fourier. Os métodos foram implementados e o treinamento realizado utilizando dados simulados. Resultados de simulação são apresentados e comparados a um método tradicional de interrogação. O sistema proposto neste trabalho mostrou um desempenho excelente ao identificar a temperatura a partir da saída do sensor e mostrou maior precisão em relação ao método tradicional apresentado.

Palavras-chave: Interrogação de Sensores Ópticos. Métodos Computacionais. Técnicas Inteligentes.

ABSTRACT

Optical fiber sensors have become a popular alternative to traditional electronic sensors due to their numerous advantages. An important challenge in deploying optical sensors is the interrogation of the sensor, that is, recovering the measurement value from the sensor output. This work aims to present a simple yet effective way of interrogating a fiber Bragg grating (FBG) sensor using optical filters and suitable computational methods. As an example, a temperature sensor was analyzed, although the interrogation system is able to deal with any measurement, by calibrating it suitably. This interrogation system is capable of giving the precise temperature value without directly measuring the resonance wavelength shift or performing any Fourier calculations. The methods were implemented and the training was accomplished using simulated data. Simulation results are presented and compared to a traditional method of interrogation. The system proposed in this work showed excellent performance in identifying the temperature from the sensor output and showed higher precision than the traditional method presented.

Keywords: Optical Sensor Interrogation. Computational Methods. Intelligent Techniques.

LISTA DE ILUSTRAÇÕES

Figura 1 – Distribuição de energia em alguns modos LP. (a) LP ₀₁ . (b) LP ₁₁ . (c) LP ₂₁ . (d) LP ₀₂ . (e) LP ₁₂ . (f) LP ₂₂	17
Figura 2 – Estrutura de uma grade de Bragg.	19
Figura 3 – Espectros resultantes do funcionamento de uma FBG.	20
Figura 4 – Espectro resultante do funcionamento de uma LPG.	22
Figura 5 – Característica espectral de transmissão de luz por uma LPG.	22
Figura 6 – Conjuntos fuzzy para temperatura interna de uma sala.	26
Figura 7 – Exemplo de fuzzificação.	29
Figura 8 – Exemplo de obtenção do grau de ativação. (a) Utilizando o operador de conjunção. (b) Utilizando o operador de disjunção.	31
Figura 9 – Exemplo de ativação do consequente de uma regra.	32
Figura 10 – Exemplo de agregação em um sistema com duas regras.	33
Figura 11 – Exemplo de defuzzificação pelo centroide.	33
Figura 12 – Exemplo completo de inferência <i>fuzzy</i>	34
Figura 13 – Modelo não linear de um neurônio.	37
Figura 14 – Tipos de função de ativação. (a) Função de limiar (degrau). (b) Funções sigmoides (logísticas) com diversas inclinações.	38
Figura 15 – Exemplos de redes diretas. (a) Rede direta de camada única. (b) Rede direta de múltiplas camadas.	39
Figura 16 – Visão geral do sistema de sensoriamento, composto do sensor e do interrogador.	42
Figura 17 – Espectro do sensor sobreposto aos espectros dos diferentes filtros. . . .	42
Figura 18 – Potência óptica na saída dos filtros para diversas temperaturas. . . .	43
Figura 19 – Funções de pertinência dos conjuntos <i>fuzzy</i> definidos manualmente. (a) Variáveis de entrada. (b) Variável de saída.	45
Figura 20 – Evolução do desempenho do FIS ao longo da otimização.	46
Figura 21 – Funções de pertinência dos conjuntos <i>fuzzy</i> otimizados pelo algoritmo de ecolocalização de morcegos. (a) Variável de entrada: potência após filtro 1. (b) Variável de entrada: potência após filtro 2. (c) Variável de entrada: potência após filtro 3. (d) Variável de saída: temperatura estimada.	47
Figura 22 – Desempenho do melhor ajuste polinomial de grau 3 com termos cruzados. (a) Resposta à temperatura. (b) Residual.	49
Figura 23 – Desempenho do interrogador baseado em lógica <i>fuzzy</i> . (a) Resposta à temperatura. (b) Residual.	49
Figura 24 – Desempenho do interrogador baseado em lógica <i>fuzzy</i> otimizado pelo algoritmo de ecolocalização de morcegos. (a) Resposta à temperatura. (b) Residual.	50

Figura 25 – Estrutura da rede escolhida.	51
Figura 26 – Desempenho do interrogador baseado em rede neural com 6 neurônios na camada oculta. (a) Resposta à temperatura. (b) Residual.	51
Figura 27 – Utilização de LPG para interrogação. (a) Faixa espectral de uma LPG que pode ser utilizada para interrogar um sensor FBG. (b) Interação entre os dois espectros.	52
Figura 28 – Comparativo do desempenho dos interrogadores. (a) Respostas à temperatura. (b) Residuais.	53
Figura 29 – Desempenho dos interrogadores em sistemas sujeitos a ruído com desvio padrão de 0,1 dB. (a) Respostas à temperatura. (b) Residuais.	54
Figura 30 – Desempenho dos interrogadores em sistemas sujeitos a ruído com desvio padrão de 0,5 dB. (a) Respostas à temperatura. (b) Residuais.	54
Figura 31 – Desempenho dos interrogadores em sistemas sujeitos a ruído com desvio padrão de 1 dB. (a) Respostas à temperatura. (b) Residuais.	54

LISTA DE TABELAS

Tabela 1 – Valores típicos para a sensibilidade de uma FBG à variação de temperatura.	20
Tabela 2 – Regras de funcionamento do sistema de inferência <i>fuzzy</i>	45
Tabela 3 – Ajustes polinomiais para a temperatura.	48
Tabela 4 – Desempenho das redes para diferentes números de neurônios na camada oculta.	50
Tabela 5 – Resumo do desempenho das técnicas de interrogação.	52
Tabela 6 – Desempenho das técnicas de interrogação em sistemas ruidosos.	53

LISTA DE ABREVIATURAS E SIGLAS

EDFA	<i>Erbium Doped Fiber Amplifier</i> - Amplificador de Fibra Dopada com Érbio
EQM	Erro Quadrático Médio
FBG	<i>Fiber Bragg Grating</i> - Grade de Bragg em Fibra
FIS	<i>Fuzzy Inference System</i> - Sistema de Inferência Fuzzy
FPGA	<i>Field Programmable Gate Array</i> - Arranjo de Portas Programável em Campo
FWHM	<i>Full Width at Half Maximum</i> - Largura em Meia Potência
LED	<i>Light Emitting Diode</i> - Diodo Emissor de Luz
LP	Linearmente Polarizado
LPG	<i>Long Period Grating</i> - Grade de Período Longo
MMQ	Método dos Mínimos Quadrados
OSA	<i>Optical Spectrum Analyzer</i> - Analisador de Espectro Óptico
RNA	Rede Neural Artificial
TE	Transversal Elétrico
TM	Transversal Magnético
WDM	<i>Wavelength Division Multiplexing</i> - Multiplexação por Divisão de Comprimento de Onda

LISTA DE SÍMBOLOS

\emptyset	Conjunto vazio
\cap	Interseção
\cup	União
\subseteq	Está contido ou é igual a
$\vec{0}$	Elemento neutro de um espaço vetorial
α	Coefficiente de expansão térmica
δ	Coefficiente termo-óptico
$\Delta\lambda_B$	Deslocamento no comprimento de onda de Bragg
ΔT	Variação de temperatura
λ_B	Comprimento de onda de Bragg
$\lambda_R^{(m)}$	Comprimento de onda central do vale de ressonância de ordem m em uma LPG
Λ	Período da grade
μ_A	Função de pertinência do conjunto <i>fuzzy</i> A
$\varphi(\cdot)$	Função de ativação
\bar{A}	Complemento do conjunto <i>fuzzy</i> A
c_r	Grau de ativação da regra <i>fuzzy</i> r
$\text{im}(A)$	Imagem da transformação linear A
$\text{ker}(A)$	Núcleo da transformação linear A
n_1	Índice de refração do núcleo
n_2	Índice de refração da casca
n_{eff}	Índice de refração efetivo
$\text{proj}_V \vec{b}$	Projeção ortogonal do vetor \vec{b} no subespaço vetorial V
V^\perp	Complemento ortogonal do subespaço vetorial V
\bar{x}	Coordenada x do centroide de uma área
$\ \vec{x}\ $	Norma do vetor \vec{x}

SUMÁRIO

1	INTRODUÇÃO	13
1.1	OBJETIVOS E CONTRIBUIÇÕES	13
1.2	PUBLICAÇÕES CORRELACIONADAS	14
1.3	REVISÃO BIBLIOGRÁFICA	14
1.4	ESTRUTURA DA DISSERTAÇÃO	15
2	FUNDAMENTAÇÃO TEÓRICA	16
2.1	SENSORES A FIBRA ÓPTICA	16
2.1.1	Modos de Propagação em Fibras Ópticas	16
2.1.2	Grades de Difração em Fibras Ópticas	18
2.1.2.1	Grades de Bragg em Fibra (FBG)	19
2.1.2.2	Grades de Período Longo (LPG)	21
2.2	MÉTODOS COMPUTACIONAIS	23
2.2.1	Método dos Mínimos Quadrados	23
2.2.1.1	Ajuste Polinomial Utilizando o MMQ	24
2.2.2	Sistemas de Inferência Fuzzy	25
2.2.3	Redes Neurais Artificiais	35
3	PROJETO DO INTERROGADOR	41
3.1	ESTÁGIO ÓPTICO	41
3.2	ESTÁGIO DE PROCESSAMENTO	43
3.2.1	Ajuste Polinomial pelo Método dos Mínimos Quadrados	44
3.2.2	Sistema de Inferência Fuzzy	45
3.2.3	Rede Neural Artificial	46
4	TESTES E RESULTADOS	48
4.1	TESTES DE DESEMPENHO	48
4.2	COMPARATIVO DAS TÉCNICAS DE INTERROGAÇÃO	52
4.3	DESEMPENHO EM SISTEMAS RUIDOSOS	53
5	CONCLUSÕES	55
5.1	TRABALHOS FUTUROS	55
	REFERÊNCIAS	56

1 INTRODUÇÃO

O uso de sensores a fibra óptica tem sido amplamente documentado nos últimos anos. As principais vantagens desse tipo de sensores são sua imunidade à interferência eletromagnética, baixo peso, pequeno tamanho, possibilidade de multiplexação de sensores e de sensoriamento remoto, além de serem inertes quimicamente [1]. Portanto, sensores a fibra óptica são convenientes para diversas aplicações em que dispositivos eletrônicos não são capazes de operar de modo satisfatório.

O dispositivo sensor escolhido para este trabalho foi a grade de Bragg em fibra (FBG - *Fiber Bragg Grating*). Uma FBG é um dispositivo óptico que atua como filtro, devido à reflexão de Bragg. Esse fenômeno causa uma reflexão em torno de um comprimento de onda de ressonância que depende de fatores construtivos da grade. Além disso, esse comprimento de onda ressonante é sensível a fatores externos, como a temperatura do ambiente e a tração mecânica aplicada na fibra. Dessa forma, é possível utilizar uma FBG como dispositivo sensor. O funcionamento de uma FBG é descrito em maiores detalhes no Item 2.1.2.1.

A resposta de sensores FBG normalmente é medida como um deslocamento no comprimento de onda do pico ressonante do espectro de reflexão. Para propósito de pesquisa, isso é feito utilizando-se um analisador de espectro óptico (OSA - *Optical Spectrum Analyzer*). Alternativamente, a interrogação pode ser feita utilizando-se interrogadores comercialmente disponíveis, baseados em escaneamento a *laser*, que podem ser automatizados e fornecem o valor processado do comprimento de onda de Bragg. Entretanto, em ambos os casos, o equipamento é relativamente grande e encarece altamente os custos de realizar o sensoriamento óptico. Por isso, aplicações práticas seriam grandemente beneficiadas por formas alternativas de interrogação óptica, especialmente com menores custos.

1.1 OBJETIVOS E CONTRIBUIÇÕES

Neste trabalho, o problema considerado é a interrogação de um sensor em fibra óptica. Para isso, por simplicidade, escolheu-se interrogar um sensor FBG de temperatura. No entanto, o sistema proposto aqui pode ser utilizado para qualquer outro tipo de medida, bastando, para isso, calibrá-lo adequadamente. O sistema de interrogação deve receber a informação do sensor, processá-la e retornar o valor estimado da temperatura detectada pelo sensor. Para isso, o sistema a ser desenvolvido deve ser composto de um estágio óptico e de um estágio de processamento. O estágio óptico é composto de filtros ópticos centrados em comprimentos de onda convenientes, de forma a possibilitar a identificação da resposta do sensor. O estágio de processamento é responsável por identificar a temperatura a partir das saídas dos filtros e retornar o valor da temperatura em graus Celsius. São propostas

três alternativas para o estágio de processamento: uma baseada em um ajuste polinomial obtido com o método dos mínimos quadrados, uma baseada em lógica *fuzzy* e uma baseada em redes neurais artificiais (RNAs), com foco nessa última.

Uma contribuição relevante deste trabalho é a agregação de algoritmos e técnicas computacionais modernas ao tratamento de sensores ópticos. As técnicas alternativas disponíveis, baseadas em filtragem e ajuste de curvas convencional, são insuficientemente precisas, especialmente em sistemas ruidosos. O tratamento de incertezas nos valores juntamente com a necessidade de generalizar conhecimento a partir de um conjunto de dados limitado motivaram o uso de técnicas inteligentes, algoritmos modernos como um sistema de inferência *fuzzy* (FIS - *Fuzzy Inference System*) ou uma RNA.

1.2 PUBLICAÇÕES CORRELACIONADAS

- **JUCÁ, Marco A.**; SANTOS, A. B. “Fiber Bragg Grating Interrogation Using FBG Filters and Artificial Neural Network”. In: *International Microwave and Optoelectronics Conference (IMOC)*, Águas de Lindoia. IMOC 2017.
- DELGADO, Felipe S.; **JUCÁ, Marco A.**; COELHO, Thiago V. N.; DOS SANTOS, Alexandre B; BARBERO, Andres P. L.; SILVA, Vinicius N. H. “Propagation Characteristics of Optical Long Period Fiber Gratings using Graphical Solution Methods”. *Journal of Microwaves, Optoelectronics and Electromagnetic Applications*, v. 15, p. 135-145, 2016.
- DELGADO, Felipe S.; **JUCÁ, Marco A.**; MARCATO, André L. M.; DOS SANTOS A. Bessa. “Optical Fiber-based Sensor for Assessing Electric Current in Unmanned Aerial Vehicles with ROS Interface”. In: *International Conference on Robotics and Automation (ICRA)*, Brisbane. ICRA 2018.

1.3 REVISÃO BIBLIOGRÁFICA

Métodos alternativos de interrogação utilizando FBGs como filtros são discutidos em [5] e [6]. Os autores mostram que, utilizando os filtros em FBG, são alcançadas uma melhor resolução espectral e uma redução de custos. Mais recentemente, outros sistemas de interrogação foram desenvolvidos utilizando filtros baseados em fibras multimodo [7], porém, a faixa dinâmica e a resolução desse sistema de interrogação são limitadas pelo regime linear da resposta do filtro. Um sistema de interrogação utilizando FBGs foi proposto para interrogar um sensor baseado em ressonância de plasmon de superfície [8]. Foi reportado o uso de FBGs como filtros interferométricos na interrogação de sensores FBG, codificando a informação do sensor na diferença de fase entre os dois ramos e lendo essa informação através de um osciloscópio [9].

Métodos computacionais inteligentes já apareceram associados a sensores ópticos nos últimos anos. O uso da lógica *fuzzy* em conjunto com sensores FBG foi reportado em [10]. Foi relatado o uso da lógica *fuzzy* em um sensor óptico para detecção de defeitos em processos de soldagem [11]. As aplicações de uma RNA como um classificador foram discutidas em [12], em que os autores utilizam RNAs associadas à análise de componentes principais para interpretar espectros ópticos complexos e sinais no domínio do tempo em diferentes aplicações. Em [13], demonstra-se o uso de uma RNA para classificar o estado de dano em estruturas de polímeros de fibra de carbono reforçados. Foi demonstrado que RNAs podem ser utilizadas em conjunto com sensores ópticos para identificar de forma eficaz a concentração de etanol em amostras de combustíveis e ainda realizar fusão de dados [14]. Foi demonstrado que uma RNA é capaz de interpretar espectros complexos oriundos de medições de deformação em polímeros utilizados na construção de aeronaves [15].

1.4 ESTRUTURA DA DISSERTAÇÃO

Além desta introdução, esta dissertação possui outros quatro capítulos.

No Capítulo 2, são expostos os fundamentos teóricos das tecnologias e das metodologias utilizadas neste trabalho. A principal tecnologia abordada é a de sensores baseados em grades de difração em fibras ópticas. Estas grades podem ser de dois tipos: grades de Bragg em fibra e grades de período longo. As metodologias para a interrogação do sensor são: aproximação polinomial pelo método dos mínimos quadrados, sistema de inferência *fuzzy* e redes neurais artificiais.

No Capítulo 3, é descrito o projeto do interrogador desenvolvido. Esse capítulo aborda a topologia do estágio óptico, além do desenvolvimento das três alternativas propostas para o estágio de processamento.

O Capítulo 4 exhibe os experimentos feitos para validação do sistema de interrogação. Inicialmente, foram feitos testes em simulação computacional, com o objetivo de estimar o desempenho das três alternativas. Um método mais tradicional de interrogação foi utilizado para fornecer uma comparação com os métodos propostos. Por fim, foi feita uma análise considerando-se a presença de ruído no sistema.

Finalmente, o Capítulo 5 discute as principais conclusões obtidas deste trabalho e aborda propostas para a evolução desta pesquisa no futuro.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, é exposto o arcabouço teórico que fundamentou o desenvolvimento do presente trabalho. A Seção 2.1 trata das tecnologias envolvidas no estudo dos sensores a fibras ópticas. O estudo desenvolvido depende essencialmente do entendimento dos modos de propagação da luz em fibras ópticas e de suas origens no Eletromagnetismo. Esses tópicos são abordados na Subseção 2.1.1.

Em particular, grades de difração são dispositivos ópticos que alteram a propagação da luz nas fibras, através do acoplamento de energia entre diferentes modos de propagação. Tais grades podem ser utilizadas tanto em comunicações ópticas como em sensores ópticos. A Subseção 2.1.2 explora esse assunto, focando no estudo de sensores ópticos baseados em grades de Bragg (FBG, Item 2.1.2.1) e em grades de período longo (LPG, Item 2.1.2.2).

A Seção 2.2 expõe as metodologias utilizadas para buscar uma resposta ao problema da interrogação de um sensor óptico: como saber o valor da medição a partir da resposta óptica do sensor. Foram estudadas três alternativas: aproximação polinomial com coeficientes calculados através do método dos mínimos quadrados (Subseção 2.2.1), sistema de inferência *fuzzy* (Subseção 2.2.2) e rede neural artificial (Subseção 2.2.3).

2.1 SENSORES A FIBRA ÓPTICA

2.1.1 Modos de Propagação em Fibras Ópticas

Para um melhor entendimento da propagação da luz em fibras ópticas, é necessário estudar a solução das equações de Maxwell sujeitas às condições de contorno cilíndricas na interface entre o núcleo e a casca da fibra [16]. O tratamento matemático dessas equações pode ser encontrado em textos específicos [17–23]. A solução das equações de Maxwell dá origem ao conceito de modos de propagação, que são um conjunto de padrões de ondas eletromagnéticas ou distribuições de campo que são capazes de propagar-se na fibra [24].

Ao solucionar as equações de Maxwell, são encontrados dois tipos de modos de propagação: modos TE (transversal elétrico) e modos TM (transversal magnético). Ao contrário das ondas no espaço livre, as ondas confinadas podem ter componentes de campo na direção de propagação. Se um modo admitir componentes de campo magnético na direção de propagação e as componentes de campo elétrico forem perpendiculares a essa direção, diz-se que o modo é TE. Analogamente, se um modo admitir componentes de campo elétrico na direção de propagação e as componentes de campo magnético forem perpendiculares a essa direção, diz-se que o modo é TM.

Entretanto, devido às condições de contorno na interface núcleo-casca, existe um acoplamento entre as componentes de campo elétrico e magnético [16]. Isso dá origem aos modos chamados de híbridos, nos quais existem componentes tanto de campo elétrico

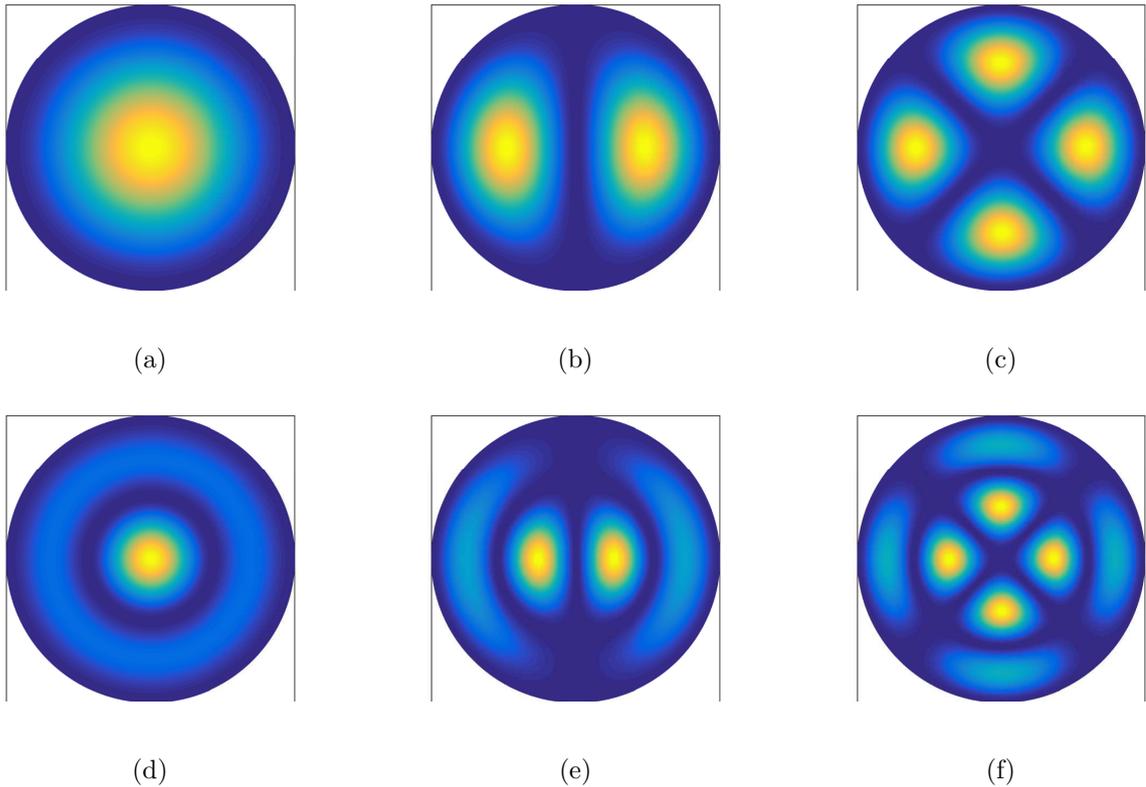


Figura 1 – Distribuição de energia em alguns modos LP. (a) LP_{01} . (b) LP_{11} . (c) LP_{21} . (d) LP_{02} . (e) LP_{12} . (f) LP_{22} .

quanto de campo magnético na direção de propagação. Os modos híbridos são denominados HE ou EH, a depender de qual for a componente de campo predominante na direção de propagação.

Os modos híbridos HE e EH possuem, portanto, seis componentes de campo a serem consideradas. No entanto, no caso específico das fibras ópticas, o fato de o índice de refração da casca ser muito próximo do índice de refração do núcleo significa que as componentes de campo na direção de propagação são muito pequenas, se comparadas às componentes transversais, e, ao serem desprezadas, levam a uma aproximação conveniente da distribuição de campo e uma simplificação significativa das expressões matemáticas. Essa aproximação é conhecida como guiamento fraco e os modos resultantes dessas equações são conhecidos como modos linearmente polarizados (LP). A modelagem matemática pertinente pode ser encontrada em textos básicos sobre o assunto [25–28]. A Figura 1 ilustra a distribuição de energia na seção reta de uma fibra para alguns modos LP. Na figura, áreas mais claras representam regiões de maior concentração de energia.

Em uma fibra monomodo comum, o modo fundamental do núcleo é descrito por HE_{11} , que corresponde ao modo LP_{01} ao utilizar-se a aproximação de guiamento fraco. Esse modo pode ser encontrado resolvendo-se (1) [29]. Esta equação é transcendental e, por isso, normalmente é resolvida graficamente ou numericamente. A solução dará o índice

efetivo para o modo fundamental de núcleo LP₀₁.

$$V\sqrt{1-b}\frac{J_1(V\sqrt{1-b})}{J_0(V\sqrt{1-b})} = V\sqrt{b}\frac{K_1(V\sqrt{b})}{K_0(V\sqrt{b})} \quad (1)$$

Em (1), as grandezas V e b são a frequência normalizada e a constante de propagação normalizada, definidas como em (2) e (3) [29].

$$V = \frac{2\pi r_1}{\lambda} \sqrt{n_1^2 - n_2^2} \quad (2)$$

$$b = \frac{n_{\text{eff}}^2 - n_2^2}{n_1^2 - n_2^2} \quad (3)$$

Nas equações acima, J_i é a função de Bessel da primeira espécie e ordem i , K_i é a função de Bessel modificada da segunda espécie e ordem i , r_1 é o raio do núcleo, λ é o comprimento de onda de operação e n_1 , n_2 e n_{eff} são os índices de refração do núcleo, da casca e efetivo, respectivamente [29].

2.1.2 Grades de Difração em Fibras Ópticas

Os dispositivos ópticos no foco deste trabalho são as grades de difração em fibras ópticas. Uma grade é uma perturbação, geralmente periódica, no índice de refração no interior do núcleo da fibra. A luz que passa por essa grade é parcialmente acoplada para diferentes modos de propagação, a depender do tipo de grade. Os dois tipos básicos de grades de difração em fibras ópticas são a grade de Bragg em fibra (FBG - *Fiber Bragg Grating*) e a grade de período longo (LPG - *Long Period Grating*). A diferença fundamental entre os dois tipos é o período da perturbação no índice, o que incorre em particularidades de cada tipo de grade que serão exploradas nos Itens 2.1.2.1 e 2.1.2.2.

As grades possuem diversas aplicações, como filtros para sinais multiplexados por divisão em comprimento de onda (WDM - *Wavelength Division Multiplexing*), equalizadores de ganho para amplificadores de fibra dopada com érbio (EDFA - *Erbium Doped Fiber Amplifier*), compensadores de dispersão, entre outros [29–31]. No entanto, o foco deste trabalho é tratá-las como sensores.

Os sensores baseados em grades de difração em fibras ópticas apresentam muitas vantagens em relação a sensores eletrônicos e outros tipos de sensores em fibra. Sua produção não é cara, são simples, imunes à interferência eletromagnética, leves, pequenos e possuem uma resposta linear, em geral. Além disso, como codificam a informação medida em termos de comprimento de onda, apresentam a possibilidade da multiplexação de dezenas de sensores na mesma fibra. [29]

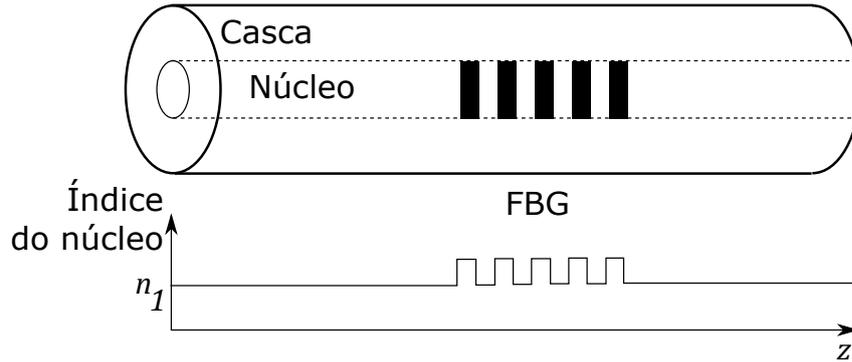


Figura 2 – Estrutura de uma grade de Bragg.

2.1.2.1 Grades de Bragg em Fibra (FBG)

Uma FBG é um dispositivo óptico que atua como filtro, devido à reflexão de Bragg, cujo comprimento de onda central varia com fatores externos. Existem diversos métodos de fabricação de FBGs. Uma das formas é expor uma fibra óptica a um padrão periódico de luz ultravioleta. Como resultado, as grades (ou redes) são regiões com índices de refração alternadamente altos e baixos no interior do núcleo da fibra, conforme a Figura 2. A grade periódica atua como filtro, refletindo uma faixa estreita de comprimentos de onda. Isso ocorre devido ao acoplamento parcial da energia do modo propagante para um modo contrapropagante, promovido pela grade na condição de casamento de fase [32]. O comprimento de onda do pico de reflexão é conhecido como comprimento de onda de Bragg, λ_B , e é dado por (4), em que n_{eff} é o índice de refração efetivo e Λ é o período da grade [33].

$$\lambda_B = 2n_{\text{eff}}\Lambda \quad (4)$$

A Figura 3 ilustra o funcionamento de uma FBG ao receber a incidência de luz de espectro largo, mostrando o pico de reflexão centrado no comprimento de onda de Bragg e o espectro transmitido. Dessa forma, uma FBG pode ser entendida como um filtro passa-faixa ao escolher-se a luz refletida como saída. Por outro lado, a mesma FBG pode ser entendida como um filtro rejeita-faixa, desde que se escolha a luz transmitida como saída do filtro. A largura em meia potência (FWHM - *Full Width at Half Maximum*) do pico de reflexão varia, tipicamente, entre 0,1 e 1 nm [1].

As FBGs são sensíveis à temperatura devido ao efeito da expansão térmica na grade, que modifica o período da rede Λ , e também devido ao efeito termo-óptico, que modifica o valor do índice de refração n_{eff} . Portanto, uma FBG sujeita à variação de temperatura ΔT exibe um deslocamento no comprimento de onda do seu pico de ressonância, que pode ser descrito por (5) [1]. Esta equação admite que a tensão mecânica no sensor é constante,

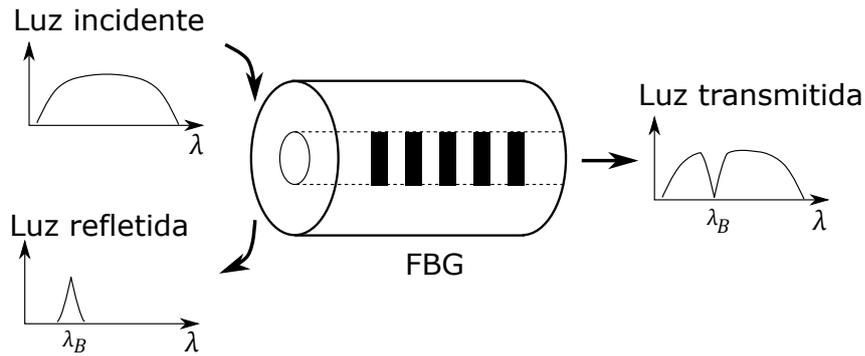


Figura 3 – Espectros resultantes do funcionamento de uma FBG.

já que as FBGs são analogamente sensíveis à deformação.

$$\Delta\lambda_B = \lambda_B (\alpha + \delta) \Delta T \quad (5)$$

Em (5), α é o coeficiente de expansão térmica, definido em (6), e δ é o coeficiente termo-óptico, definido em (7) [1].

$$\alpha = \frac{1}{\Lambda} \left(\frac{\partial \Lambda}{\partial T} \right) \quad (6)$$

$$\delta = \frac{1}{n_{\text{eff}}} \left(\frac{\partial n_{\text{eff}}}{\partial T} \right) \quad (7)$$

Os coeficientes α e δ possuem valores típicos para fibras monomodo padrão, fazendo com que a sensibilidade da FBG à temperatura também tenha valores típicos, conforme mostra a Tabela 1 [1]. É importante notar que o valor da sensibilidade, para dado comprimento de onda de operação, é constante, isto é, a resposta da FBG à variação de temperatura é linear.

Tabela 1 – Valores típicos para a sensibilidade de uma FBG à variação de temperatura.

Comprimento de Onda [nm]	Sensibilidade [pm/°C]
830	6,8
1300	10
1550	13

Sensores de temperatura baseados em FBGs comuns podem funcionar bem até aproximadamente 300 °C. FBGs especiais, fabricadas com *lasers* de femtosegundo ou com uma composição de dopantes diferenciada no núcleo, podem chegar a operar acima dos 1000 °C. No outro extremo, FBGs comuns podem operar em temperatura tão baixas quanto 80 K (≈ -193 °C) [1].

Sensores FBG têm sido utilizados em uma variedade de aplicações, como sensores de índice de refração [34], de pressão [35], de vibração [36], de campo magnético [37]. Nos últimos anos, o uso de sensores FBG foi reportado em sensoriamento de umidade [38, 39], detecção de torque em eixos giratórios [40], sensoriamento de aceleração [41], imageamento ultrassônico de modelos físicos sísmicos [42] e muitos outros.

2.1.2.2 Grades de Período Longo (LPG)

LPGs são grades que acoplam energia do modo propagante para modos de casca copropagantes [43]. Através das equações de Maxwell e da Teoria de Modos Acoplados, sabe-se que o acoplamento entre modos ocorre se as constantes de propagação dos modos forem iguais ($\beta_1 = \beta_2$), ou se forem acopladas pela condição descrita em (8), em que N é a ordem da grade. Na maioria dos casos, a difração de primeira ordem é dominante e, portanto, N é suposto unitário [29].

$$\frac{2\pi N}{\Lambda} = \beta_1 - \beta_2 \quad (8)$$

Nas grades de Bragg convencionais, o modo fundamental propagante é acoplado ao modo fundamental contrapropagante e $\beta_2 = -\beta_1$, o que leva a uma diferença grande entre as constantes de propagação, implicando um período da grade pequeno. As LPGs apresentam períodos centenas de vezes maiores que as FBGs, portanto a condição de casamento de fase não é atingida para modos contrapropagantes, e sim para modos de casca copropagantes discretos e circularmente simétricos. [44–47]

Os modos de casca decaem rapidamente devido a perdas por espalhamento na interface casca-ar e curvaturas na fibra. Como o acoplamento é seletivo em comprimento de onda, a grade atua como elemento de perda dependente do comprimento de onda. Dessa forma, as LPGs podem ser entendidas como filtros rejeita-faixa, com largura de faixa tipicamente muito maior do que uma FBG. [44]

A Figura 4 mostra o efeito de uma LPG no espectro da luz transmitida. Ao receber a incidência de luz de espectro largo, a LPG acopla parte dessa luz para alguns modos de casca, que satisfazem a condição de casamento de fase. Devido à alta perda desses modos, o espectro da luz transmitida através da LPG possui vales de atenuação, centrados em comprimentos de onda $\lambda_R^{(m)}$ correspondentes aos respectivos modos, de acordo com (9), em função dos índices efetivos do núcleo, $n_{\text{eff,co}}$, e da casca, $n_{\text{eff,cl}}$ [48]. A modelagem matemática desse dispositivo foi apresentada em [49] e desde então foi revista várias vezes [3, 50–54]. A Figura 5, criada utilizando-se o *software* OptiGrating, mostra em maior detalhe a característica de transmissão de luz por uma LPG. Nessa figura, é possível ver bandas de atenuação associadas a diversos modos de casca copropagantes.

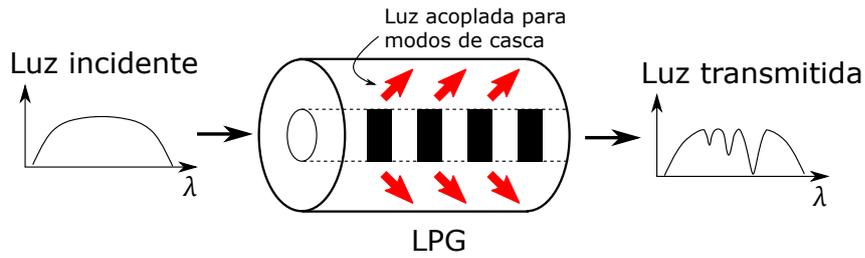


Figura 4 – Espectro resultante do funcionamento de uma LPG.

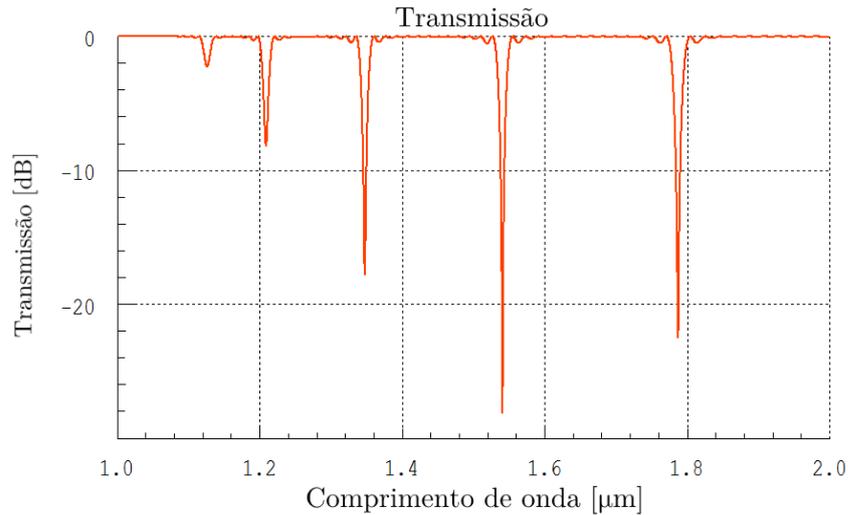


Figura 5 – Característica espectral de transmissão de luz por uma LPG.

$$\lambda_R^{(m)} = \left(n_{\text{eff,co}}^{(01)} - n_{\text{eff,cl}}^{(m)} \right) \Lambda \quad (9)$$

O formato e os comprimentos de onda centrais das bandas de atenuação são sensíveis ao período da LPG, ao seu comprimento e a grandezas relacionadas ao ambiente em que a fibra está inserida: temperatura, tração, curvatura e índice de refração do meio [31]. Assim como na FBG, essas grandezas externas influenciam no período da grade e nos índices de refração efetivos. Conseqüentemente, as condições de casamento de fase para acoplamento dos modos são alteradas, resultando em um deslocamento nos comprimentos de onda centrais das bandas de atenuação [31].

As LPGs vêm sendo utilizadas desde o seu princípio como equalizadores de ganho para amplificadores de fibra dopada com érbio (EDFA) [55]. Como sensores, podem ser utilizadas para medir o índice de refração do meio externo [56, 57], torção axial [58], turbidez [59] e salinidade [60] de água, concentração de gases como metano [61] e dióxido de carbono [62], além dos mais típicos: temperatura e deformação. Foram demonstrados esquemas de medição simultânea de temperatura e deformação (e, opcionalmente, índice de refração) utilizando apenas uma LPG [63, 64].

2.2 MÉTODOS COMPUTACIONAIS

2.2.1 Método dos Mínimos Quadrados

O método dos mínimos quadrados (MMQ) é uma forma de ajustar uma equação a dados experimentais. A origem do método está relacionada ao cálculo de órbitas de corpos celestes, porém sua autoria é controversa. Há registros de que Gauss teria desenvolvido o método aproximadamente em 1795, mas a primeira vez que foi apresentado clara e publicamente foi em 1805, numa publicação de Legendre [65, 66]. A seguir, será apresentada a fundamentação matemática do método, que será baseada em [67], uma abordagem matricial¹ com base na Álgebra Linear.

Seja um sistema linear $A\vec{x} = \vec{b}$, sendo A uma matriz $n \times m$. Caso o sistema seja consistente, isso significa que $\vec{b} \in \text{im}(A)$ e o sistema tem pelo menos uma solução exata. Se, no entanto, o sistema for inconsistente, então $\vec{b} \notin \text{im}(A)$ e é impossível que a transformação linear A aplicada a qualquer vetor \vec{x} gere o vetor \vec{b} . Porém, pode-se solucionar o problema de forma aproximada, buscando-se o vetor \vec{x}^* tal que $A\vec{x}^*$ seja o mais próximo possível a \vec{b} . Ou seja, busca-se minimizar a norma do erro $\|\vec{b} - A\vec{x}\|$. O vetor \vec{x}^* que minimiza esse erro é chamado de solução de mínimos quadrados do sistema. Nessas condições, as seguintes afirmações são equivalentes:

O vetor \vec{x}^* é uma solução de mínimos quadrados do sistema $A\vec{x} = \vec{b}$.

$$\begin{aligned}
 & \Downarrow \\
 & \|\vec{b} - A\vec{x}^*\| \leq \|\vec{b} - A\vec{x}\| \quad \forall \vec{x} \in \mathbb{R}^m. \\
 & \Downarrow \\
 & A\vec{x}^* = \text{proj}_V \vec{b}, \quad \text{em que } V = \text{im}(A). \\
 & \Downarrow \\
 & \vec{b} - A\vec{x}^* \in V^\perp = (\text{im}A)^\perp = \ker(A^T). \\
 & \Downarrow \\
 & A^T(\vec{b} - A\vec{x}^*) = \vec{0}. \\
 & \Downarrow \\
 & A^T A\vec{x}^* = A^T \vec{b}
 \end{aligned}$$

Consequentemente, se a matriz $A^T A$ for inversível pode-se encontrar uma expressão fechada para o vetor \vec{x}^* , conforme (10).

$$\vec{x}^* = (A^T A)^{-1} A^T \vec{b} \tag{10}$$

¹ A abordagem matricial é particularmente conveniente para implementação no *software* Matlab. O mesmo resultado pode ser deduzido utilizando-se somatórios [68], abordagem mais comum em Estatística.

2.2.1.1 Ajuste Polinomial Utilizando o MMQ

Sejam as n observações $(a_1, b_1), \dots, (a_n, b_n)$ de um processo com saídas b_i respectivas às entradas a_i , $i = 1, \dots, n$, às quais se deseja ajustar uma função polinomial $b \approx f(a) = c_0 + c_1a + \dots + c_{m-1}a^{m-1}$. Para isso, busca-se determinar os valores dos coeficientes c_j , $j = 0, \dots, m-1$, que tornam $f(a)$ o mais próximo possível de b . O sistema de equações respectivo pode ser escrito conforme (11a). Nota-se que o sistema é linear em relação aos coeficientes a determinar, portanto, pode ser descrito, equivalentemente, na forma matricial, conforme (11b).

$$\begin{cases} f(a_1) = b_1 \\ \vdots \\ f(a_n) = b_n \end{cases} \equiv \begin{cases} c_0 + c_1a_1 + \dots + c_{m-1}a_1^{m-1} = b_1 \\ \vdots \\ c_0 + c_1a_n + \dots + c_{m-1}a_n^{m-1} = b_n \end{cases} \quad (11a)$$

$$\begin{bmatrix} 1 & a_1 & \dots & a_1^{m-1} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & a_n & \dots & a_n^{m-1} \end{bmatrix}_{n \times m} \begin{bmatrix} c_0 \\ \vdots \\ c_{m-1} \end{bmatrix}_{m \times 1} = \begin{bmatrix} b_1 \\ \vdots \\ b_n \end{bmatrix}_{n \times 1} \quad (11b)$$

A Eq. (11b) já se encontra no formato $A\vec{x} = \vec{b}$ para resolução através do MMQ. Assim, a matriz A será dada pelos valores observados da variável independente, elevados a expoentes convenientes, de acordo com a função f . O vetor \vec{b} será formado pelos valores observados da variável dependente. O vetor formado pelos parâmetros da função será a incógnita \vec{x} , sendo que os valores dos parâmetros que minimizam a norma do erro $\|\vec{b} - A\vec{x}\|$ serão dados por (10).

Nota-se que o método é igualmente capaz de lidar com funções de várias variáveis. Como exemplo, considera-se o ajuste de uma função polinomial de grau 1 de duas variáveis $b \approx f(a, d) = c_0 + c_1a + c_2d$ aos valores de n observações. O sistema a resolver-se será dado por (12a) e, na forma matricial, por (12b).

$$\begin{cases} f(a_1, d_1) = b_1 \\ \vdots \\ f(a_n, d_n) = b_n \end{cases} \equiv \begin{cases} c_0 + c_1a_1 + c_2d_1 = b_1 \\ \vdots \\ c_0 + c_1a_n + c_2d_n = b_n \end{cases} \quad (12a)$$

$$\begin{bmatrix} 1 & a_1 & d_1 \\ \vdots & \vdots & \vdots \\ 1 & a_n & d_n \end{bmatrix}_{n \times 3} \begin{bmatrix} c_0 \\ c_1 \\ c_2 \end{bmatrix}_{3 \times 1} = \begin{bmatrix} b_1 \\ \vdots \\ b_n \end{bmatrix}_{n \times 1} \quad (12b)$$

Assim, a Eq. (12b) pode ser resolvida utilizando-se (10), da mesma forma que para funções de uma variável. Esse é apenas um exemplo da aplicação do método para uma função multivariada simples. A mesma metodologia pode ser seguida para ajustar funções

mais complexas, de maior grau e com termos contendo multiplicação cruzada de variáveis independentes.

2.2.2 Sistemas de Inferência Fuzzy

Uma importante mudança de paradigma no campo das ciências e da matemática ocorrida no último século diz respeito à incerteza. Tradicionalmente, a incerteza era vista pela ciência como indesejável, não científica, devendo ser evitada a qualquer custo. Uma visão alternativa, mais recente, considera a incerteza essencial à ciência: além de ser inevitável, a incerteza pode ser muito útil, desde que se conheçam suas propriedades e se saiba lidar com seus efeitos. Em geral, tolerar um certo grau de incerteza tende a reduzir a complexidade de um modelo e, além disso, aumentar a sua credibilidade. [69]

Na teoria clássica de conjuntos (aristotélica, booleana), quando se analisa a relação de pertinência entre um elemento e um conjunto, existem duas possibilidades: (I) o elemento pertence ao conjunto ou (II) o elemento não pertence ao conjunto. Assim, considerando um conjunto A e um elemento x , uma proposição do tipo $x \in A$ pode assumir um dos dois valores lógicos: *verdadeiro* ou *falso*. Nesse caso, A é classificado como um conjunto *crisp* e x , como um valor *crisp* (em que o termo “*crisp*” indica nitidez, ausência de incerteza, em contraposição ao termo *fuzzy*, que indica nebulosidade). Entretanto, em muitas situações, os seres humanos raciocinam com uma arquitetura lógica distinta dessa lógica binária aristotélica.

Quando se considera a temperatura em uma sala, por exemplo. Podem-se separar as temperaturas em três conjuntos: fria, confortável e quente. A maioria das pessoas consideraria 23°C uma temperatura confortável, 30°C uma temperatura quente e 15°C, fria. Porém, 19°C estaria entre os conjuntos “confortável” e “fria”, sem pertencer exclusivamente a nenhum. Da mesma forma, 26°C estaria entre “confortável” e “quente”. Nesses casos, no pensamento humano, a pertinência a um conjunto não é simplesmente uma questão de pertencer ou não pertencer; existe uma gradualidade. Dessa maneira, existe a necessidade de representar o grau de pertinência de um elemento com relação a um conjunto, com valores intermediários entre 0 e 100%. Além disso, um elemento pode pertencer a mais de um conjunto, com um grau de pertinência específico para cada um.

Em 1965, Lotfi A. Zadeh publicou um artigo introduzindo a noção de conjuntos *fuzzy* [70], termo traduzido para o português como “difuso” ou “nebuloso”, dando origem a um novo tipo de lógica, que apresenta uma quebra na dicotomia das relações de pertinência [71]. Através do conceito de conjuntos *fuzzy*, a relação entre um elemento e um conjunto passa a ser definida por um grau de pertinência, ou seja, o grau com que o elemento pertence ao conjunto. Esse grau é comumente expresso como um valor real no intervalo unitário $[0, 1]$, em que o grau 0 indica a negação total da pertinência e o grau 1 indica a pertinência total [69]. Valores intermediários mais altos indicam que a relação

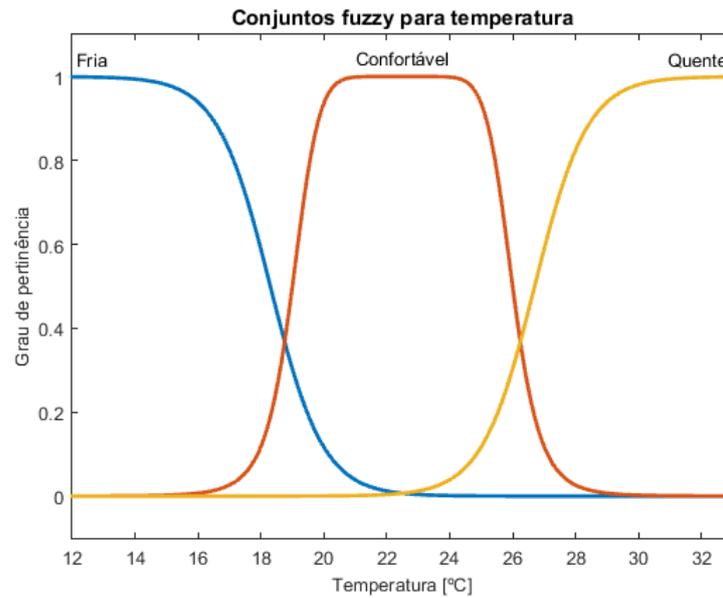


Figura 6 – Conjuntos fuzzy para temperatura interna de uma sala.

do elemento com o conjunto é mais forte, enquanto valores baixos indicam uma relação distante.

Sendo assim, a função de pertinência μ_A , referente a um conjunto *fuzzy* A (também chamado de grupo *fuzzy*), relaciona os elementos de um domínio *crisp* X (comumente chamado de universo de discurso) a um valor real no intervalo $[0, 1]$, que representa o grau com que cada elemento de X pertence a A , conforme a definição em (13) [69].

$$\mu_A : X \rightarrow [0, 1] \quad (13)$$

A abordagem de conjuntos *fuzzy* se adéqua bem à situação anterior. A Figura 6 representa três conjuntos *fuzzy* associados à temperatura interna de uma sala. As curvas, na figura, representam as funções de pertinência. Cada valor de temperatura está associado aos três conjuntos pelas respectivas funções de pertinência. Nota-se que alguns valores pertencem a um conjunto com alto grau de pertinência; outros pertencem a dois conjuntos com graus de pertinência mais baixos.

Utilizando a representação dos conjuntos *fuzzy*, é possível utilizar uma lógica diferente da Aristotélica (binária), mais parecida com o pensamento humano, chamada de lógica *Fuzzy*. Para representar as relações de negação, conjunção, disjunção e implicação na lógica *fuzzy*, são necessárias expressões que considerem as funções de pertinência dos conjuntos. As expressões mais comuns são dadas em (14) [72].

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x) \quad (14a)$$

$$\mu_{A_1 \cap A_2}(x) = \min [\mu_{A_1}(x), \mu_{A_2}(x)] \quad (14b)$$

$$\mu_{A_1 \cup A_2}(x) = \max [\mu_{A_1}(x), \mu_{A_2}(x)] \quad (14c)$$

$$\mu_{A \rightarrow B}(x, y) = \max [1 - \mu_A(x), \mu_B(y)] \quad (14d)$$

Além disso, é possível definir um produto cartesiano entre conjuntos *fuzzy*, em que cada par (x, y) está associado à função de pertinência dada por (15) [72].

$$\mu_{A \times B} = \min (\mu_A(x), \mu_B(y)) \quad (15)$$

Outra definição importante para conjuntos *fuzzy* é a de conjunto suporte. O conjunto suporte S de um conjunto *fuzzy* A é um conjunto *crisp* cujos elementos são todos os elementos do universo de discurso X de A que possuem valor não nulo quando aplicados à função de pertinência μ_A , conforme indicado em (16).

$$S(A) = \{x \in X \mid \mu_A(x) > 0\} \quad (16)$$

Quanto às relações entre conjuntos *fuzzy*, as propriedades válidas para conjuntos *crisp* são mantidas, conforme listado a seguir [72]. Na lista, A , B e C são conjuntos *fuzzy*, X é o universo de discurso e \emptyset é o conjunto vazio.

- Comutatividade:

$$A \cup B = B \cup A \quad (17a)$$

$$A \cap B = B \cap A \quad (17b)$$

- Associatividade:

$$A \cup (B \cup C) = (A \cup B) \cup C \quad (18a)$$

$$A \cap (B \cap C) = (A \cap B) \cap C \quad (18b)$$

- Distributividade:

$$A \cup (B \cap C) = (A \cup B) \cap (A \cup C) \quad (19a)$$

$$A \cap (B \cup C) = (A \cap B) \cup (A \cap C) \quad (19b)$$

- Idempotência:

$$A \cup A = A \quad (20a)$$

$$A \cap A = A \quad (20b)$$

- Identidade:

$$A \cup \emptyset = A \quad (21a)$$

$$A \cap X = A \quad (21b)$$

$$A \cap \emptyset = \emptyset \quad (21c)$$

$$A \cup X = X \quad (21d)$$

- Transitividade:

$$\text{Se } A \subseteq B \text{ e } B \subseteq C, \text{ então } A \subseteq C \quad (22)$$

- Involução:

$$\overline{\overline{A}} = A \quad (23)$$

- Princípios de De Morgan:

$$\overline{A \cap B} = \overline{A} \cup \overline{B} \quad (24a)$$

$$\overline{A \cup B} = \overline{A} \cap \overline{B} \quad (24b)$$

A lógica *fuzzy* é capaz de lidar com sistemas altamente não-lineares ou complexos com relativa facilidade, gerando modelos e controladores baseados em variáveis linguísticas. O modelo ou controlador *fuzzy* é comumente chamado de sistema de inferência *fuzzy* (FIS - *Fuzzy Inference System*). Essas generalizações separam variáveis de entrada e de saída em conjuntos *fuzzy*, em que suas relações se dão por uma série de regras do tipo **se-então**.

Por definição, variáveis são identificadores que podem assumir mais de um valor em determinado contexto. Usualmente são representadas por meio de símbolos. Variáveis linguísticas, no contexto da lógica *fuzzy*, são variáveis que podem assumir mais de um termo linguístico. Esses termos linguísticos carregam em si noções de quantificação, intensificação, aumento ou decréscimo, dentre outros, como por exemplo: “baixo”, “alto”, “médio”, “extremamente”, “muito forte”, “fraco”, “positivo”, “neutro”, “negativo”, dentre outros. Com esses termos não-numéricos é possível realizar operações e extrair conclusões numéricas por meio das operações *fuzzy*.

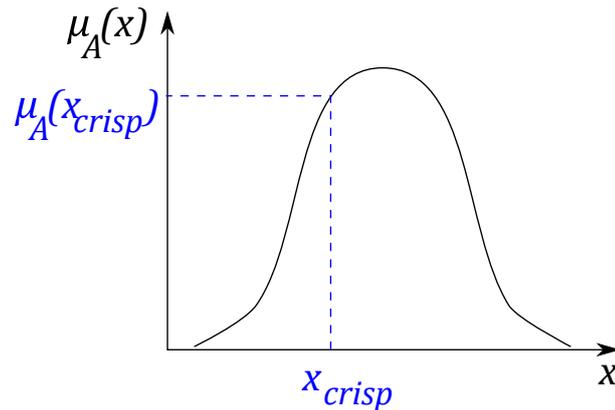


Figura 7 – Exemplo de fuzzificação.

Existem diferentes abordagens em relação aos métodos de inferência na lógica *fuzzy*. As mais comuns são as arquiteturas tipo Takagi-Sugeno e Mamdani. A inferência Takagi-Sugeno calcula as variáveis de saída ponderando funções das variáveis de entrada, cujos pesos são mais ou menos ativados a depender das regras. Já a inferência Mamdani utiliza a área sob as curvas de pertinência para calcular as variáveis de saída. Essas curvas tomam a forma de figuras geométricas para representar os conjuntos, como triângulos, trapézios, gaussianas, dentre outros. O sistema de inferência *fuzzy* utilizado neste trabalho foi do tipo Mamdani. Seu funcionamento é descrito com mais detalhes abaixo.

Em uma abordagem *fuzzy*, seja um controlador ou um modelo de um processo ou sistema, informações úteis chegam por meio de sensores ou operadores humanos. Essas informações são usualmente numéricas e serão as variáveis de entrada do sistema *fuzzy*. No entanto, a lógica *fuzzy* não processa valores numéricos, e sim linguísticos. Portanto, primeiramente, as entradas do controlador deverão ser fuzzificadas, deixando de ser valores numéricos (*crisp*) para tornarem-se valores *fuzzy*. Essa fase, chamada de fuzzificação, classificará os valores *crisp* nos conjuntos *fuzzy* do sistema, e produzirá um valor *fuzzy*, que dependerá dos conjuntos a que o valor *crisp* pertence e com quais graus de pertinência. Matematicamente, a fuzzificação consiste em aplicar-se o valor *crisp* da entrada, x_{crisp} , nas funções de pertinência respectivas. Considerando-se um conjunto *fuzzy* A , o objetivo é encontrar $\mu_A(x_{crisp})$, conforme expresso em (25) e ilustrado na Figura 7.

$$\mu_A(x_{crisp}) = \mu_A(x) |_{x=x_{crisp}} \quad (25)$$

Em seguida, são aplicadas as regras elaboradas que definem o comportamento desejado para o controlador ou modelo do sistema. Em um modelo de sistema *fuzzy*, cada regra define quais devem ser os valores das variáveis de saída para uma situação específica das variáveis de entrada. As regras são a ligação entre os conjuntos de entrada e de saída. Definir as regras é a parte do projeto de um sistema de inferência *fuzzy* que lhe confere inteligência, e sua eficácia depende da experiência do projetista para com o processo, visto

que o conjunto de regras de um FIS deve prever todas as situações possíveis e relevantes das variáveis de entrada e relacionar cada uma dessas situações a uma ação nas variáveis de saída. As regras *fuzzy* têm o seguinte formato:

Se x é A , então y é B .

A expressão acima é uma regra *fuzzy* que determina que, se a variável de entrada x pertencer ao conjunto de entrada A , então a variável de saída y pertencerá ao conjunto de saída B . A condição, a parte entre os termos “se” e “então”, é chamada de antecedente, segundo a terminologia *fuzzy*. Analogamente, a parte que se segue ao termo “então” é chamada de conseqüente. Essa estrutura **se-então** também pode ser utilizada para relacionar múltiplas variáveis de entrada com múltiplas variáveis de saída. Nesse caso, o formato seria:

Se x_1 é A_1 e x_2 é A_2 , então y_1 é B_1 e y_2 é B_2 .

Nessa expressão, a regra determina os conjuntos de saída de ambas as variáveis de saída y_1 e y_2 , desde que uma condição seja satisfeita pelas variáveis de entrada x_1 e x_2 . Em particular, o antecedente poderia ser estabelecido utilizando-se “ou” em vez de “e”, com efeito similar ao encontrado na lógica Booleana, porém, utilizando-se as expressões matemáticas que definem as relações entre conjuntos *fuzzy*, conforme (14).

A operação de aplicação das regras e atribuição de um valor de pertinência a cada conjunto *fuzzy* de saída é chamada de ativação. Após avaliar a pertinência das variáveis de entrada aos conjuntos respectivos, é definido o grau de ativação de cada regra, indicado por c_r . Caso o antecedente tenha apenas uma proposição, como em “Se x é $A...$ ”, o grau de ativação da regra é o próprio valor da função de pertinência $\mu_A(x_{crisp})$. Caso o antecedente tenha mais de uma proposição, estas serão relacionadas por algum operador *fuzzy* para gerar o grau de ativação. Por exemplo, em “Se x_1 é A_1 e x_2 é $A_2...$ ”, as duas proposições estão relacionadas por uma conjunção. Nesse caso, o valor do grau de ativação é:

$$c_r = \min [\mu_{A_1}(x_{crisp,1}), \mu_{A_2}(x_{crisp,2})] \quad (26)$$

Por outro lado, em “Se x_1 é A_1 ou x_2 é $A_2...$ ”, as duas proposições estão relacionadas por uma disjunção. Nesse caso, o valor do grau de ativação é:

$$c_r = \max [\mu_{A_1}(x_{crisp,1}), \mu_{A_2}(x_{crisp,2})] \quad (27)$$

Nas equações acima, as operações de conjunção e disjunção foram representadas conforme (14). A Figura 8 ilustra o processo de obtenção do valor do grau de ativação de uma regra com duas proposições conectadas por operadores de conjunção e de disjunção.

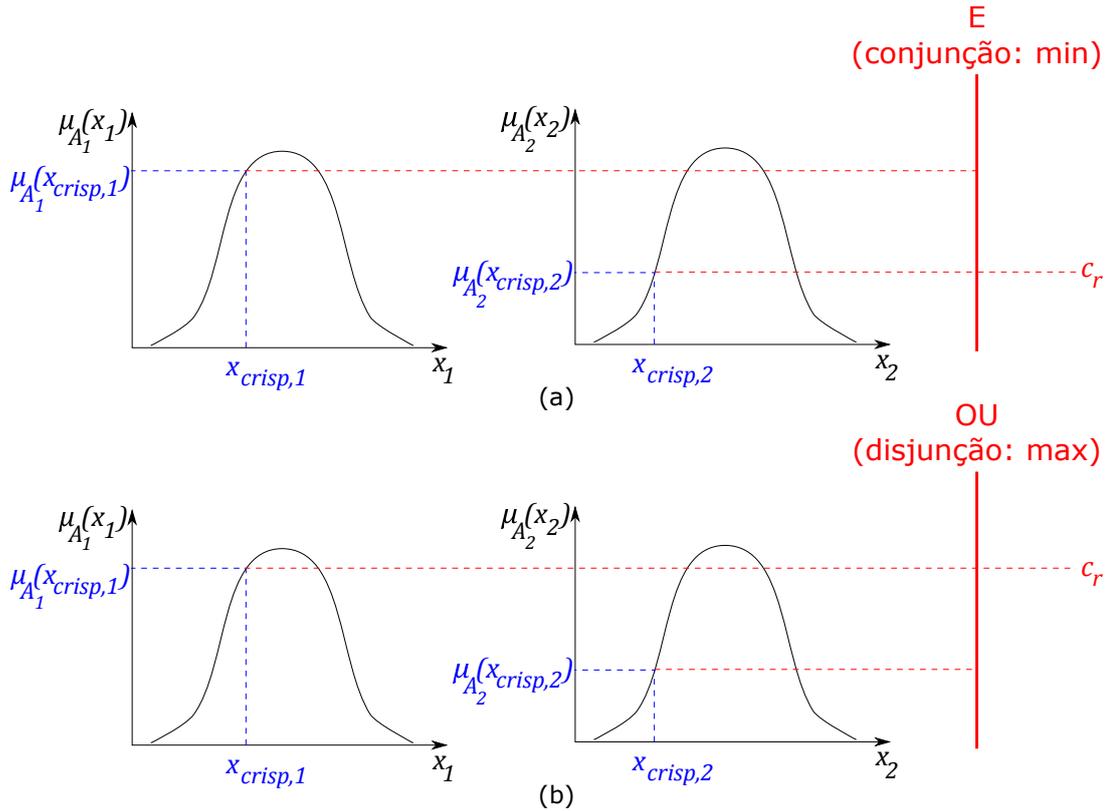


Figura 8 – Exemplo de obtenção do grau de ativação. (a) Utilizando o operador de conjunção. (b) Utilizando o operador de disjunção.

Com o grau de ativação c_r de uma regra r , é possível obter uma representação do conjunto *fuzzy* de saída referente ao conseqüente dessa regra. É definida uma região sob a curva de pertinência do conjunto de saída de acordo com o operador de ativação, que comumente é o operador min, de acordo com (28), em que μ_B^r representa a função de pertinência do conjunto de saída específico a ser ativado pela regra r .

$$\mu_B^{At,r}(y) = \min [c_r, \mu_B^r(y)] \quad (28)$$

A área sombreada na Figura 9 é a área sob a curva $\mu_B^r(y)$, que será utilizada, juntamente com as saídas de outras regras, para encontrar-se a saída *fuzzy* do sistema. O conseqüente de uma regra pode ter mais de uma proposição, conectadas por operadores de conjunção. Nesse caso, a etapa de ativação é repetida para cada uma das proposições no conseqüente. É importante notar que cada variável de entrada pode ativar não apenas uma, mas várias regras. Como a variável é classificada em conjuntos *fuzzy*, seu valor *crisp* pode pertencer a mais de um conjunto, com graus de pertinência específicos para cada conjunto.

Após a ativação das regras, as variáveis de saída têm graus de pertinência relacionados aos diversos conjuntos *fuzzy* de saída. Em seguida, é necessário associar esses valores de pertinência da variável de forma a gerar um único “objeto” *fuzzy* que represente

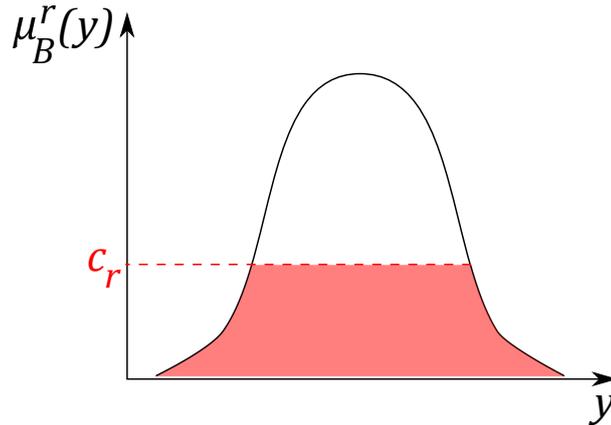


Figura 9 – Exemplo de ativação do consequente de uma regra.

a saída do sistema. No caso da metodologia Mamdani, isto se dá por meio das áreas *fuzzy* geradas pelos graus de pertinência e sua interação por meio do conjunto de regras. As áreas referentes a cada conjunto de saída são associadas, definindo uma área sobre o intervalo de definição da variável de saída. A operação que associa o grau de pertinência da variável de saída aos diversos conjuntos é chamada de agregação. Em geral, a agregação é feita utilizando-se o operador max, conforme (29), em que N_r é o número total de regras. A área final, resultante da agregação, é a solução *fuzzy* para o problema que se apresenta. A Figura 10 ilustra o processo de obtenção da área *fuzzy* resultante da agregação em um sistema com duas regras.

$$\mu_B^{Ag}(y) = \max \{ \min [c_r, \mu_B^r(y)] \}, \quad r = 1, 2, \dots, N_r \quad (29)$$

No entanto, a solução *fuzzy* não pode ser diretamente aplicada em sistemas eletrônicos, pois eles esperam valores numéricos *crisp*. Dessa maneira, para definir o valor *crisp* correspondente da variável de saída, é necessário realizar o processo de defuzzificação, ou seja, transformar uma resposta *fuzzy* em uma resposta *crisp*. Isso é feito para cada variável de saída.

Existem diversos métodos para defuzzificar a saída do FIS. Pode-se escolher a abcissa do valor com máxima pertinência, pode-se fazer uma média dos valores com maior pertinência, pode-se escolher o valor da abcissa que divide a área ao meio. A escolha do método de defuzzificação depende das particularidades do problema a ser resolvido.

O método utilizado neste trabalho define o valor de saída pelo centroide da área estabelecida pela agregação. De fato, o valor *crisp* de saída será a abcissa do centroide da área em questão. Para uma função $f(x)$ com suporte no intervalo $[a, b]$, a abcissa \bar{x} do centroide da área sob a curva da função é calculada de acordo com (30) [72]. A Figura 11

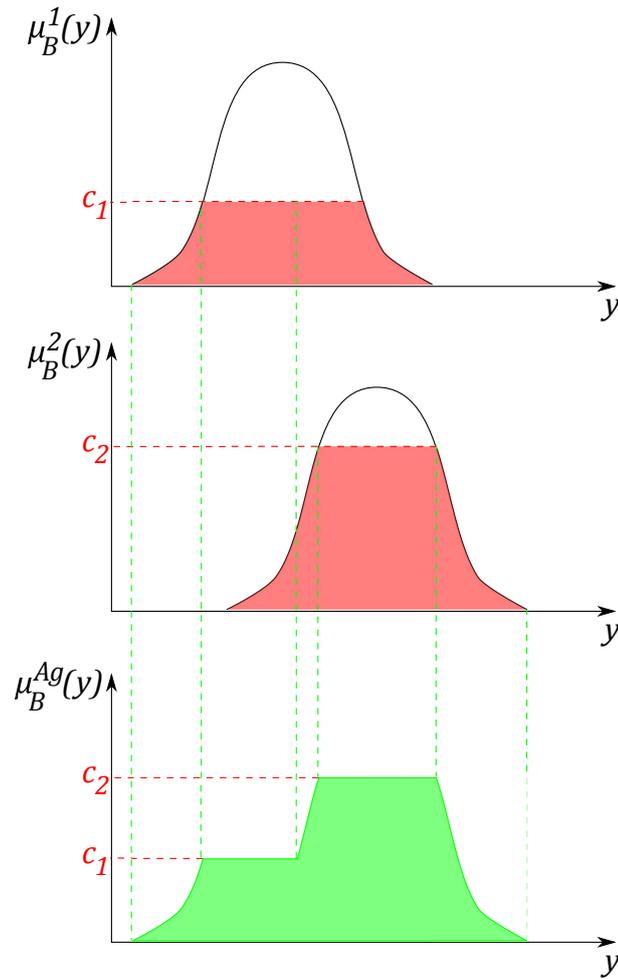


Figura 10 – Exemplo de agregação em um sistema com duas regras.

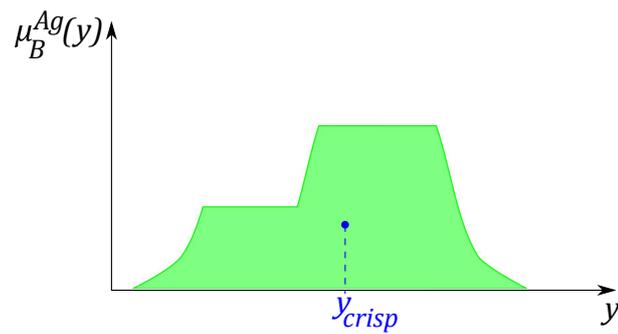


Figura 11 – Exemplo de defuzzificação pelo centroide.

mostra um exemplo de defuzzificação utilizando esse método.

$$\bar{x} = \frac{\int_a^b x \cdot f(x) dx}{\int_a^b f(x) dx} \quad (30)$$

A Figura 12 mostra um exemplo completo de inferência *fuzzy*, seguindo os passos

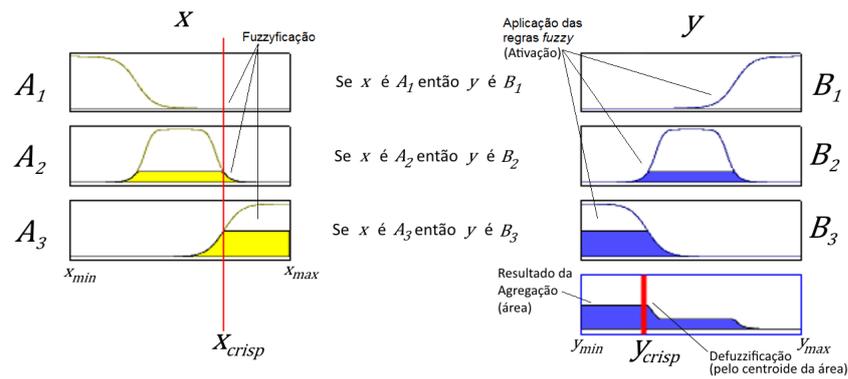


Figura 12 – Exemplo completo de inferência *fuzzy*.

descritos acima. A variável *fuzzy* de entrada x está definida em um universo de discurso *crisp* $[x_{min}, x_{max}]$. A variável *fuzzy* de saída y está definida em um universo de discurso *crisp* $[y_{min}, y_{max}]$. Inicialmente, o sistema recebe uma entrada *crisp* x_{crisp} . O primeiro processo realizado é a fuzzificação, em que a variável recebe graus de pertinência relacionados aos três grupos *fuzzy* de entrada A_1 , A_2 e A_3 . As áreas em amarelo representam as regiões em que a curva é menor ou igual ao grau de pertinência respectivo. Em seguida, são aplicadas as regras. Cada regra transfere ao grupo de saída o grau de pertinência referente ao conjunto de entrada, gerando as áreas em azul nos conjuntos de saída, analogamente às em amarelo no conjuntos de entrada. Dessa forma, a primeira regra é ativada com um grau muito baixo, visto que a pertinência de x a A_1 é quase nula. Em contrapartida, as outras regras são ativadas com graus mais significativos. O próximo passo é agregar as áreas referentes aos três conjuntos de saída B_1 , B_2 e B_3 , gerando a área indicada como resultado da agregação, isto é, a saída *fuzzy* do sistema. Por fim, é feita a defuzzificação desse resultado, utilizando a abcissa y_{crisp} do centroide da área em questão. A Figura 12 foi criada utilizando-se a *toolbox* de lógica *fuzzy* do *software* Matlab.

As vantagens de um sistema *fuzzy* residem em sua simplicidade de implementação, alta tolerância a erros das variáveis de entrada, especialmente os erros aleatórios, e garantia de estabilidade dentro do universo de discurso do problema, desde que o projetista a tenha previsto nas regras. O projeto é feito de forma intuitiva, através de variáveis linguísticas, definindo regras gerais de funcionamento para o sistema.

Dessa forma, o sucesso do sistema depende de o projetista conseguir relacionar as entradas com as saídas da maneira adequada, baseado em sua experiência e conhecimento sobre o problema. Os sistemas *fuzzy* são especialmente úteis quando o modelo matemático do sistema é altamente não-linear ou complexo, devido ao funcionamento baseado em regras.

2.2.3 Redes Neurais Artificiais

Redes neurais artificiais (RNAs) são sistemas de processamento de informação que têm certas características em comum com redes neurais biológicas [73]. São sistemas paralelos distribuídos compostos por unidades de processamento simples que calculam determinadas funções matemáticas, geralmente não lineares [74]. O funcionamento das RNAs é inspirado em processos observados no cérebro humano, que possui diversas características desejáveis em sistemas artificiais [75]:

- É robusto e tolerante a falhas. Células nervosas do cérebro morrem todos os dias sem que isso afete significativamente seu desempenho.
- É flexível. Pode ajustar-se facilmente a um novo ambiente por meio do aprendizado. Não precisa ser programado.
- É capaz de lidar com informações imprecisas, probabilísticas, ruidosas ou inconsistentes.
- É altamente paralelo.
- É pequeno, compacto e dissipa muito pouca potência.

As RNAs foram desenvolvidas como generalizações de modelos matemáticos da cognição humana ou da biologia neural, baseado nas hipóteses de que [73]:

1. O processamento da informação ocorre em diversos elementos simples chamados de neurônios.
2. Os sinais são transmitidos entre neurônios através de conexões.
3. Cada conexão tem um peso associado, que, em uma rede neural típica, multiplica o sinal transmitido.
4. Cada neurônio aplica uma função de ativação, geralmente não linear, à sua entrada total (soma dos sinais de entrada ponderados) para determinar seu sinal de saída.

Os parâmetros que caracterizam uma rede são: (I) seu padrão de conexões entre os neurônios, chamado de arquitetura da rede, (II) o método utilizado para determinar os pesos das conexões², chamado de algoritmo de aprendizado, ou de algoritmo de treinamento, (III) sua função de ativação [73]. Os primeiros artigos sobre RNAs foram publicados há

² As conexões entre os neurônios em uma RNA também são conhecidas como sinapses, seguindo a nomenclatura biológica. Os pesos associados às conexões também são chamados de pesos sinápticos.

mais de 50 anos, porém, na década de 1990 o assunto começou a ser pesquisado mais profundamente e ainda mostra grande potencial de pesquisa. As aplicações envolvendo sistemas considerados inteligentes são diversas, incluindo: [76]

- Análise de imagens obtidas por satélites artificiais.
- Classificação de padrões de fala e de escrita.
- Reconhecimento facial com visão computacional.
- Controle de trens de alta velocidade.
- Previsão de valores de ações no mercado financeiro.
- Identificação de anomalias em imagens médicas.
- Identificação automática de perfis de crédito para clientes de instituições financeiras.
- Controle de dispositivos eletrônicos e eletrodomésticos, como lavadoras de roupa, fornos de micro-ondas, geladeiras, cafeteiras, fritadeiras, câmeras de vídeo, entre outros.

As RNAs apresentam diversas características que podem ser exploradas no processamento de informação, dentre elas [76]:

- (a) **Adaptação a partir da experiência:** os pesos sinápticos são ajustados pela examinação de exemplos sucessivos, permitindo a aquisição de conhecimento pela experiência.
- (b) **Capacidade de aprendizado:** através do uso de um método de aprendizado, a rede pode extrair a relação existente entre as várias variáveis da aplicação.
- (c) **Capacidade de generalização:** terminado o processo de aprendizado, a rede é capaz de generalizar o conhecimento adquirido, permitindo a estimação de soluções até então desconhecidas.
- (d) **Organização de dados:** baseada em informações inerentes ao processo, a rede pode organizar essa informação, permitindo o agrupamento de padrões com características comuns.
- (e) **Tolerância a falhas:** devido ao alto número de interconexões entre os neurônios, a rede é tolerante a falhas se parte de sua estrutura interna for corrompida de alguma forma.

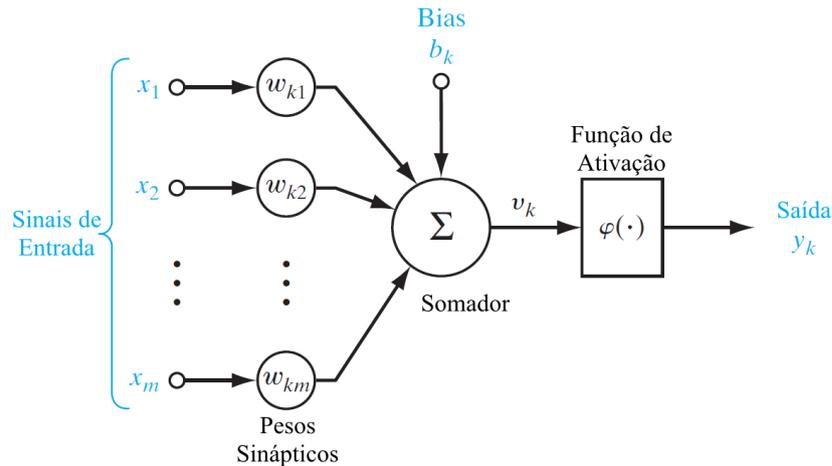


Figura 13 – Modelo não linear de um neurônio.

Fonte: [77] (Adaptada)

- (f) **Armazenamento distribuído:** o conhecimento sobre um processo aprendido pela rede é armazenado nas diversas sinapses, melhorando a robustez da arquitetura em caso de perda de algum neurônio.
- (g) **Prototipagem facilitada:** muitas arquiteturas neurais podem ser facilmente implementadas em *hardware* ou *software*, visto que, após o treinamento, os resultados são obtidos a partir de operações matemáticas básicas.

O modelo matemático do neurônio é composto de três elementos básicos: as sinapses, caracterizadas pelos seus pesos, um somador e uma função de ativação, conforme ilustrado na Figura 13. Um neurônio, k , pode ter m entradas x_j , com $j = 1, \dots, m$. Cada uma delas é multiplicada pelo peso sináptico correspondente, w_{kj} . Esses valores ponderados são, então, somados e, além disso, a soma pode incluir um valor constante, b_k , chamado *bias*, que não depende de nenhuma entrada do neurônio. O resultado, v_k , passa por uma função de ativação, $\varphi(\cdot)$, para gerar a saída do neurônio, y_k . A função geralmente é não linear, com o objetivo de limitar a saída a um intervalo normalizado. Matematicamente, o modelo do neurônio pode ser descrito utilizando-se a Eq. (31). [77]

$$y_k = \varphi(v_k) = \varphi\left(\sum_{j=1}^m w_{kj}x_j + b_k\right) \quad (31)$$

Os tipos básicos de função de ativação são dois: as funções de limiar e as funções sigmóides. Funções de limiar são aquelas que possuem um valor de saída até certo limiar da variável de entrada e mudam seu valor a partir desse limiar. Um exemplo desse tipo de função é a função degrau, expressa em (32) [77]. Um neurônio que utilize tal função como

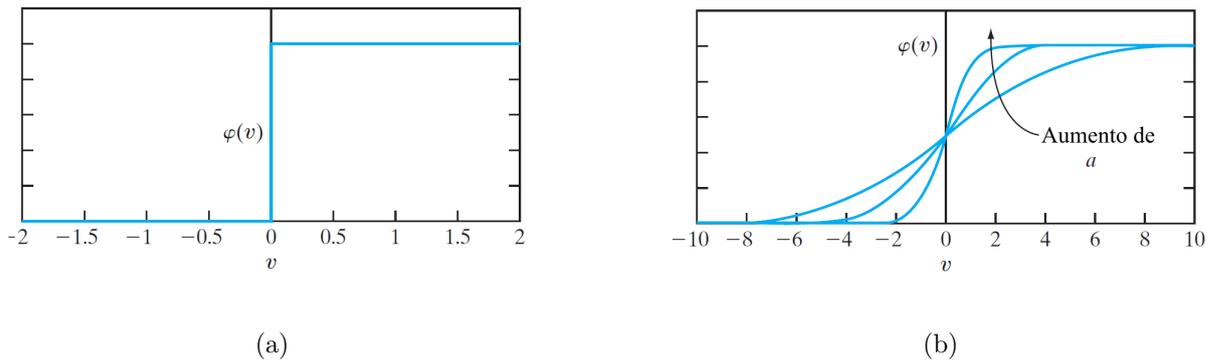


Figura 14 – Tipos de função de ativação. (a) Função de limiar (degrau). (b) Funções sigmoides (logísticas) com diversas inclinações.

Fonte: [77] (Adaptada)

função de ativação terá uma saída binária.

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq 0 \\ 0, & \text{se } v < 0 \end{cases} \quad (32)$$

As funções sigmoides apresentam gráficos em forma de “S” e são o tipo mais comum na construção de redes neurais. Um exemplo desse tipo de função é a função logística, expressa em (33), em que a é o parâmetro que controla a inclinação da curva. A Figura 14 ilustra os dois tipos de função de ativação. [77]

$$\varphi(v) = \frac{1}{1 + \exp(-av)} \quad (33)$$

Os dois exemplos de função citados geram saídas y_k assumindo valores no intervalo $[0, 1]$. Em diversas aplicações, é interessante que a saída possa assumir valores no intervalo $[-1, 1]$. A função sinal, descrita conforme (34), é um exemplo de função de limiar com saída no intervalo $[-1, 1]$. Analogamente, a tangente hiperbólica, conforme (35), é um exemplo de função sigmoide que assume valores nesse mesmo intervalo. [77]

$$\varphi(v) = \begin{cases} 1, & \text{se } v > 0 \\ 0, & \text{se } v = 0 \\ -1, & \text{se } v < 0 \end{cases} \quad (34)$$

$$\varphi(v) = \tanh(v) \quad (35)$$

Outros tipos de função de ativação são possíveis, embora menos comuns. A relação entre v_k e y_k pode ser, por exemplo, uma função linear. É importante notar que, devido à saturação inerente à aplicação dessas funções, uma etapa fundamental da utilização das RNAs é a normalização dos dados e, conseqüentemente, sua desnormalização ao final do processo.

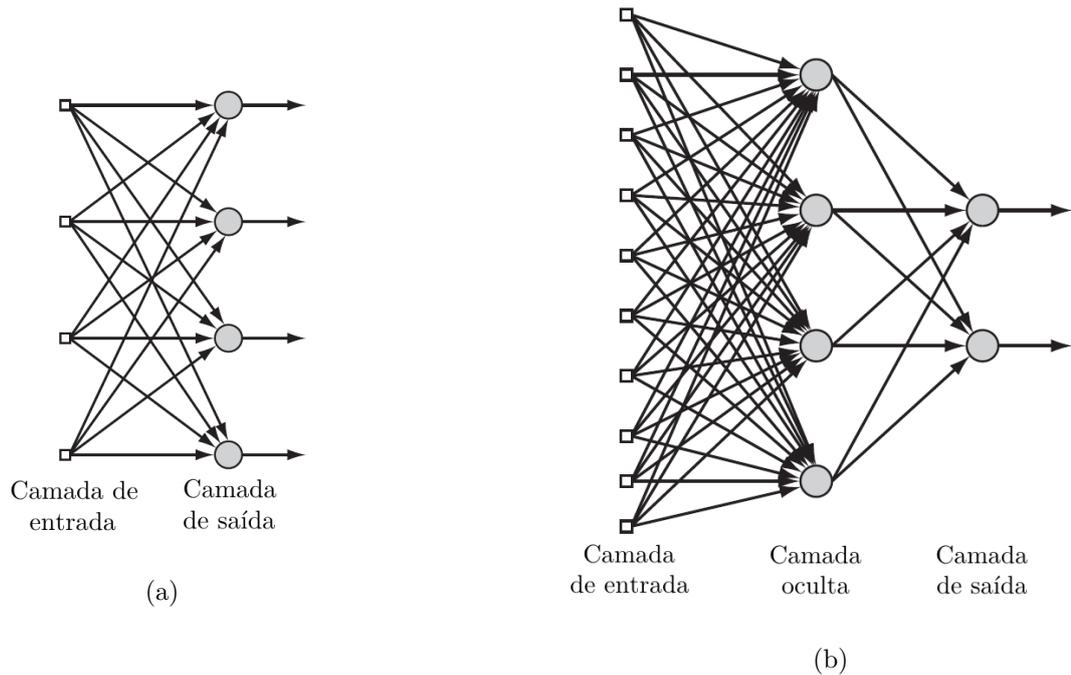


Figura 15 – Exemplos de redes diretas. (a) Rede direta de camada única. (b) Rede direta de múltiplas camadas.

Fonte: [77] (Adaptada)

A disposição e a estrutura de interconexão entre os neurônios é chamada de arquitetura da RNA. O tipo de arquitetura está intimamente ligado às aplicações e ao algoritmo de aprendizado da rede.

As redes com arquitetura mais simples são as redes diretas de camada única. Sua estrutura está ilustrada na Figura 15a. Nesse modelo, os nós de entrada conectam-se diretamente à camada de neurônios de saída da rede. Não há processamento na camada de entrada, apenas na de saída, por isso a denominação “camada única”. A informação, nas redes com essa arquitetura, procede apenas na direção dos nós de entrada para os neurônios de saída, por isso são chamadas de redes diretas. [77]

As redes diretas de múltiplas camadas também possuem fluxo de informação em apenas uma direção, porém, não apresentam conexões entre os nós de entrada e a camada de saída. Essa conexão é feita através de pelo menos uma camada oculta. A presença de camadas ocultas permite que a rede extraia estatísticas de mais alta ordem a partir de suas entradas. Nesse modelo, se cada neurônio estiver conectado a todos os neurônios da camada seguinte, diz-se que a rede é completamente conectada. Cabe ressaltar que existem redes que não apresentam essa característica. As RNAs consideradas neste trabalho serão redes diretas de múltiplas camadas. A Figura 15b mostra a estrutura de uma rede desse tipo. [77]

O conhecimento adquirido por uma rede neural é armazenado nos pesos sinápticos. Os valores dos pesos sinápticos são determinados ao longo do treinamento da rede, sua

fase de aprendizado. O conhecimento armazenado nas sinapses de uma RNA representa uma espécie de memória. A rede utiliza essa memória para gerar saídas corretas para entradas conhecidas e, também, para generalizar o conhecimento, gerando saídas coerentes para entradas desconhecidas.

As saídas de uma RNA podem ser treinadas para responder a um conjunto de entradas da forma desejada. Essa característica permite que as RNAs forneçam uma aproximação para funções com qualquer número de variáveis de entrada e de saída. Para isso, é necessário fornecer, na fase de treinamento, um conjunto grande o suficiente de exemplos de entradas e saídas correspondentes para que a rede aprenda o comportamento da função em questão. Dessa forma, as RNAs são ferramentas muito úteis na identificação e simulação de sistemas e na modelagem de sistemas inversos.

Um método comum para o treinamento de redes de múltiplas camadas é o algoritmo conhecido como *back-propagation*. O processo ocorre em duas fases e requer um conjunto de dados de exemplo para o treinamento. Primeiramente, os pesos sinápticos iniciais são utilizados para gerar um sinal de saída para uma entrada do conjunto de treinamento. Em seguida, essa saída é utilizada para gerar um sinal de erro, em relação à saída desejada, que é propagado na direção inversa, gerando ajustes nos pesos sinápticos que minimizem o sinal de erro. O processo é iterativo e continua até que algum critério de parada seja atingido. Na terminologia específica, cada uma das iterações é chamada de época. Os critérios de parada mais comuns são o número máximo de épocas, o valor mínimo do gradiente³ da superfície de erro e o número máximo de falhas de validação⁴. A formulação matemática do algoritmo pode ser encontrada em [77].

³ O algoritmo é baseado no método do gradiente descendente. Um valor muito baixo do gradiente pode significar que um ponto de mínimo foi encontrado.

⁴ Uma parte dos dados de treinamento é reservada para validação e não afeta o treinamento da rede. O procedimento de validação é fundamental para evitar que a rede se especialize excessivamente no conjunto de treinamento, o que significaria uma perda na capacidade de generalização. Essa especialização excessiva é conhecida como *overfitting* e diz-se que a rede está viciada.

3 PROJETO DO INTERROGADOR

Neste capítulo, é descrito o processo de desenvolvimento do sistema proposto. As características e o funcionamento do estágio óptico do sistema são expostos na Seção 3.1. A Seção 3.2 discorre sobre o desenvolvimento dos métodos que se propõem como alternativas para o estágio de processamento. Primeiramente, é abordada uma técnica mais tradicional de aproximação de funções, utilizando o método dos mínimos quadrados, na Subseção 3.2.1. Em seguida, é analisada a utilização de um sistema de inferência *fuzzy*, na Subseção 3.2.2. Finalmente, a Subseção 3.2.3 trata do desenvolvimento de uma rede neural artificial para ser empregada no estágio de processamento.

3.1 ESTÁGIO ÓPTICO

A fim de projetar o sistema de interrogação, um sensor de temperatura baseado em FBG foi desenvolvido. O funcionamento do sensor FBG é bem documentado na literatura e, por isso, não é o foco deste trabalho. A faixa de operação do sensor é adotada como sendo de 15 °C a 65 °C. Tal sensor pode ser utilizado para monitorar a temperatura em dispositivos eletrônicos, por exemplo.

A Figura 16 mostra uma visão geral do sistema de sensoriamento, ilustrando tanto o sensor quanto o interrogador. A fonte, que pode ser um diodo emissor de luz (LED - *Light Emitting Diode*), irradia a luz na seção de fibra contendo o sensor, que a reflete parcialmente. Conforme mencionado no Item 2.1.2.1, a resposta do sensor é dada como um deslocamento espectral no comprimento de onda do pico ressonante. Portanto, o estágio óptico do sistema de interrogação proposto recebe o sinal do sensor e o distribui para vários filtros passa-banda⁵, com o objetivo de separar o sinal em sub-bandas espectrais. Os filtros são FBGs mantidas em temperatura controlada, com picos ressonantes centrados em comprimentos de onda escolhidos. A Figura 17 mostra como o espectro do sensor interage com os três filtros do interrogador. Nesta figura, as curvas vermelha, verde e azul representam os espectros dos filtros, cada um centrado em um comprimento de onda de referência correspondendo às temperaturas de 15 °C, 35 °C e 55 °C. A curva preta representa o espectro do sensor, que se desloca de acordo com a temperatura a que o sensor está sujeito. Neste caso, a figura ilustra a resposta do sensor para uma temperatura simulada de 20 °C.

Dependendo da localização do pico ressonante, a convolução entre a resposta do sensor e a de cada filtro fixo poderá conter uma potência óptica maior ou menor, gerando diferentes valores em cada fotodetector. A Figura 18 mostra como a potência óptica, na

⁵ O número de filtros e o espaçamento entre eles definem a faixa dinâmica e a resolução do sistema de interrogação. Neste trabalho, foram arbitrados três filtros, como forma de obter uma evidência de que esse sistema de interrogação é válido e possível.

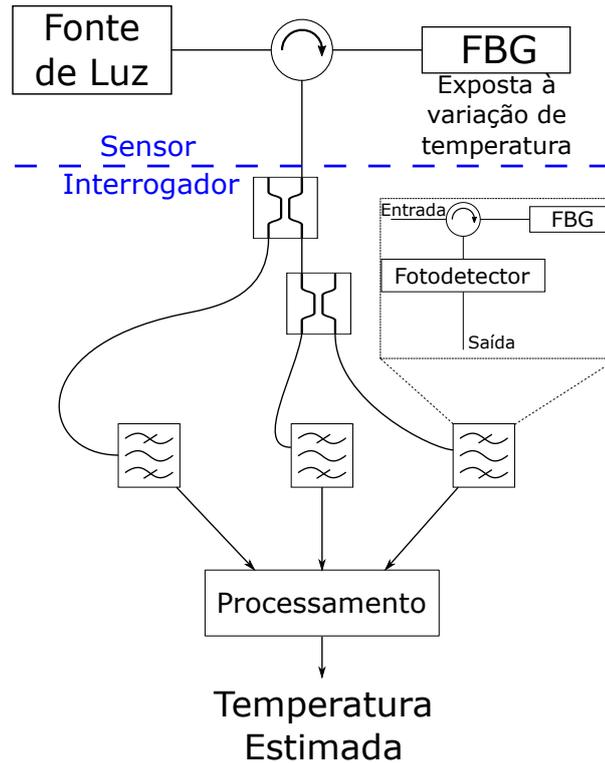


Figura 16 – Visão geral do sistema de sensoriamento, composto do sensor e do interrogador.

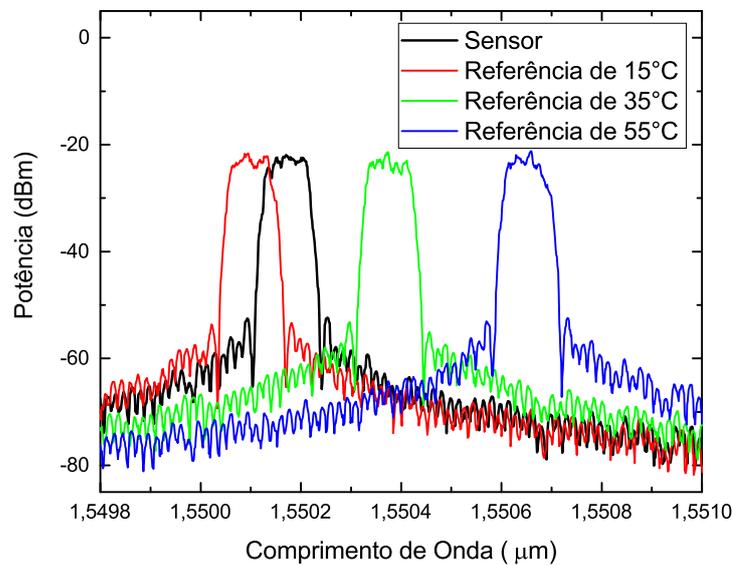


Figura 17 – Espectro do sensor sobreposto aos espectros dos diferentes filtros.

saída de cada filtro, muda com a temperatura simulada. A curva vermelha, que representa o primeiro filtro, é 3 dB mais alta que as outras duas. Isso ocorre devido à forma com que os acopladores estão dispostos no sistema. A Figura 18 ilustra as entradas e saídas do sistema de interrogação a ser desenvolvido. As ordenadas, as potências ópticas nas saídas dos três filtros, são as entradas do sistema, enquanto a abscissa, a temperatura, é sua saída.

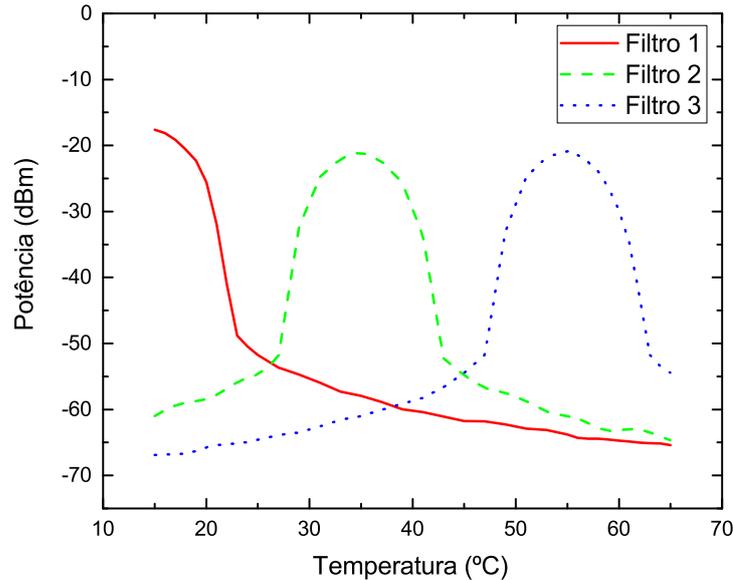


Figura 18 – Potência óptica na saída dos filtros para diversas temperaturas.

A convolução do sinal em cada filtro é coletada por um fotodetector, o que efetivamente dá uma medida da similaridade entre o sinal e a referência. A saída de cada fotodetector é, então, convertida para um valor digital e passada para o estágio de processamento, cujo objetivo é associar esses valores a fim de retornar o valor da temperatura medida pelo sensor, em graus Celsius.

Em comparação com métodos tradicionais, esse sistema de interrogação apresenta vantagens interessantes. Algoritmos de detecção de pico podem ser utilizados para interrogar sensores FBG, mas demandam uma forma de calcular o espectro de reflexão do sensor, o que requer mais equipamento, memória e poder de processamento que o sistema proposto. Uma alternativa é filtrar a saída do sensor com uma LPG e coletar a potência óptica com um fotodetector, porém, isso gera resultados menos precisos que os do sistema proposto, como será mostrado no capítulo seguinte. Adicionalmente, os valores da resolução e da faixa dinâmica do sistema proposto podem ser controlados ajustando-se os comprimentos de onda de referência e o número de filtros.

3.2 ESTÁGIO DE PROCESSAMENTO

A seguir, serão analisadas três propostas para o estágio de processamento. Para analisar as propostas de forma imparcial, foram criados dois conjuntos independentes de dados: um para o treinamento e um para testes. Cada conjunto consiste em simulações das saídas de cada fotodetector referentes a diferentes temperaturas, utilizando-se, para isso, os *softwares* OptiGrating e OptiSystem para simulação de sistemas ópticos⁶. A

⁶ No OptiGrating, foram geradas simulações do comportamento do sensor para diversas temperaturas, que foram inseridas no OptiSystem, de acordo com o esquemático da Figura 16.

implementação dos algoritmos foi feita no *software* Matlab. Nota-se que a saída do fotodetector é diretamente proporcional à potência óptica, tornando simples a conversão entre elas. Portanto, por simplicidade, a potência óptica foi utilizada como parâmetro nas simulações.

3.2.1 Ajuste Polinomial pelo Método dos Mínimos Quadrados

Como primeira análise, foi escolhida uma técnica tradicional de aproximação de funções: o ajuste polinomial. Para realizar o ajuste, foi utilizado o método dos mínimos quadrados, de acordo com a metodologia exposta no Item 2.2.1.1. O sistema a ser modelado possui como entradas as variáveis independentes p_1 , p_2 e p_3 , as potências após cada filtro, e como variável dependente t , a temperatura, como saída. Portanto, busca-se obter uma função polinomial $f(p_1, p_2, p_3)$ que aproxime t da melhor forma possível.

Utilizando o conjunto de dados de treinamento, foram geradas aproximações polinomiais de grau 1, 2 e 3, com e sem utilização de termos cruzados. Para os graus superiores a 3, o método rendeu coeficientes nulos, ou insignificantes, portanto esses ajustes não foram considerados. Abaixo, são apresentadas as equações obtidas, nas quais t_i indica a aproximação com termos de grau menor ou igual a i e $t_{i,tc}$ um ajuste que leva em conta os termos cruzados de primeira ordem.

$$t_1 = -0,7591p_1 - 0,2904p_2 + 0,2182p_3 - 4,4851 \quad (36a)$$

$$t_{1,tc} = -19,7043p_1 + 19,4034p_2 - 14,2197p_3 + 0,1353p_1p_2 - 0,4063p_1p_3 + 0,1893p_2p_3 - 539,8593 \quad (36b)$$

$$t_2 = 0,0249p_1^2 + 0,0195p_2^2 - 0,0102p_3^2 + 1,3606p_1 + 1,4334p_2 - 0,8106p_3 + 41,6634 \quad (36c)$$

$$t_{2,tc} = 0,0225p_1^2 + 0,0153p_2^2 - 0,0101p_3^2 - 2,0280p_1 + 9,1625p_2 - 3,9047p_3 + 0,0698p_1p_2 - 0,1109p_1p_3 + 0,0648p_2p_3 + 51,7101 \quad (36d)$$

$$t_3 = -0,0008p_1^3 - 0,0006p_2^3 + 0,0007p_3^3 - 0,0821p_1^2 - 0,0673p_2^2 + 0,0790p_3^2 - 2,9393p_1 - 2,1403p_2 + 2,7540p_3 - 0,0262 \quad (36e)$$

$$t_{3,tc} = -0,0014p_1^3 - 0,0005p_2^3 - 0,0001p_3^3 - 0,1428p_1^2 - 0,0503p_2^2 + 0,0072p_3^2 - 4,7502p_1 - 0,1028p_2 + 0,2821p_3 + 0,0147p_1p_2 - 0,0097p_1p_3 + 0,0121p_2p_3 + 0,0935 \quad (36f)$$

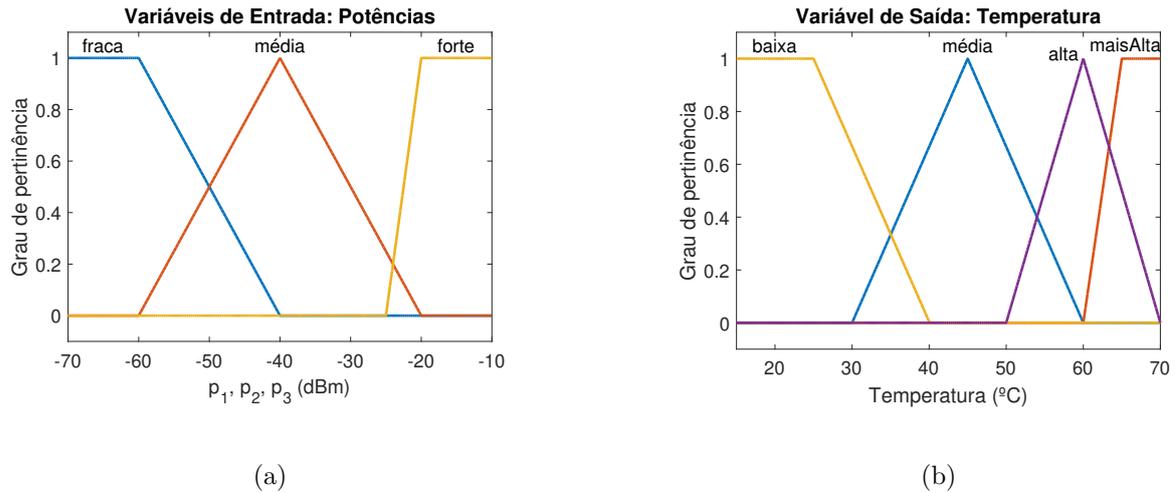


Figura 19 – Funções de pertinência dos conjuntos *fuzzy* definidos manualmente. (a) Variáveis de entrada. (b) Variável de saída.

3.2.2 Sistema de Inferência Fuzzy

Devido à natureza das respostas dos filtros⁷, foi desenvolvido um sistema de inferência *fuzzy* para decodificar os valores dos fotodetectores para a temperatura estimada. O sistema *fuzzy* apresenta três variáveis de entrada e uma de saída, correspondendo às potências e à temperatura. O primeiro FIS foi desenvolvido manualmente, num processo de tentativa e erro. Entretanto, o grande número de parâmetros para ajustar⁸ tornou difícil a obtenção de precisão na resposta. A melhor configuração encontrada manualmente, cujas variáveis estão ilustradas na Figura 19, foi incapaz de estimar a temperatura com a precisão desejada. As regras definidas para o funcionamento do FIS estão expostas na Tabela 2.

Tabela 2 – Regras de funcionamento do sistema de inferência *fuzzy*.

1	Se p_1 é forte e p_2 é fraca e p_3 é fraca, então t é baixa.
2	Se p_1 é fraca e p_2 é forte e p_3 é fraca, então t é média.
3	Se p_1 é fraca e p_2 é fraca e p_3 é forte, então t é alta.
4	Se p_1 é fraca e p_2 é fraca e p_3 é média, então t é maisAlta.
5	Se p_1 é média e p_2 é média e p_3 é fraca, então t é baixa.
6	Se p_1 é fraca e p_2 é média e p_3 é média, então t é alta.

Devido ao baixo desempenho do FIS original, foi realizada uma otimização utilizando o algoritmo de ecolocalização de morcegos. A fundamentação do algoritmo é apresentada em [78] e algumas aplicações são discutidas em [79]. Os parâmetros utilizados no algoritmo de otimização foram: número de morcegos igual a 50, taxa de decréscimo da amplitude

⁷ Parece haver uma lógica na relação entre as potências ópticas nas saídas de cada filtro que leve ao valor da temperatura.

⁸ Os parâmetros do FIS são a quantidade e o formato das funções de pertinência, os parâmetros de cada função e as regras que definem seu comportamento.

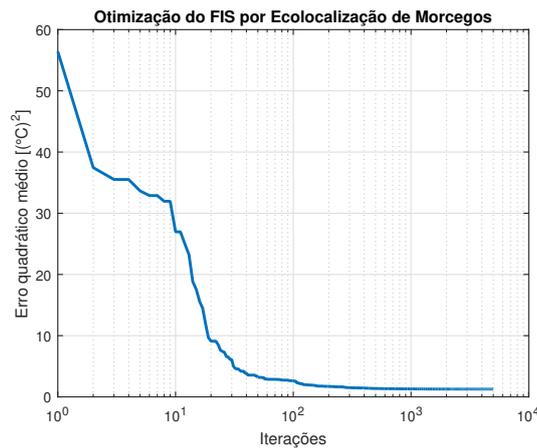


Figura 20 – Evolução do desempenho do FIS ao longo da otimização.

da onda sonora igual a 0,99, taxa de aumento da emissão do pulso da onda sonora igual a 0,01 e número máximo de iterações igual a 5000. As variáveis a serem otimizadas foram os 31 parâmetros livres⁹ das funções de pertinência do FIS, mantendo as regras e o número e o formato das funções sem alterações. Ao longo das iterações do algoritmo, o FIS foi capaz de fazer estimativas progressivamente melhores, como mostra a Figura 20. A Figura 21 mostra a configuração das variáveis do FIS após a otimização pelo algoritmo de ecolocalização de morcegos.

3.2.3 Rede Neural Artificial

Como nova alternativa para realizar a interrogação, foi criada uma RNA que recebe como entradas os valores dos fotodetectores e fornece como saída a temperatura. A estrutura escolhida para a rede tem apenas uma camada oculta, o que é suficiente na maioria dos problemas de aproximação de funções. Nos testes, a configuração que obteve melhor desempenho foi a que utilizava a função de ativação tangente hiperbólica na camada oculta e uma função linear na camada de saída.

Várias redes foram treinadas utilizando-se as simulações do grupo de treinamento: as saídas dos fotodetectores foram apresentadas a cada rede como entradas e os respectivos valores de temperatura como objetivos. Os critérios de parada utilizados foram o número de épocas (25000) e falhas de validação (1000). O processo de treinamento foi iniciado com um neurônio na camada oculta, e esse número foi aumentado progressivamente até a obtenção de resultados satisfatórios. Foram treinadas 30 redes com cada configuração da camada oculta e a melhor rede de cada configuração foi selecionada. Essa estratégia foi adotada porque, devido a aleatoriedade dos pesos sinápticos iniciais, os processos de treinamento podem gerar redes com desempenhos muito diferentes.

⁹ A primeira e a última função de pertinência de cada variável *fuzzy* possuem parâmetros cujos valores foram considerados fixos, devido ao universo de discurso finito das variáveis.

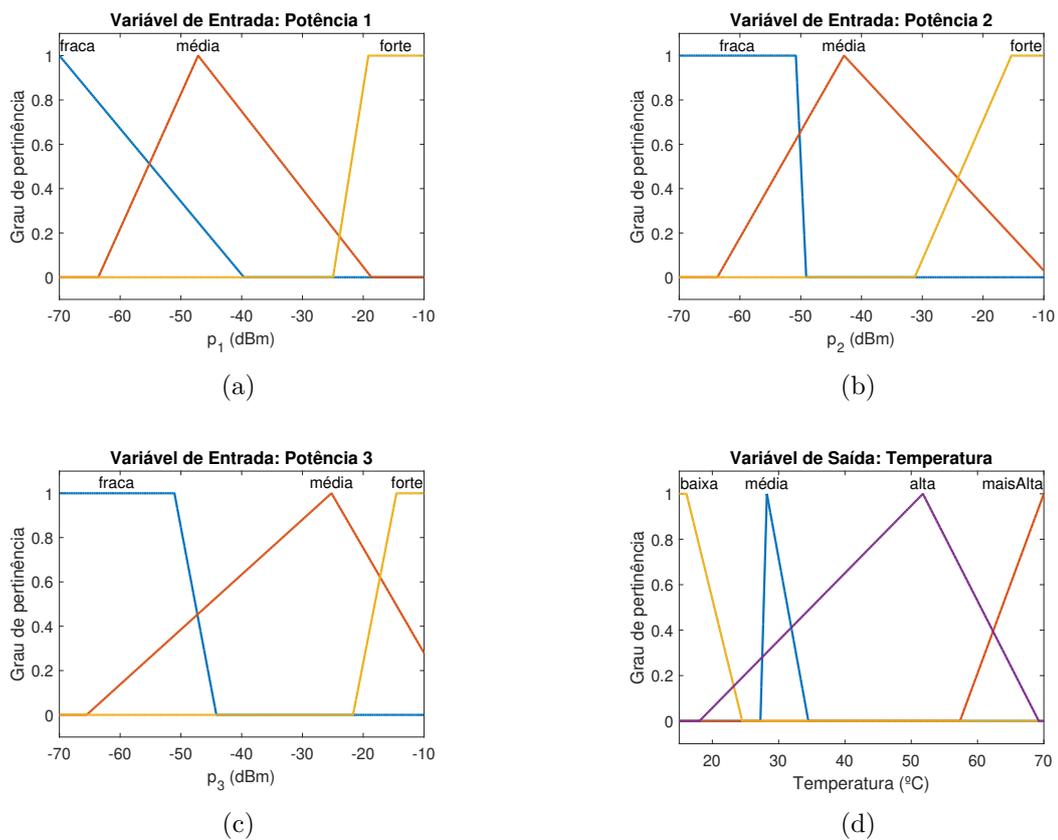


Figura 21 – Funções de pertinência dos conjuntos *fuzzy* otimizados pelo algoritmo de ecolocalização de morcegos. (a) Variável de entrada: potência após filtro 1. (b) Variável de entrada: potência após filtro 2. (c) Variável de entrada: potência após filtro 3. (d) Variável de saída: temperatura estimada.

4 TESTES E RESULTADOS

Neste capítulo, são descritos os testes realizados para verificação do desempenho dos sistemas propostos e são expostos os resultados obtidos. Inicialmente, na Seção 4.1, apresentam-se os resultados de desempenho das três propostas de interrogadores individualmente. Na Seção 4.2, é feita uma comparação dos resultados obtidos com uma técnica tradicional de interrogação, utilizando uma LPG para filtrar a saída do sensor. Por fim, a Seção 4.3 discute o desempenho das duas melhores propostas considerando-se a presença de ruído Gaussiano no sistema.

4.1 TESTES DE DESEMPENHO

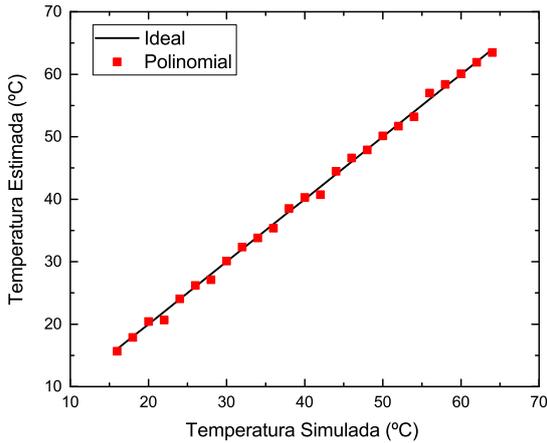
Os resultados foram obtidos em co-simulação utilizando os *softwares* OptiSystem e Matlab. Os componentes ópticos foram dispostos no OptiSystem de acordo com o esquemático da Figura 16 e os sinais dos fotodetectores foram enviados ao estágio de processamento, implementado no Matlab. Todos os resultados deste capítulo foram obtidos utilizando-se o grupo de dados de teste, ou seja, dados que não foram utilizados para o treinamento de nenhuma das técnicas.

A primeira proposta avaliada foi a do ajuste polinomial. O código desenvolvido no Matlab recebeu como entradas as potências ópticas coletadas em cada fotodetector. A Tabela 3 mostra os ajustes obtidos para algumas configurações polinomiais, além do erro quadrático médio (EQM) obtido aplicando-se o ajuste no conjunto de teste.

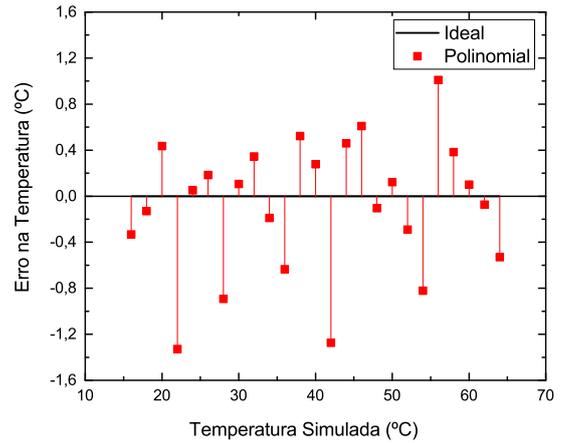
Tabela 3 – Ajustes polinomiais para a temperatura.

Grau	Termos Cruzados	Equação	EQM $[(^{\circ}\text{C})^2]$
1	não	(36a)	28,4422
1	sim	(36b)	12,3052
2	não	(36c)	4,2771
2	sim	(36d)	3,8612
3	não	(36e)	0,8311
3	sim	(36f)	0,3314

Conforme esperado, à medida que se aumenta o grau do polinômio, o erro do ajuste diminui. Além disso, a utilização dos termos com multiplicação cruzada se mostrou eficaz, melhorando o desempenho do sistema em todos os casos. A Figura 22a mostra a resposta do melhor ajuste polinomial, com grau 3 e utilizando os termos cruzados. Nessa figura, as abcissas indicam a temperatura que foi configurada na simulação do estágio óptico. As ordenadas indicam a temperatura obtida como resposta do sistema de interrogação. Idealmente, o gráfico deveria mostrar uma função identidade, representada em preto na figura. Quanto maior a proximidade entre os pontos obtidos e a curva preta, melhor o



(a)

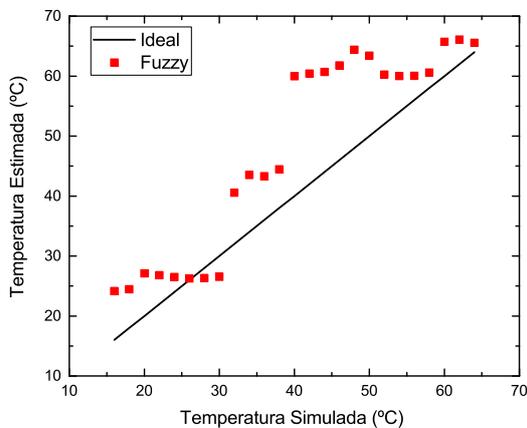


(b)

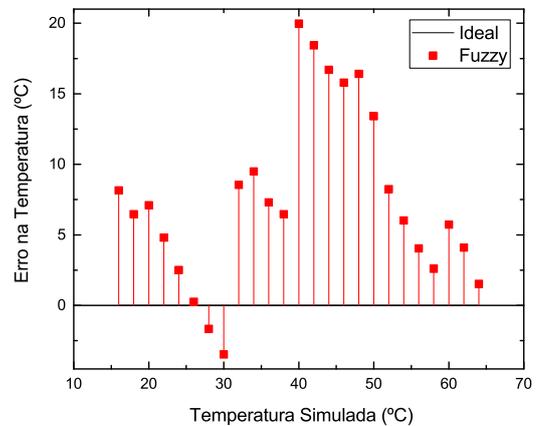
Figura 22 – Desempenho do melhor ajuste polinomial de grau 3 com termos cruzados. (a) Resposta à temperatura. (b) Residual.

desempenho do sistema. A Figura 22b mostra o residual, isto é, o erro na estimativa da temperatura, também para o melhor ajuste polinomial. Não se trata de novo conjunto de dados, apenas uma representação diferente que permite uma melhor visualização do erro na estimativa feita pelo sistema. Nessa figura, o ideal seria que os erros fossem nulos.

Em seguida, o sistema de interrogação baseado em inferência *fuzzy* foi avaliado, começando pelo FIS desenvolvido manualmente. Conforme indicado na Subseção 3.2.2, o desempenho desse sistema foi insuficiente, principalmente devido ao grande número de parâmetros a serem ajustados, o que dificultou o processo de tentativa e erro. A Figura 23a mostra a resposta desse sistema, com EQM superior a $90\text{ (}^\circ\text{C)}^2$. O residual encontra-se na Figura 23b. Nota-se que o desempenho do sistema está longe do ideal. Portanto, procedeu-se à otimização do FIS.



(a)



(b)

Figura 23 – Desempenho do interrogador baseado em lógica *fuzzy*. (a) Resposta à temperatura. (b) Residual.

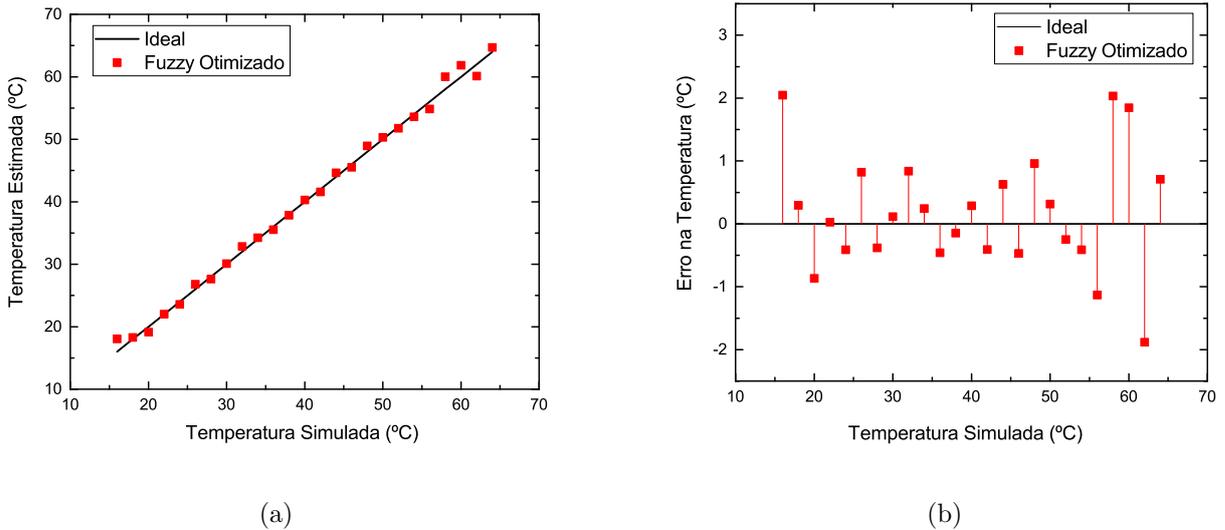


Figura 24 – Desempenho do interrogador baseado em lógica *fuzzy* otimizado pelo algoritmo de ecolocalização de morcegos. (a) Resposta à temperatura. (b) Residual.

Após a otimização, utilizando-se o algoritmo de ecolocalização de morcegos, com as variáveis configuradas conforme a Figura 21 e as regras definidas conforme a Tabela 2, o FIS exibiu uma resposta consideravelmente melhor, conforme ilustra a Figura 24a, registrando um EQM de $0,88 \text{ (}^\circ\text{C)}^2$. A Figura 24b mostra o residual correspondente. Nota-se que o desempenho poderia ser melhorado alterando-se o número e o formato das funções de pertinência em cada variável ou definindo-se novas regras. No entanto, quanto maior for o número de parâmetros, mais lenta será a otimização, de sorte que não se considerou viável expandir essa análise.

Finalmente, os interrogadores baseados em RNAs foram avaliados. Das redes treinadas, selecionaram-se as melhores de cada configuração da camada oculta. O desempenho das redes em função do número de neurônios na camada oculta pode ser visto na Tabela 4. Em geral, existe uma tendência de que o desempenho melhore à medida que se aumenta o número de neurônios ocultos. Porém, se esse número for muito grande, o treinamento se torna mais lento e tende a ser interrompido por *overfitting* mais frequentemente. Por isso, o desempenho pode piorar quando se utiliza neurônios ocultos excessivos.

Tabela 4 – Desempenho das redes para diferentes números de neurônios na camada oculta.

Neurônios Ocultos	EQM $[(^\circ\text{C})^2]$	Neurônios Ocultos	EQM $[(^\circ\text{C})^2]$
1	1,3305	5	0,1268
2	0,3924	6	0,1018
3	0,1734	7	0,1298
4	0,1584	8	0,1182

A rede que apresentou o melhor desempenho foi aquela composta de seis neurônios na camada oculta. A estrutura da rede final pode ser encontrada na Figura 25. Os nós

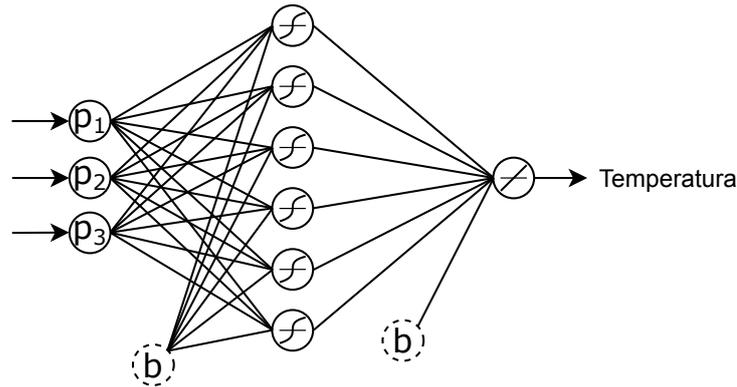
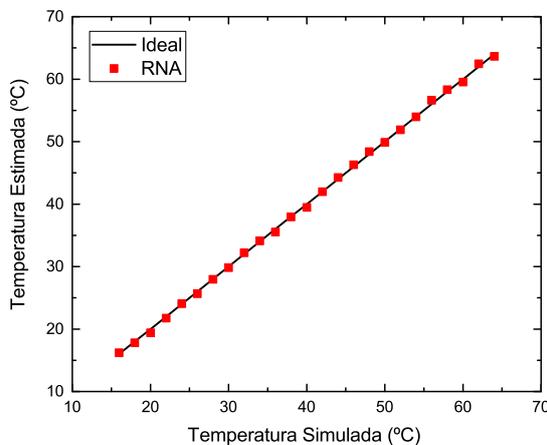
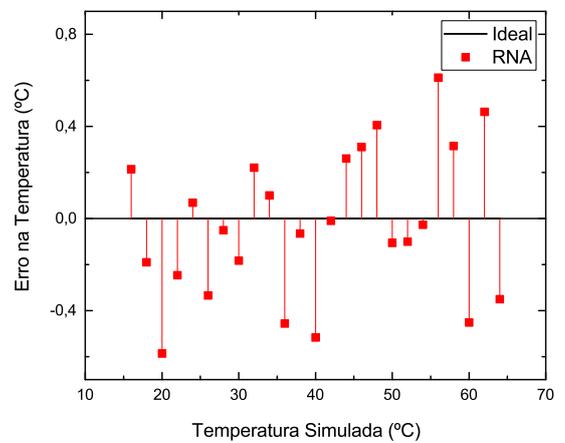


Figura 25 – Estrutura da rede escolhida.



(a)



(b)

Figura 26 – Desempenho do interrogador baseado em rede neural com 6 neurônios na camada oculta. (a) Resposta à temperatura. (b) Residual.

de entrada recebem as potências p_1 , p_2 e p_3 , vindas do OptiSystem, que passam por um processo de normalização. A rede possui conectividade completa e todos os neurônios estão ligados a um *bias*. Cada uma das conexões tem um peso específico, não mostrado na figura, definido pelo algoritmo de treinamento. Dentro de cada neurônio está ilustrada a sua função de ativação. Na última camada, a saída é um valor normalizado ao intervalo $[-1,1]$, que passa por um processo de desnormalização para gerar a estimativa da temperatura medida pelo sensor.

A RNA mostrou excelente desempenho em identificar a temperatura a partir das potências ópticas nas sub-bandas, como pode ser visto na Figura 26a, feita utilizando-se o conjunto de dados de teste aplicado à melhor rede encontrada. O residual correspondente encontra-se na Figura 26b.

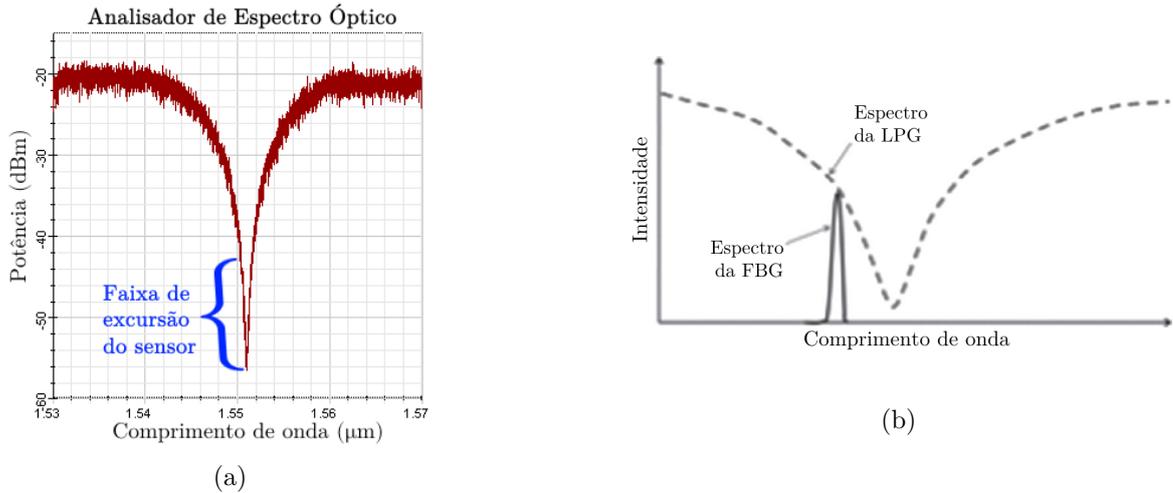


Figura 27 – Utilização de LPG para interrogação. (a) Faixa espectral de uma LPG que pode ser utilizada para interrogar um sensor FBG. (b) Interação entre os dois espectros.

Fonte: (b) [1] (Adaptada)

4.2 COMPARATIVO DAS TÉCNICAS DE INTERROGAÇÃO

Para fornecer uma comparação com métodos tradicionais, foi considerado também um outro sistema de interrogação mais tradicional: a saída do sensor é filtrada por uma LPG e coletada por um fotodetector. Essa técnica de interrogação foi apresentada em [80]. Ao excursionar a curva da LPG, o comprimento de onda do pico de ressonância do sensor é codificado em termos da potência óptica coletada pelo fotodetector. A faixa de temperatura escolhida pode ser interrogada projetando-se a LPG apropriadamente. A Figura 27a mostra a região espectral da LPG de interesse para a interrogação. A Figura 27b ilustra o efeito da excursão de um espectro sobre o outro.

A Figura 28a mostra a resposta do sistema para diversas temperaturas do grupo de testes, utilizando diferentes métodos de interrogação. A Figura 28b mostra o erro em utilizar cada técnica. A Tabela 5 mostra um resumo comparativo dos métodos de interrogação testados. As figuras e a tabela mostram que a estimativa feita pela RNA é melhor que aquela baseada no ajuste polinomial e, ainda, que ambas são muito superiores ao método baseado em LPG e àquele baseado em inferência *fuzzy*.

Tabela 5 – Resumo do desempenho das técnicas de interrogação.

Método	EQM $[(^{\circ}\text{C})^2]$	Mínimo Erro Absoluto ($^{\circ}\text{C}$)	Máximo Erro Absoluto ($^{\circ}\text{C}$)	Erro Absoluto Médio ($^{\circ}\text{C}$)
LPG	1,4105	0,0214	2,5907	0,9509
Polinomial	0,3314	0,0510	1,3286	0,4481
FIS	0,8802	0,0263	2,0471	0,7193
RNA	0,1018	0,0099	0,6120	0,2659

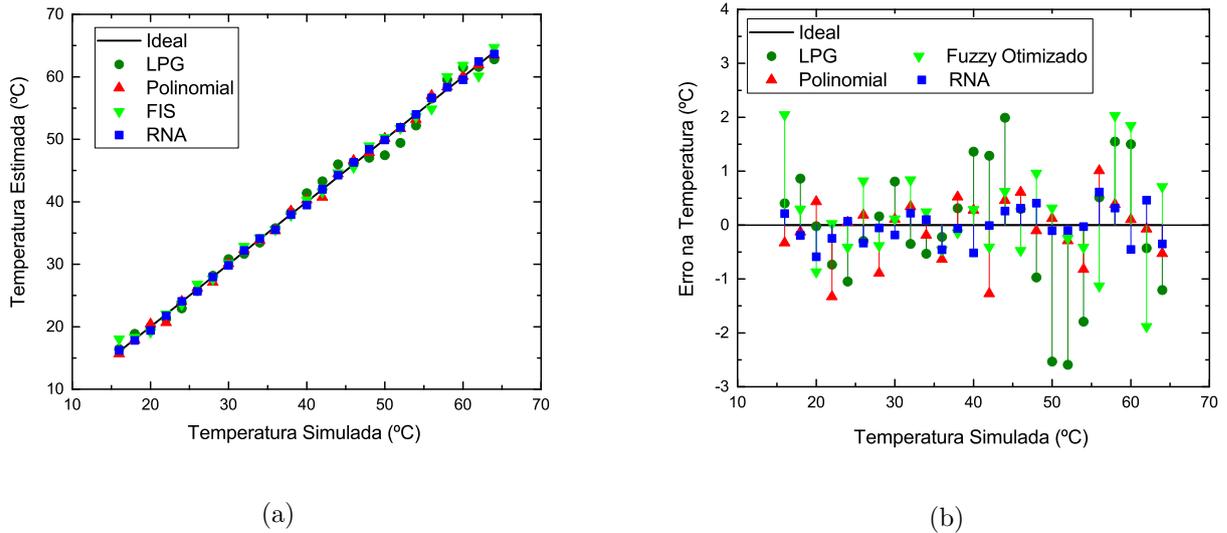


Figura 28 – Comparativo do desempenho dos interrogadores. (a) Respostas à temperatura. (b) Residuais.

4.3 DESEMPENHO EM SISTEMAS RUIDOSOS

Para avaliar melhor a qualidade dos métodos propostos, foi feita uma análise adicionando-se ruído aos valores dos fotodetectores. O ruído utilizado nas simulações foi Gaussiano. As propostas selecionadas para essa análise foram aquelas com melhor desempenho nos sistemas sem ruído, ou seja, os métodos baseados em ajuste polinomial e em RNA. Foram feitas 500 simulações para cada valor de temperatura do grupo de teste. O erro médio e o desvio padrão das medidas foi calculado para cada temperatura. Por fim, foi analisado o valor médio do erro e do desvio padrão, considerando-se as diversas temperaturas. A Tabela 6 mostra o resultado dessa análise para alguns valores do desvio padrão do ruído na entrada do estágio de processamento. As Figuras 29 a 31 mostram exemplos da resposta dos dois sistemas na presença de ruído. A capacidade de generalização da RNA auxilia na manutenção da precisão, mesmo em sistemas consideravelmente ruidosos. Portanto, esse é o sistema proposto para prototipagem. Uma plataforma que se adequaria bem a essa prototipagem seria a FPGA, devido ao seu alto nível de paralelismo.

Tabela 6 – Desempenho das técnicas de interrogação em sistemas ruidosos.

Desvio Padrão na Entrada (dB)	Método	EQM $[(^{\circ}\text{C})^2]$	Desvio Padrão Médio ($^{\circ}\text{C}$)
0,1	Polinomial	0,3323	0,2314
	RNA	0,1029	0,2067
0,5	Polinomial	0,3330	1,1616
	RNA	0,1035	1,0366
1,0	Polinomial	0,3437	2,3433
	RNA	0,1063	2,0782

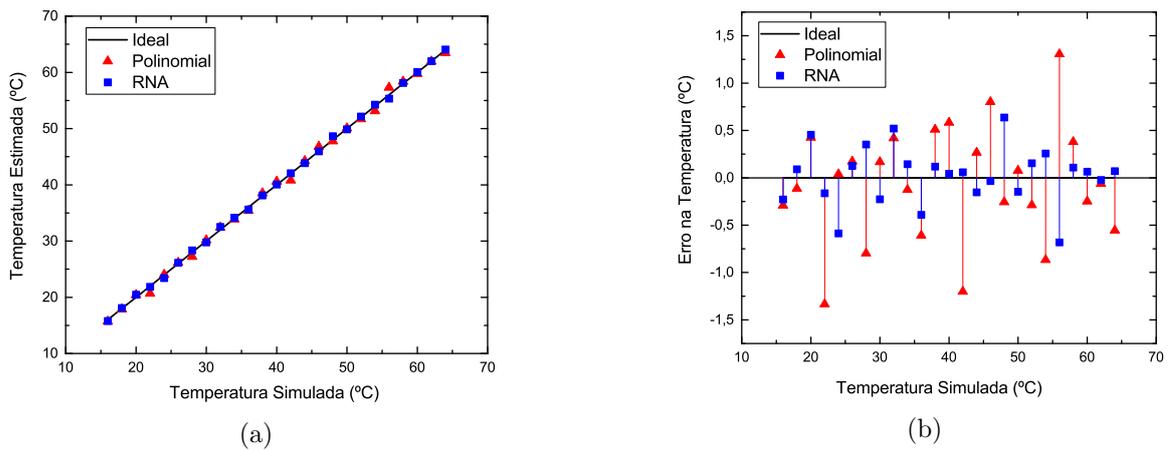


Figura 29 – Desempenho dos interrogadores em sistemas sujeitos a ruído com desvio padrão de 0,1 dB. (a) Respostas à temperatura. (b) Residuais.

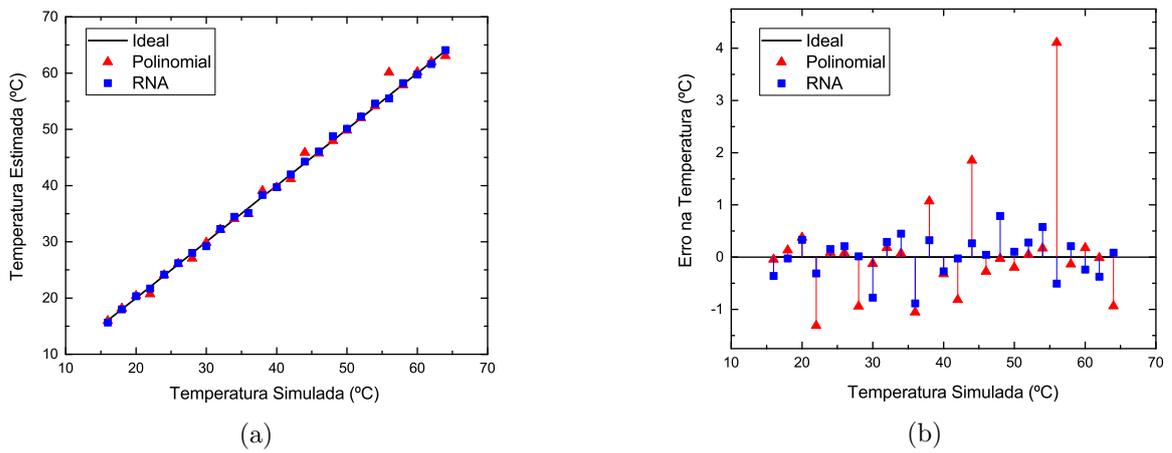


Figura 30 – Desempenho dos interrogadores em sistemas sujeitos a ruído com desvio padrão de 0,5 dB. (a) Respostas à temperatura. (b) Residuais.

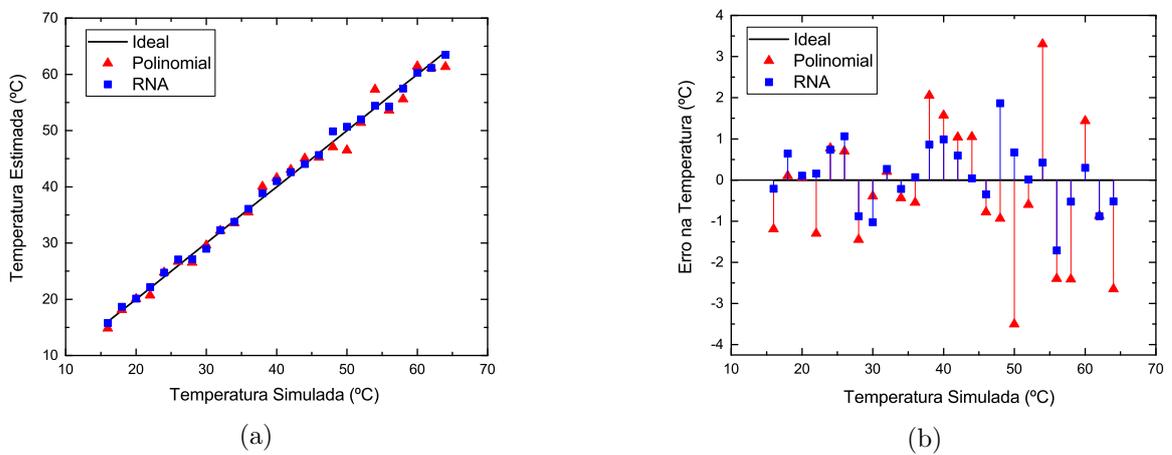


Figura 31 – Desempenho dos interrogadores em sistemas sujeitos a ruído com desvio padrão de 1 dB. (a) Respostas à temperatura. (b) Residuais.

5 CONCLUSÕES

Neste trabalho, foram desenvolvidos três sistemas de interrogação para um sensor de temperatura em FBG, que foram testados em simulação, comparando-os com um sistema tradicional. O projeto dos sistemas de interrogação foi baseado em um sensor FBG cuja faixa de temperaturas varia entre 15 °C e 65 °C, como pode ser utilizado no monitoramento de equipamentos eletrônicos. O princípio de funcionamento dos sistemas fundamenta-se na filtragem da saída do sensor em diversas sub-bandas, utilizando filtros ópticos também baseados em FBGs, e empregando fotodetectores para coletar a potência óptica e utilizá-la como entrada no estágio de processamento.

Os estágios de processamento são métodos computacionais que foram ajustados utilizando dados obtidos de simulações, e seus desempenhos foram testados utilizando um conjunto diferente de temperaturas simuladas. Os três sistemas mostraram bom desempenho em identificar a temperatura a partir das saídas dos fotodetectores, porém a RNA mostrou um resultado muito superior. Os sistemas propostos foram comparados com uma técnica tradicional e os resultados confirmam que uma melhora considerável foi alcançada em utilizar-se a rede neural, tanto em sistemas simples como em sistemas ruidosos. A análise foi feita com ruídos similares aos encontrados em sistemas ópticos reais e, em todos os casos, o desempenho da RNA mostrou-se superior. Os resultados apresentados evidenciam a possibilidade de aplicação prática do sistema baseado em RNA, fornecendo uma alternativa barata para a interrogação com precisão.

5.1 TRABALHOS FUTUROS

Em trabalhos futuros, novas técnicas computacionais podem ser analisadas e ter seu desempenho comparado com aqueles exibidos neste trabalho. Além disso, as técnicas apresentadas podem ser analisadas de forma mais profunda. Com um conjunto de dados consideravelmente maior, podem-se encontrar aproximações polinomiais de grau maior que aqueles apresentados e que apresentem um melhor desempenho. O sistema baseado em FIS pode ser analisado variando-se o número e o formato das funções de pertinência, além da base de regras.

É importante notar que o sensor utilizado neste trabalho é apenas um exemplo do potencial do sistema proposto. Futuramente, pode-se conduzir uma investigação mais profunda da relação exata entre o espaçamento dos filtros e a resolução do interrogador, ou entre a quantidade de filtros e a faixa dinâmica do sistema.

Em relação ao sistema proposto, o próximo passo será implementar a RNA e testar o desempenho do sistema na prática, sujeito a variações de temperatura, sensibilidade cruzada no sensor, instabilidade na fonte e outras perturbações no ambiente, com o objetivo de projetar uma rede capaz de atenuar o efeito dessas perturbações.

REFERÊNCIAS

- [1] RAJAN, G. (Ed.). *Optical Fiber Sensors: Advanced Techniques and Applications*. Boca Raton, FL: CRC Press, 2015. (Devices, Circuits and Systems).
- [2] JUCÁ, M. A.; SANTOS, A. B. dos. Fiber Bragg grating interrogation using FBG filters and artificial neural network. In: *International Microwave and Optoelectronics Conference (IMOC)*. Águas de Lindoia: [s.n.], 2017.
- [3] DELGADO, F. S. et al. Propagation characteristics of optical long period fiber gratings using graphical solution methods. *Journal of Microwaves, Optoelectronics and Electromagnetic Applications*, v. 15, n. 2, p. 135–145, jun. 2016.
- [4] DELGADO, F. S. et al. Optical fiber-based sensor for assessing electric current in unmanned aerial vehicles with ROS interface. In: *International Conference on Robotics and Automation (ICRA)*. Brisbane: [s.n.], 2018.
- [5] COELHO, T. V. N. et al. A numerical and experimental study of the remote long-period grating fiber sensor with Raman amplification. In: *2015 SBMO/IEEE MTT-S International Microwave and Optoelectronics Conference (IMOC)*. Porto de Galinhas: [s.n.], 2015. p. 1–6.
- [6] VIEGAS, D. et al. Long-period grating fiber sensor with in situ optical source for remote sensing. *IEEE Photonics Technology Letters*, v. 22, n. 20, p. 1533–1535, out. 2010.
- [7] WEI, L. et al. Tunable multimode fiber based filter and its application in cost-effective interrogation of fiber-optic temperature sensors. *IEEE Photonics Journal*, v. 9, n. 2, abr. 2017.
- [8] DÍAZ-HERRERA, N. et al. Fibre-optic SPR sensor with a FBG interrogation scheme for readout enhancement. *Sensors and Actuators B: Chemical*, v. 144, n. 1, p. 226–231, jan. 2010.
- [9] GIORDANA, A. A.; SICRE, E. E.; DUCHOWICZ, R. Simple wavelength-to-phase mapping FBG's interrogation method. *Optics and Lasers in Engineering*, v. 55, p. 221–225, abr. 2014.
- [10] MAHMOUD, M. Design and modeling of compact-size environmental telemetry station based on passive optical sensors and fuzzy logic control. *Proceedings of SPIE*, v. 5073, n. Thermosense XXV, p. 469–475, abr. 2003.
- [11] NASO, D.; TURCHIANO, B.; PANTALEO, P. A fuzzy-logic based optical sensor for online weld defect-detection. *IEEE Transactions on Industrial Informatics*, v. 1, n. 4, p. 259–273, nov. 2005.
- [12] LEWIS, E. et al. Principal component analysis and artificial neural network based approach to analysing optical fibre sensors signals. *Sensors and Actuators, A: Physical*, v. 136, n. 1, p. 28–38, maio 2007.
- [13] JIANG, M. et al. CFRP damage identification system by using FBG sensor and RBF neural network. In: *2015 IEEE 10th Conference on Industrial Electronics and Applications (ICIEA)*. Auckland: [s.n.], 2015. p. 1487–1490.

- [14] NEGRI, L. et al. FBG refractometry and electrical impedance analysis in fuel samples characterization. In: *2011 SBMO/IEEE MTT-S International Microwave and Optoelectronics Conference (IMOC)*. Natal: [s.n.], 2011. p. 867–871.
- [15] KAHANDAWA, G. C. et al. Estimation of strain of distorted FBG sensor spectra using a fixed FBG filter circuit and an artificial neural network. In: *2013 IEEE Eighth International Conference on Intelligent Sensors, Sensor Networks and Information Processing*. Melbourne, VIC: [s.n.], 2013. p. 89–94.
- [16] KEISER, G. *Optical Fiber Communications*. 4th. ed. [S.l.]: McGraw-Hill, 2008.
- [17] MARCUSE, D. *Theory of Dielectric Optical Waveguides*. 2nd. ed. New York: Academic, 1991.
- [18] KAWANO, K.; KITO, T. *Introduction to Optical Waveguide Analysis: Solving Maxwell's Equation and the Schrödinger Equation*. Hoboken, NJ: Wiley, 2002.
- [19] SNITZER, E. Cylindrical dielectric waveguide modes. *Journal of the Optical Society of America*, v. 51, p. 491–498, maio 1961.
- [20] KOSHIBA, M. *Optical Waveguide Analysis*. New York: McGraw-Hill, 1992.
- [21] MARCUSE, D. *Light Transmission Optics*. 2nd. ed. New York: Van Nostrand-Reinhold, 1982.
- [22] OLSHANSKY, R. Propagation in glass optical waveguides. *Reviews of Modern Physics*, v. 51, p. 341–367, abr. 1979.
- [23] GLOGE, D. The optical fiber as a transmission medium. *Reports on Progress in Physics*, v. 42, p. 1777–1824, nov. 1979.
- [24] KEISER, G. *Optical Communications Essentials*. [S.l.]: McGraw-Hill, 2003.
- [25] SNYDER, A. W. Asymptotic expressions for eigenfunctions and eigenvalues of a dielectric or optical waveguide. *IEEE Transactions on Microwave Theory and Techniques*, MTT-17, p. 1130–1138, dez. 1969.
- [26] GLOGE, D. Weakly guiding fibers. *Applied Optics*, v. 10, p. 2252–2258, out. 1971.
- [27] MARCUSE, D. Gaussian approximation of the fundamental modes of graded index fibers. *Journal of the Optical Society of America*, v. 68, p. 103–109, jan. 1978.
- [28] DERUITER, H. M. Integral equation approach to the computation of modes in an optical waveguide. *Journal of the Optical Society of America*, v. 70, p. 1519–1524, dez. 1980.
- [29] YIN, S.; RUFFIN, P. B.; YU, F. T. S. (Ed.). *Fiber Optic Sensors*. 2nd. ed. Boca Raton, FL: CRC Press, 2008. v. 76. (Optical Science and Engineering, v. 76).
- [30] LEE, B. Review of the present status of optical fiber sensors. *Optical Fiber Technology*, v. 9, n. 2, p. 57–79, abr. 2003.
- [31] JAMES, S. W.; TATAM, R. P. Optical fibre long-period grating sensors: characteristics and application. *Measurement Science and Technology*, v. 14, n. 5, p. R49–R61, mar. 2003.

- [32] KASHYAP, R. *Fiber Bragg Gratings*. San Diego, CA: Academic Press, 1999. (Optics and Photonics).
- [33] GRATAN, K. T. V.; MEGGITT, B. T. (Ed.). *Optical Fiber Sensor Technology: Advanced Applications - Bragg Gratings and Distributed Sensors*. New York: Springer, 2000.
- [34] MIAO, Y.-P.; LIU, B.; ZHAO, Q.-D. Refractive index sensor based on measuring the transmission power of tilted fiber bragg grating. *Optical Fiber Technology*, v. 15, n. 3, p. 233–236, jun. 2009.
- [35] SHENG, H.-J. et al. High-sensitivity temperature-independent differential pressure sensor using fiber bragg gratings. *Optics Express*, v. 16, n. 20, p. 16013–16018, set. 2008.
- [36] GANGOPADHYAY, T. K. Prospects for fibre bragg gratings and fabry–perot interferometers in fibre-optic vibration sensing. *Sensors and Actuators A: Physical*, v. 113, n. 1, p. 20–38, jun. 2004.
- [37] SU, Y. et al. Use of the polarization properties of magneto-optic fiber bragg gratings for magnetic field sensing purposes. *Optical Fiber Technology*, v. 17, n. 3, maio 2011.
- [38] SHAO, M. et al. Humidity sensor based on hybrid fiber Bragg grating/abrupt fiber taper. *IEEE Sensors Journal*, v. 17, n. 5, p. 1302–1305, mar. 2017.
- [39] WOYESSA, G. et al. Low loss polycarbonate polymer optical fiber for high temperature FBG humidity sensing. *IEEE Photonics Technology Letters*, v. 29, n. 7, p. 575–578, abr. 2017.
- [40] LI, T. et al. Fiber Bragg grating sensing-based online torque detection on coupled bending and torsional vibration of rotating shaft. *IEEE Sensors Journal*, v. 17, n. 7, p. 1999–2007, abr. 2017.
- [41] LI, T. et al. Paralleled structure-based string-type fiber Bragg grating acceleration sensor. *IEEE Sensors Journal*, v. 17, n. 5, p. 1325–1332, mar. 2017.
- [42] RONG, Q. et al. Ultrasonic imaging of seismic physical models using fiber Bragg grating Fabry-Perot probe. *IEEE Journal of Selected Topics in Quantum Electronics*, v. 23, n. 2, Mar-Apr 2017.
- [43] LOPEZ-HIGUERA, J. M. (Ed.). *Handbook of Optical Fibre Sensing Technology*. [S.l.]: Wiley, 2002.
- [44] VENGSARKAR, A. M. et al. Long-period fiber gratings as band-rejection filters. *Journal of Lightwave Technology*, v. 14, n. 1, p. 58–65, jan. 1996.
- [45] BHATIA, V.; VENGSARKAR, A. M. Optical fiber long-period grating sensors. *Optics Letters*, v. 21, n. 9, p. 692–694, maio 1996.
- [46] HILL, K. O.; MELTZ, G. Fiber bragg grating technology fundamentals and overview. *Journal of Lightwave Technology*, v. 15, n. 8, p. 1263–1276, ago. 1997.
- [47] VASILIEV, S. A.; MEDVEDKOV, O. I. Long-period refractive index fiber gratings: Properties, applications, and fabrication techniques. *Proceedings of SPIE Advances in Fiber Optics*, v. 4083, p. 212–223, maio 2000.

- [48] ERDOGAN, T. Fiber grating spectra. *Journal of Lightwave Technology*, v. 15, n. 8, p. 1277–1294, ago. 1997.
- [49] ERDOGAN, T. Cladding-mode resonances in short- and long-period fiber grating filters. *Journal of the Optical Society of America*, v. 14, n. 8, p. 1760–1773, ago. 1997.
- [50] ERDOGAN, T. Cladding-mode resonances in short- and long-period fiber grating filters: errata. *Journal of the Optical Society of America*, v. 17, n. 11, p. 2113, nov. 2000.
- [51] SINGH, R.; KUMAR, H.; SHARMA, E. K. Design of long-period gratings: necessity of a three-layer fiber geometry for cladding mode characteristics. *Microwave and Optical Technology Letters*, v. 37, n. 1, p. 45–49, abr. 2003.
- [52] YUAN, Y. Cladding mode resonances in short- and long-fiber grating filters: comment. *Journal of the Optical Society of America*, v. 26, n. 10, p. 2199–2201, out. 2009.
- [53] SINGH, A.; ENGLER, D. Calculation of cladding modes using both two layer and three layer geometry in lpfg. *Optik*, v. 124, n. 21, p. 5042–5045, nov. 2013.
- [54] SINGH, A. Study of modeling aspects of long period fiber grating using three-layer fiber geometry. *Photonic Sensors*, v. 5, n. 1, p. 32–42, mar. 2015.
- [55] VENGSARKAR, A. et al. Long-period fiber-grating-based gain equalizers. *Optics Letters*, v. 21, n. 5, p. 336–338, mar. 1996.
- [56] ESPOSITO, F. et al. Experimental study of the refractive index sensitivity in arc-induced long period gratings. *IEEE Photonics Journal*, v. 9, n. 1, fev. 2017.
- [57] NIDHI; KALER, R. S.; KAPUR, P. Theoretical and experimental study of long-period grating refractive index sensor. *Fiber and Integrated Optics*, v. 33, n. 1-2, p. 37–46, 2014.
- [58] NAIR, A. S.; KUMAR, V. P. S.; JOE, H. Twist sensitivity of cladding-mode resonances and its cross-sensitivity to strain and temperature in a mechanically induced long-period fiber grating. *Fiber and Integrated Optics*, v. 33, n. 5-6, p. 347–359, 2014.
- [59] ALVARENGA, I. et al. A novel experimental set-up for turbidity sensing based on plastic optical fibre. *Journal of Modern Optics*, v. 64, n. 3, p. 214–217, 2016.
- [60] ALVARENGA, I. et al. Water salinity measurement using long period gratings. In: *12^o CBMag - Congresso Brasileiro de Eletromagnetismo; 17^o SBMO - Simpósio Brasileiro de Micro-ondas e Optoeletrônica e LAWOFs 2016 - Latin American Workshop on Optical Fiber Sensors*. Porto Alegre: [s.n.], 2016.
- [61] YANG, J. et al. Long-period fiber grating sensor with a styrene-acrylonitrile nano-film incorporating cryptophane a for methane detection. *Optics Express*, v. 19, n. 15, p. 14696–14706, jul. 2011.
- [62] JUCÁ, M. A. et al. Investigation of carbon dioxide sensitivity in long period gratings. In: *12^o CBMag - Congresso Brasileiro de Eletromagnetismo; 17^o SBMO - Simpósio Brasileiro de Micro-ondas e Optoeletrônica e LAWOFs 2016 - Latin American Workshop on Optical Fiber Sensors*. Porto Alegre: [s.n.], 2016.
- [63] DELGADO, F. S. et al. Mathematical modelling for correlation between temperature and mechanical strain in long period gratings. In: *2014 IEEE Sensors*. Valencia: [s.n.], 2014. p. 1900–1903.

- [64] DELGADO, F. S.; SANTOS, A. B. dos. Multi-measurement scheme for a fiber-optic sensor based on a single long-period grating. *Journal of Modern Optics*, v. 64, n. 21, p. 2428–2432, ago. 2017.
- [65] STIGLER, S. M. Gauss and the invention of least squares. *The Annals of Statistics*, v. 9, n. 3, p. 465–474, maio 1981.
- [66] LEGENDRE, A. M. *Nouvelles méthodes pour la détermination des orbites des comètes*. Paris: F. Didot, 1805.
- [67] BRETSCHER, O. *Linear Algebra with Applications*. 5th. ed. Upper Saddle River, NJ: Pearson, 2013.
- [68] CHAPRA, S.; CANALE, R. *Numerical Method for Engineers: With Software and Programming Applications*. 7th. ed. New York, NY: McGraw-Hill, 2014.
- [69] KLIR, G. J.; YUAN, B. *Fuzzy Sets and Fuzzy Logic: Theory and Applications*. Upper Saddle River, NJ: Prentice Hall, 1995.
- [70] ZADEH, L. A. Fuzzy sets. *Information and Control*, v. 8, p. 338–353, 1965.
- [71] PEDRYCZ, W.; GOMIDE, F. *Fuzzy Systems Engineering: Toward Human-Centric Computing*. Hoboken, NJ: John Wiley & Sons, 2007.
- [72] ROSS, T. J. *Fuzzy Logic with Engineering Applications*. 4th. ed. [S.l.]: Wiley, 2017.
- [73] FAUSETT, L. *Fundamentals of Neural Networks: Architectures, Algorithms and Applications*. Upper Saddle River, NJ: Prentice Hall, 1993.
- [74] BRAGA, A. P.; CARVALHO, A. P. L. F. de; LUDERMIR, T. B. *Redes Neurais Artificiais: Teoria e Aplicações*. Rio de Janeiro: LTC, 2000.
- [75] HERTZ, J.; KROGH, A.; PALMER, R. G. *Introduction to the Theory of Neural Computation*. Boca Raton, FL: CRC Press, 2018.
- [76] SILVA, I. N. da et al. *Artificial Neural Networks: A Practical Course*. [S.l.]: Springer, 2017.
- [77] HAYKIN, S. *Neural Networks and Learning Machines*. 3rd. ed. Upper Saddle River, NJ: Prentice Hall, 2008.
- [78] YANG, X.-S. A new metaheuristic bat-inspired algorithm. In: GONZALEZ, J. R. et al. (Ed.). *Nature Inspired Cooperative Strategies for Optimization (NICSO 2010)*. Berlin: Springer, 2010. (Studies in Computational Intelligence, v. 284), p. 65–74.
- [79] XIN-SHE; HE, X. Bat algorithm: Literature review and applications. *International Journal of Bio-Inspired Computation*, v. 5, n. 3, p. 141–149, ago. 2013.
- [80] FALLON, R. W. et al. All-fibre optical sensing system: Bragg grating sensor interrogated by a long-period grating. *Measurement Science and Technology*, v. 9, n. 12, p. 1969–1973, dez. 1998.