

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
FACULDADE DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Marco Aurélio Jucá da Silva Junior

Aplicações de Técnicas Computacionais à Interrogação de Sensores Ópticos
Baseados em Grades de Período Longo

Juiz de Fora

2023

Marco Aurélio Jucá da Silva Junior

**Aplicações de Técnicas Computacionais à Interrogação de Sensores Ópticos
Baseados em Grades de Período Longo**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Doutor em Engenharia Elétrica. Área de concentração: Sistemas Eletrônicos

Orientador: Prof. Dr. Alexandre Bessa dos Santos

Juiz de Fora

2023

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

Jucá, Marco Aurélio.

Aplicações de Técnicas Computacionais à Interrogação de Sensores Ópticos Baseados em Grades de Período Longo / Marco Aurélio Jucá da Silva Junior. – 2023.

130 f. : il.

Orientador: Alexandre Bessa dos Santos

Tese (Doutorado) – Universidade Federal de Juiz de Fora, Faculdade de Engenharia. Programa de Pós-Graduação em Engenharia Elétrica, 2023.

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

Marco Aurélio Jucá da Silva Junior

Aplicações de Técnicas Computacionais à Interrogação de Sensores Ópticos Baseados em Grades de Período Longo

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Doutor em Engenharia Elétrica. Área de concentração: Sistemas Eletrônicos

Aprovada em 28 de abril de 2023.

BANCA EXAMINADORA

Prof. Dr. Alexandre Bessa dos Santos - Orientador

Universidade Federal de Juiz de Fora

Prof. Dr. André Luis Marques Marcato

Universidade Federal de Juiz de Fora

Prof. Dr. Ulysses Roberto Chaves Vitor

Universidade Federal de Juiz de Fora

Prof. Dr. Marcelo Eduardo Vieira Segatto

Universidade Federal do Espírito Santo

Prof. Dr. José Luís Fabris

Universidade Tecnológica Federal do Paraná



Documento assinado eletronicamente por **Alexandre Bessa dos Santos, Professor(a)**, em 28/04/2023, às 20:45, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **José Luís Fabris, Usuário Externo**, em 29/04/2023, às 10:21, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Marcelo Eduardo Vieira Segatto, Usuário Externo**, em 02/05/2023, às 07:43, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Ulysses Roberto Chaves Vitor, Professor(a)**, em 02/05/2023, às 09:13, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Andre Luis Marques Marcato, Professor(a)**, em 27/06/2023, às 20:58, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no Portal do SEI-Ufjf (www2.ufjf.br/SEI) através do ícone Conferência de Documentos, informando o código verificador **1229018** e o código CRC **5EDEF966**.

AGRADECIMENTOS

Agradeço a Deus por todas as oportunidades que me foram oferecidas e por ter tido condições de chegar até aqui.

Agradeço à minha mãe, Adriana, e ao meu pai, Marco Aurélio[†], por me apoiarem e me incentivarem desde cedo a aprender, a pesquisar, a ler, a ir além da superficialidade e a buscar meus objetivos.

Agradeço à minha esposa, Laís, por partilhar comigo os desafios de um processo de doutoramento, por oferecer suporte e incentivo quando eu precisei, e por estar ao meu lado, confiante no sucesso deste trabalho.

Agradeço aos meus familiares e amigos, e, em especial, ao meu irmão, Bruno, pela compreensão com a minha ausência nos últimos meses, pela paciência e pelo apoio.

Agradeço ao professor Alexandre Bessa, com quem aprendi muito durante os últimos anos, pela orientação sempre competente, desde a iniciação científica, pela confiança no meu trabalho e pelo incentivo para que eu continuasse progredindo.

Agradeço ao professor Diego Haddad, que deu contribuições valiosas para este trabalho, pela dedicação e pelo empenho em fazer a pesquisa avançar.

Agradeço a todos os professores e professoras que, ao longo dos anos, deixaram suas contribuições para minha formação.

Agradeço aos estudantes que participaram dos grupos de pesquisa envolvidos neste trabalho. Aos alunos Isaac G. Y. Rabello, Luiz Miguel B. Silva e Pedro C. Guamá Spelta, que participaram da criação das primeiras versões do simulador apresentado no Apêndice A. E à aluna Isabela V. C. Pereira e ao aluno Pedro C. Guamá Spelta, que realizaram a coleta de dados nos experimentos com reflectometria.

Agradeço aos colegas da unidade Petrópolis do Centro Federal de Educação Tecnológica Celso Suckow da Fonseca (CEFET/RJ), que se tornaram grandes amigos e sempre me ofereceram palavras de apoio e de incentivo, por fazerem com que eu me sentisse acolhido pelo grupo em todos os momentos.

Agradeço ao CEFET/RJ por ter me concedido afastamento das atividades docentes durante a parte final do doutorado, o que foi essencial para que eu conseguisse concluir este trabalho.

Por fim, sou muito grato à Universidade Federal de Juiz de Fora (UFJF). A conclusão do doutorado encerra um ciclo de 11 anos na UFJF, desde o início da graduação. A Universidade e toda a sua estrutura, dos restaurantes aos ônibus circulares, das bibliotecas aos laboratórios, fizeram parte da minha vida e deixaram marcas profundas na pessoa que me tornei.

“N3o importa ao tempo o minuto que passa, mas o minuto que vem.”
(Machado de Assis, 2019, p. 43)

RESUMO

A aplicação de técnicas computacionais, processamento de sinais e extração de características à interrogação de sensores ópticos baseados em grades de período longo é objeto de intenso desenvolvimento de pesquisa recente e ainda demanda aprofundamento. Considerando a aplicação cada vez mais ampla de sensores a fibra óptica, este trabalho visa apresentar formas alternativas de interrogação que não dependam da análise espectral ou de equipamentos de alto custo. Duas propostas são apresentadas. A primeira é baseada na separação do sinal do sensor em sub-bandas espectrais e posterior análise da potência óptica de cada sub-banda por uma rede neural artificial. A segunda proposta é baseada na extração de características aplicada a traços de reflectometria medidos em fibras contendo grades de período longo e na utilização de descritores de características como variáveis explicativas em um algoritmo de regressão linear múltipla. Ambas as propostas se valem de métodos computacionais para atingir o objetivo de recuperar a informação coletada pelo sensor e fornecê-la em um formato adequado. Os resultados obtidos indicam que os métodos propostos, com configurações experimentais simples, apresentam desempenhos melhores que os de métodos similares, ou apresentam desempenho comparável adicionando as vantagens inerentes ao sensoriamento a fibra.

Palavras-chave: Grades de período longo. Instrumentação óptica. Interrogação. Métodos computacionais. Sensores a fibras ópticas.

ABSTRACT

The application of computational techniques, signal processing and feature extraction to the interrogation of optical sensors based on long-period gratings is the object of intensive development of recent research and still requires advancement. Considering the increasingly wide application of optical fiber sensors, this work aims to present alternative forms of interrogation which do not rely on spectral analysis or high-cost devices. Two proposals are presented. The first one is based on the separation of the sensor signal in spectral sub-bands and the ensuing analysis of the optical power in each sub-band by an artificial neural network. The second proposal is based on feature extraction applied on reflectometry traces measured from fibers containing long-period gratings and on the use of feature descriptors as explanatory variables in a multiple linear regression algorithm. Both proposals rely on computational methods in order to achieve the goal of recovering the information collected by the sensor and making it available in a suitable format. The obtained results indicate that the proposed methods, with simple experimental setups, present better performance than similar methods, or present comparable performance while adding the inherent advantages of in-fiber sensing.

Keywords: Computational methods. Interrogation. Long period gratings. Optical instrumentation. Optical fiber sensors.

LISTA DE FIGURAS

Figura 1	– Estrutura de uma fibra óptica convencional.	18
Figura 2	– Campo transversal no modo LP fundamental de núcleo.	22
Figura 3	– Perfil radial do campo transversal nos modos LP de casca.	24
Figura 4	– Intensidade do campo transversal ao longo da seção reta da fibra nos modos LP de casca.	25
Figura 5	– Constantes de acoplamento normalizadas de modos LP em uma fibra monomodo padrão.	26
Figura 6	– Estrutura de uma grade de Bragg.	29
Figura 7	– Espectros resultantes do funcionamento de uma FBG.	29
Figura 8	– Simulação dos espectros de reflexão e de transmissão de uma FBG.	30
Figura 9	– Espectro resultante do funcionamento de uma LPG.	32
Figura 10	– Característica espectral de transmissão de luz por uma LPG.	32
Figura 11	– Resposta espectral de uma LPG.	34
Figura 12	– Modelo não linear de um neurônio.	38
Figura 13	– Tipos de função de ativação.	39
Figura 14	– Tipos de arquitetura de rede.	41
Figura 15	– Configuração do sensor e do interrogador baseado em três filtros.	53
Figura 16	– RNA com três entradas e três neurônios na camada oculta.	56
Figura 17	– Estimacão de temperatura do sistema de interrogacão composto por sete filtros usando seis neurônios na camada oculta.	59
Figura 18	– Valores de entrada normalizados da RNA.	60
Figura 19	– Ilustracão da montagem.	63
Figura 20	– Resposta espectral da fonte de luz e da LPG.	65
Figura 21	– Traço de OTDR no sistema em repouso.	66
Figura 22	– Montagem experimental.	67
Figura 23	– Traço no entorno do sensor para diferentes cargas.	68
Figura 24	– Resultados da aplicacão dos descritores de acordo com o método proposto.	71
Figura 25	– Validacão cruzada <i>k-fold</i> : desempenho de classificacão médio no <i>fold</i> de teste usando as <i>L</i> variáveis mais relevantes.	72
Figura 26	– Resultados do classificador com $L = 5$, calculados no conjunto de teste.	73
Figura 27	– Traços de OTDR que são a base para a análise proposta.	79
Figura 28	– Classificadores lineares baseados em apenas um descritor.	80
Figura 29	– Espectros de transmissão da LPG utilizada e de emissão da fonte do OTDR.	85
Figura 30	– Modelo da LPG e do seu invólucro.	85
Figura 31	– Montagem experimental durante uma medição.	86
Figura 32	– Traços de OTDR com a LPG sujeita a amostras de diferentes salinidades.	87
Figura 33	– Valores normalizados dos descritores de características.	90

Figura 34 – Pontuação dos modelos na validação cruzada <i>k-fold</i>	91
Figura 35 – Resultados da regressão e resíduos do modelo ajustado.	92
Figura 36 – Diagrama de classes do pacote de simulação GratingSim.	111
Figura 37 – Simulação do espectro de fontes.	117
Figura 38 – Perfil de índice de refração em uma fibra de índice degrau.	117
Figura 39 – Simulação de uma montagem simples.	121
Figura 40 – Simulação de uma montagem mais elaborada.	123
Figura 41 – Simulação do traço de OTDR de uma fibra.	123
Figura 42 – Simulação do traço de OTDR em fibra com emenda.	124
Figura 43 – Simulação do traço de OTDR em caminho com conectores	125
Figura 44 – Simulação do traço de OTDR em montagem com LPG.	126
Figura 45 – Simulação de um traço de OTDR de LPGs em cascata.	128
Figura 46 – Simulação dos traços de OTDR de um sensor LPG.	130

LISTA DE TABELAS

Tabela 1 – Comparação dos materiais de referência sobre modos de propagação.	21
Tabela 2 – Erro quadrático médio das RNAs treinadas para diferentes tamanhos da camada oculta.	58
Tabela 3 – Tipos de carga e suas massas e pesos.	67
Tabela 4 – Condições e limiares do classificador.	73
Tabela 5 – Índices de refração dos líquidos utilizados como amostras.	77
Tabela 6 – Comparação da média e do desvio padrão das saídas normalizadas dos descritores de características.	81
Tabela 7 – Comparação dos classificadores baseados em limiares de uma variável.	81
Tabela 8 – Coeficientes do modelo de regressão final.	92
Tabela 9 – Informação numérica sobre os resultados da regressão.	93

LISTA DE ABREVIATURAS E SIGLAS

CE	Centroide Espectral
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
FE	Fluxo Espectral
FPGA	<i>Field Programmable Gate Array</i> - Arranjo de Porta Programável em Campo
FWHM	<i>Full Width at Half Maximum</i> - Largura em Meia Potência
LITel	Laboratório de Instrumentação e Telemetria
LB	Largura de Banda
LED	<i>Light Emitting Diode</i> - Diodo Emissor de Luz
LP	Linearmente Polarizado
LPG	<i>Long-Period Grating</i> - Grade de Período Longo
MFCC	<i>Mel-Frequency Cepstrum Coefficients</i> - Coeficientes Mel-Cepstrais
MLP	<i>Multilayer Perceptron</i> - Perceptron Multicamadas
OSA	<i>Optical Spectrum Analyzer</i> - Analisador de Espectro Óptico
OTDR	<i>Optical Time-Domain Reflectometer</i> - Reflectômetro Óptico no Domínio do Tempo
PCA	<i>Principal Component Analysis</i> - Análise de Componentes Principais
PLA	<i>Polylactic Acid</i> - Polilático
PM	Potência Média
RMS	<i>Root Mean Square</i> - Raiz do Valor Quadrático Médio
RNA	Rede Neural Artificial
SLD	<i>Superluminescent Diode</i> - Diodo Superluminescente
TE	Transversal Elétrico
TM	Transversal Magnético
UFJF	Universidade Federal de Juiz de Fora
VQM	Valor Quadrático Médio
WDM	<i>Wavelength Division Multiplexing</i> - Multiplexação por Divisão de Comprimento de Onda
WLS	<i>White Light Source</i> - Fonte de Luz Branca

LISTA DE SÍMBOLOS

β	Constante de propagação
Δ	Diferença relativa de índices de refração
$\Delta\lambda_B$	Deslocamento no comprimento de onda de Bragg
$\Delta\lambda_\nu$	Deslocamento no comprimento de onda ressonante de ordem ν
$\Delta\ell$	Deformação
ΔT	Variação de temperatura
ϵ_0	Permissividade elétrica do vácuo
λ	Comprimento de onda
λ_B	Comprimento de onda de Bragg
λ_ν	Comprimento de onda central do vale de ressonância de ordem ν
Λ	Período da grade
μ_0	Permeabilidade magnética do vácuo
b	Índice efetivo normalizado
$J_i(\cdot)$	Função de Bessel da primeira espécie e ordem i
k_0	Número de onda no espaço livre
$K_i(\cdot)$	Função de Bessel modificada da segunda espécie e ordem i
n	Índice de refração
n_1	Índice de refração do núcleo
n_2	Índice de refração da casca
n_3	Índice de refração do meio externo
n_{eff}	Índice de refração efetivo
r_1	Raio do núcleo
r_2	Raio da casca
v_p	Velocidade de propagação da luz em um material
V	Frequência normalizada
$Y_i(\cdot)$	Função de Bessel da segunda espécie e ordem i

SUMÁRIO

1	INTRODUÇÃO	13
1.1	PUBLICAÇÕES CORRELACIONADAS	15
1.2	ESTRUTURA DA TESE	16
2	SENSORES EM FIBRAS ÓPTICAS	17
2.1	CONCEITOS BÁSICOS	17
2.2	MODOS DE PROPAGAÇÃO EM FIBRAS ÓPTICAS	19
2.3	GRADES DE DIFRAÇÃO EM FIBRAS	28
2.3.1	Grades de período curto	28
2.3.2	Grades de período longo	31
2.4	INTERROGAÇÃO DE SENSORES A FIBRA	33
3	FERRAMENTAS COMPUTACIONAIS	36
3.1	REDES NEURAIS ARTIFICIAIS	36
3.2	REGRESSÃO LINEAR MÚLTIPLA	43
3.3	EXTRAÇÃO DE CARACTERÍSTICAS	45
3.4	ANÁLISE DE COMPONENTES PRINCIPAIS	47
3.5	VALIDAÇÃO CRUZADA K-FOLD	51
4	SISTEMA DE INTERROGAÇÃO BASEADO EM BANCO DE FILTROS E REDE NEURAL ARTIFICIAL	52
4.1	CONFIGURAÇÃO DO SENSOR E DO INTERROGADOR	53
4.2	PRINCÍPIO DE INTERROGAÇÃO	53
4.3	A REDE NEURAL ARTIFICIAL	54
4.4	FAIXA DINÂMICA E EXATIDÃO	56
4.5	TESTES E RESULTADOS	57
4.6	DISCUSSÃO	60
5	SISTEMA DE INTERROGAÇÃO BASEADO EM REFLECTOME- TRIA ÓPTICA NO DOMÍNIO DO TEMPO	62
5.1	CONFIGURAÇÃO DO SENSOR E DO INTERROGADOR	63
5.2	INTERROGAÇÃO DE LPG BASEADA EM OTDR	64
5.3	CLASSIFICADOR DE PESOS	67
5.4	CLASSIFICADOR DE MEIOS	74
5.5	INTERROGADOR DE SALINIDADE	81
5.6	DISCUSSÃO	94
6	CONCLUSÃO	95
	REFERÊNCIAS	96
	APÊNDICE A – GratingSim	110

1 INTRODUÇÃO

Neste trabalho, o problema da interrogação de sensores a fibra óptica é analisado a partir de uma perspectiva multidisciplinar, envolvendo tanto conhecimentos de óptica quanto de processamento de sinais e de técnicas computacionais, e duas potenciais soluções são propostas. Interrogação é, resumidamente, o processo através do qual se obtêm ou se interpretam as leituras do sensor em termos de uma grandeza de interesse, fornecendo um resultado inteligível. O sensoriamento a que se refere este trabalho se deve ao efeito de grades de difração inscritas no interior das fibras, especialmente as grades de período longo fabricadas a partir da técnica de arco elétrico.

A história do desenvolvimento de sensores baseados em fibras ópticas é relativamente recente. A ideia de utilizar fibras ópticas como meio de sensoriamento remete à década de 1960, de acordo com Culshaw e Kersey [1]. Desde então, desenvolveram-se diferentes formas de utilizar luz ou fibras ópticas como parte de sistemas de sensoriamento de diversas grandezas. As primeiras evidências de que uma grade de difração poderia ser formada através da interação com a luz em uma fibra foram descobertas em 1978, por Hill *et al.* [2]. Em 1989, Meltz *et al.* apresentaram o método holográfico transversal para inscrição de grades em fibras [3]. Em 1996, Vengsarkar *et al.* publicaram o primeiro artigo relacionando as grades de período longo ao efeito de filtragem e de acoplamento a modos de casca copropagantes, incluindo uma demonstração do efeito de sensoriamento de deformação, de temperatura e de índice de refração [4]. Em 1998, a técnica de fabricação de grades de período longo utilizando-se laser de CO₂ foi apresentada por Davis *et al.* [5, 6]. Ao final da década de 1990, as bases da técnica de formação de grades de período longo por arco elétrico já estavam estabelecidas [7–10].

As décadas de pesquisas na área de sensoriamento com fibras ópticas levaram ao desenvolvimento de instrumentos de medição precisos, incluindo giroscópios, hidrofones, sensores de temperatura e detectores de substâncias químicas. Ao longo dos anos, a pesquisa em sensores a fibra óptica também se beneficiou dos avanços tecnológicos promovidos pelo rápido desenvolvimento dos sistemas de comunicação a fibras ópticas, como o próprio aprimoramento da qualidade da fibra, e sobretudo da redução de custos associada à ampla utilização dos componentes essenciais a sistemas ópticos, como as fontes de luz e os fotodetectores [11].

A partir das referidas melhorias na qualidade e no custo dos componentes, os sensores ópticos tornaram-se capazes de substituir, com vantagens, os sensores tradicionais de rotação, aceleração, campo elétrico e campo magnético, temperatura, pressão, acústica, vibração, posição linear e posição angular, deformação, umidade, viscosidade e substâncias químicas, entre outras aplicações [12]. Dentre as vantagens dos sensores ópticos em relação aos sensores tradicionais, destacam-se as seguintes: são leves e pequenos, são passivos,

consomem pouca potência, resistem à interferência eletromagnética e têm alta sensibilidade, alta largura de banda e alta robustez [12], além de serem inertes quimicamente e permitirem com facilidade a multiplexação de sensores e o sensoriamento remoto [11].

Independentemente da grandeza a ser monitorada, uma etapa essencial do sensoriamento óptico é a interrogação, isto é, o processo de obtenção do resultado numérico da medição a partir da leitura de algum parâmetro óptico do sensor. Uma vez estabelecidas as numerosas vantagens dos sensores ópticos, a interrogação passou a ser reconhecida como um dos tópicos de importante atividade de pesquisa e desenvolvimento no contexto do sensoriamento óptico [13]. A complexidade na interrogação é citada na literatura específica como um dos maiores entraves à popularização dos sistemas de sensoriamento ópticos [11, 12], além do custo, que pode ser comparativamente mais alto em muitos casos [12, 13].

Os desenvolvimentos apresentados neste trabalho são motivados, principalmente, pela intenção de popularizar o acesso à implementação de sistemas de sensoriamento que utilizam fibras ópticas. As ferramentas de inteligência artificial e de processamento de sinais podem contribuir com novas abordagens em interrogação de sensores a fibra. Além disso, sabe-se que o custo dos equipamentos ópticos, sobretudo dos interrogadores, é um fator que pode desestimular essa implementação, apesar das suas conhecidas vantagens. Acredita-se que, com o desenvolvimento de novas técnicas de interrogação com configurações simples e preços mais competitivos, o custo da implementação de sistemas ópticos possa ser reduzido.

O objetivo principal deste trabalho é apresentar novas configurações de sistemas sensores e interrogadores que permitam alcançar um desempenho comparável aos de sistemas convencionais, porém, com custo reduzido. Para atingir esse objetivo, propõem-se configurações inovadoras do sistema óptico, especialmente no que diz respeito à interrogação. Ferramentas computacionais modernas, tais como as redes neurais artificiais, se apresentam como potenciais aliadas. Além disso, a associação de técnicas computacionais clássicas a configurações ópticas inovadoras pode ser suficiente para atingir resultados satisfatórios.

Com este trabalho, espera-se contribuir para que haja um maior incentivo à implementação de sistemas de sensoriamento a fibras. A partir dos desenvolvimentos apresentados, isso pode se dar de duas formas: com um aumento na disponibilidade de métodos diferentes para interrogar sensores ópticos e, também, com uma redução nos custos de implementação desses sistemas de interrogação. Além disso, também se espera que um custo menor dos sistemas de sensoriamento a fibras ópticas aliado a uma diversidade maior de métodos de interrogação disponíveis permitam que mais laboratórios possam realizar pesquisa nessa área, o que fortaleceria a comunidade e viabilizaria mais possibilidades de colaboração.

1.1 PUBLICAÇÕES CORRELACIONADAS

- **JUCÁ, M.A.**; PEREIRA, I.V.C.; SPELTA, P.C.G.; SANTOS, A.B. Water salinity measurement using a long-period grating and optical time-domain reflectometry. *JOSA B, Optica*, v. 40, n. 4, p. C8–C14, fev. 2023. ISSN 1520-8540.
- **JUCÁ, M.A.**; PEREIRA, I.V.C.; SPELTA, P.C.G.; SANTOS, A.B. Identification of external media using a long-period grating and optical time-domain reflectometry. *Applied Optics, Optica*, v. 62, n. 8, p. C43–C48, fev. 2023. ISSN 2155-3165.
- **JUCÁ, M.A.**; PEREIRA, I.V.C.; HADDAD, D.B.; SANTOS, A.B. Weight classifier using optical time domain reflectometry and a long period grating sensor. *Optical Fiber Technology*, Elsevier BV, v. 67, p. 102694, dez. 2021. ISSN 1068-5200.
- **JUCÁ, M.A.**; HADDAD, D.B.; SANTOS, A.B. Interrogation system for optical sensor using filter bank and artificial neural network. *Microwave Opt. Technol. Lett.*, Wiley, v. 62, n. 12, p. 4015–4020, dez. 2020. ISSN 1098-2760.
- BARINO, F.; DELGADO, F.S.; **JUCÁ, M.A.**; COELHO T.V.N.; SANTOS, A.B. Comparison of regression methods for transverse load sensor based on optical fiber long-period grating *Measurement*, Elsevier BV, v. 146, p. 728–735, nov. 2019. ISSN 0263-2241.
- RABELLO, I.G.Y.; **JUCÁ, M.A.**; HENRIQUES, F.R. Desenvolvimento de uma interface gráfica para simulador de meios ópticos guiados. *In: SIMPÓSIO BRASILEIRO DE TELECOMUNICAÇÕES E PROCESSAMENTO DE SINAIS (SBrT)*, 40., 2022, Santa Rita do Sapucaí. *Anais [...]* Rio de Janeiro: SBrT, 2022.
- **JUCÁ, M.A.**; SANTOS, A.B. Interrogation of Long-Period Grating Temperature Sensor Using Fiber Bragg Gratings and Artificial Neural Network. *In: LATIN AMERICAN WORKSHOP ON OPTICAL FIBER SENSORS (LAWOFS)*, 2., 2019, Rio de Janeiro. *Proceedings [...]* São Caetano do Sul: SBMO, 2019. p. 41–44.
- OLIVEIRA, M.C.; DELGADO, F.S.; **JUCÁ, M.A.**; FARACO FILHO, R.L.; SILVEIRA, D.D.; COELHO, T.V.N.; SANTOS, A.B. Optical Fiber Sensor for Carbon Dioxide Measurement Using Tapered Long Period Grating. *In: LATIN AMERICAN WORKSHOP ON OPTICAL FIBER SENSORS (LAWOFS)*, 2., 2019, Rio de Janeiro. *Proceedings [...]* São Caetano do Sul: SBMO, 2019. p. 148–152.
- DELGADO, F.S.; **JUCÁ, M.A.**; MARCATO, A.L.M.; SANTOS, A.B. Optical Fiber-Based Sensor for Assessing Electric Current in Unmanned Aerial Vehicles with ROS Interface. *In: INTERNATIONAL CONFERENCE ON ROBOTICS AND AUTOMATION (ICRA)*, 2018, Brisbane. *Proceedings [...]* New York: IEEE, 2018. p. 7820–7825.

1.2 ESTRUTURA DA TESE

Este trabalho é composto desta introdução e de mais cinco capítulos, além de um apêndice.

O Capítulo 2 trata das bases teóricas dos sensores a fibra óptica. Apresentam-se a modelagem matemática necessária e dois tipos de sensores a fibra baseados em grades de difração. O final do capítulo apresenta o estado das técnicas de interrogação desses sensores na literatura recente.

O Capítulo 3 aborda as ferramentas computacionais utilizadas neste trabalho, a fim de fornecer a base para o entendimento das aplicações apresentadas nos capítulos seguintes. Os temas principais desse capítulo são inteligência artificial e estatística.

O Capítulo 4 apresenta uma aplicação das redes neurais artificiais à interrogação de sensores do tipo grade de período longo. O sistema é baseado na filtragem do sinal transmitido pela grade em sub-bandas e na análise da potência óptica contida nessas sub-bandas pela rede neural.

O Capítulo 5 apresenta três aplicações da reflectometria óptica no domínio do tempo, associada a métodos adequados de pós-processamento, à interrogação de sensores do tipo grade de período longo. Esse sistema, que apresenta uma configuração experimental simples e uma análise inovadora, mostrou resultados experimentais promissores.

Por fim, o Capítulo 6 conclui o trabalho, e o Apêndice A apresenta o pacote de simulação GratingSim, que foi desenvolvido ao longo da pesquisa e será disponibilizado como *software* de código aberto.

2 SENSORES EM FIBRAS ÓPTICAS

Neste capítulo, serão apresentados os fundamentos teóricos do funcionamento dos sensores em fibras ópticas (Seção 2.1). Os sensores utilizados neste trabalho são do tipo grade de difração em fibras, que são dispositivos ópticos que alteram a propagação da luz nas fibras através do acoplamento de energia entre diferentes modos de propagação. A Seção 2.2 aborda o conceito de modos, além de apresentar a modelagem matemática do acoplamento de energia entre modos, especialmente o promovido por grades de difração. As grades podem ser utilizadas tanto em comunicações ópticas como em sensores ópticos, o que é explorado na Seção 2.3, focando no estudo de sensores ópticos baseados em grades de Bragg (Subseção **2.3.1**) e em grades de período longo (Subseção **2.3.2**). Por fim, a Seção 2.4 aborda a questão da interrogação dos sensores do tipo grade e expõe algumas limitações dos métodos atuais.

2.1 CONCEITOS BÁSICOS

Uma fibra óptica é um guia de ondas dielétrico que opera em frequências ópticas e consiste essencialmente em dois cilindros dielétricos concêntricos [14, 15]. O objetivo de uma fibra óptica é guiar a luz ao longo do seu comprimento. Como as frequências ópticas são extremamente altas, seu guiamento disponibiliza regiões de banda ultralarga para acomodar canais de informação [15]. As fibras vêm sendo desenvolvidas e aprimoradas desde meados da década de 1960 e, atualmente, possibilitam transmissões a taxas da ordem de centenas a milhares de gigabits por segundo, em enlaces da ordem de centenas de quilômetros [16–18]. Os principais benefícios do uso das fibras em detrimento dos fios de cobre são [15, 16]:

- a) a transmissão a longa distância: a baixa atenuação das fibras permite que os sinais possam se propagar por uma distância longa e ainda serem detectáveis com boa relação sinal-ruído;
- b) a alta capacidade de informação: a grande largura de banda das fibras, associada à baixa dispersão em janelas específicas, permite a transmissão de grande quantidade de dados a cada instante;
- c) o pequeno tamanho e o baixo peso: as fibras têm diâmetros muito pequenos e são feitas de materiais relativamente leves;
- d) a imunidade à interferência eletromagnética: campos eletromagnéticos externos não são capazes de interferir nos sinais que se propagam no interior das fibras;
- e) o aumento na segurança operacional: a ausência de corrente elétrica nas fibras torna a operação mais segura ao reduzir os riscos de curtos e faíscas; e

- f) o aumento na segurança do sinal: o acesso não autorizado à informação é difícil, porque os sinais ópticos ficam confinados ao interior da fibra e são rapidamente atenuados no seu exterior, e pode ser detectado como uma perda inesperada.

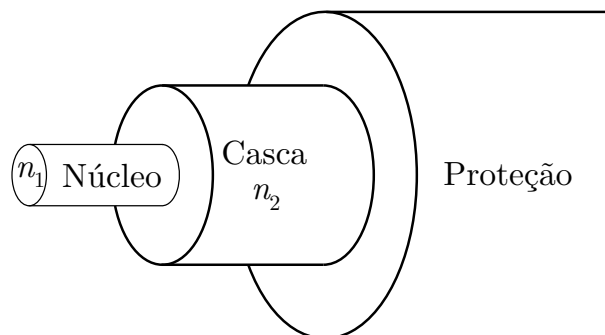
Além do uso em comunicações ópticas, a propagação da luz no interior das fibras também possibilita a criação de sensores [11–13, 19, 20], que estão no foco deste trabalho. O sensoriamento a fibra óptica é frequentemente considerado uma alternativa adequada e de baixo custo para o monitoramento em tempo real das condições de infraestrutura industrial e civil, ou mesmo de ambientes extremos [21, 22].

Um dos parâmetros ópticos fundamentais de um material é o índice de refração, ou índice refrativo [16]. Esse parâmetro é a razão entre a velocidade da luz no vácuo e a velocidade da luz em dado material. No vácuo, a luz se move a uma velocidade $c = 299\,792\,458$ m/s. A velocidade de propagação da luz em um material é indicada por v_p . Assim, o índice de refração do material, denotado n , é dado por:

$$n = \frac{c}{v_p}. \quad (2.1)$$

A Figura 1 mostra a estrutura básica de uma fibra óptica convencional. A fibra é composta essencialmente pelo núcleo e pela casca. O núcleo é o cilindro interno, de menor raio, mostrado na figura com índice de refração n_1 . É principalmente nessa região que a luz se propaga no interior da fibra. A casca envolve o núcleo, com índice de refração n_2 ligeiramente menor que n_1 . Esse arranjo permite o guiamento da onda luminosa ao longo do eixo longitudinal da fibra. Comumente, a casca é envolvida por uma ou mais camadas protetoras com o objetivo de aumentar a resistência da fibra a choques e a abrasão e, conseqüentemente, aumentar sua durabilidade [16].

Figura 1 – Estrutura de uma fibra óptica convencional.



Fonte: elaborada pelo autor (2023).

Variações no material utilizado para compor o núcleo dão origem a dois tipos de fibras: as fibras de índice degrau e as de índice gradual [14, 23]. No primeiro caso, o índice

de refração é uniforme no núcleo e muda abruptamente na fronteira com a casca. No segundo, o índice de refração no núcleo varia em função da distância radial ao centro da fibra. As fibras ainda podem ser divididas em monomodo e multimodo, dependendo do número de modos de propagação possíveis no interior de cada fibra [14].

A diferença entre os índices de refração do núcleo e da casca pode ser quantificada, de forma relativa, utilizando o parâmetro Δ da fibra, chamado de diferença relativa de índices de refração [17]. Seu valor é definido conforme a Equação (2.2a), mas pode ser aproximado pela Equação (2.2b), considerando que a diferença entre os dois índices é muito pequena.

$$\Delta = \frac{n_1^2 - n_2^2}{2n_1^2} \quad (2.2a)$$

$$\Delta \approx \frac{n_1 - n_2}{n_1} \quad (2.2b)$$

2.2 MODOS DE PROPAGAÇÃO EM FIBRAS ÓPTICAS

O completo entendimento da propagação da luz em fibras ópticas demanda uma análise da solução da equação da onda, proveniente das equações de Maxwell, sujeita às condições de contorno cilíndricas na interface entre o núcleo e a casca da fibra [16, 24, 25]. A solução da equação da onda em coordenadas cilíndricas dá origem ao conceito de modos de propagação, que são um conjunto de padrões de ondas eletromagnéticas ou distribuições de campo capazes de se propagar na fibra [26]. O tratamento matemático dessas equações pode ser encontrado em textos específicos [27–34]. No entanto, devido à complexidade das equações, as referências frequentemente pressupõem simplificações ou apresentam inconsistências que dificultam a análise mais detalhada, em especial a simulação computacional, de dispositivos ópticos na fibra, sobretudo daqueles mais influenciados pelas propriedades físicas do meio externo. Isso é particularmente relevante, porque, neste trabalho, optou-se por desenvolver as ferramentas de simulação necessárias em vez de depender de *software* comercial. O pacote de simulação desenvolvido é apresentado no Apêndice A e será disponibilizado como *software* de código aberto.

Ao solucionar a equação da onda para guias circulares metálicos, são encontrados apenas modos transversais elétricos (TE) e transversais magnéticos (TM) [16]. Ao contrário das ondas no espaço livre, as ondas confinadas podem ter componentes de campo na direção de propagação. Se um modo admitir uma componente 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 uma componente 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, em guias totalmente dielétricos como as fibras, devido às condições de contorno na interface núcleo-casca, existe um acoplamento entre as componentes de campo elétrico e magnético. Isso dá origem aos modos chamados híbridos, nos quais existem componentes tanto de campo elétrico quanto de campo magnético na direção de propagação. Os modos híbridos são denominados EH ou HE, a depender de qual for a componente de campo predominante na direção de propagação: elétrico (E) ou magnético (H), respectivamente [16].

Os modos híbridos EH e HE possuem, portanto, seis componentes de campo a serem consideradas, e o seu equacionamento é complexo. No entanto, no caso da maioria das fibras ópticas comerciais, esse equacionamento pode ser simplificado utilizando o fato de o índice de refração da casca ser muito próximo daquele do núcleo, ou seja: $n_1 - n_2 \ll 1$. Nessas condições, diz-se que a fibra promove um guiamento fraco da luz [35]. Dessa forma, as componentes de campo na direção de propagação são muito pequenas, se comparadas às componentes transversais. Ao considerar a situação de guiamento fraco, é possível aproximar convenientemente as distribuições de campo como sendo linearmente polarizadas, dando origem a uma simplificação significativa das expressões matemáticas. 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 [29, 30, 34–37].

A Tabela 1 apresenta um comparativo das principais referências utilizadas para o estudo dos modos nesta pesquisa no que se refere ao tipo dos modos analisados pelos autores, se exatos ou linearmente polarizados, ao número de camadas cilíndricas coaxiais consideradas na análise e, finalmente, às dificuldades encontradas na aplicação dessas referências ao estudo em questão. O restante desta seção será dedicado a elucidar a modelagem matemática dos sensores conforme utilizada nesta pesquisa.

Em uma fibra monomodo comum, o modo fundamental do núcleo é HE_{11} . Utilizando a aproximação de guiamento fraco, o modo linearmente polarizado fundamental é o LP_{01} . Os dois índices representam a ordem azimutal e a ordem radial do modo LP, respectivamente. Os parâmetros de propagação desse modo podem ser encontrados resolvendo-se a Equação (2.3) [32]. Esta equação é transcendental e, por isso, normalmente é resolvida graficamente ou numericamente. A solução fornecerá o índice efetivo para o modo fundamental de núcleo LP_{01} .

$$V\sqrt{1-b}\frac{J_1(V\sqrt{1-b})}{J_0(V\sqrt{1-b})} = V\sqrt{b}\frac{K_1(V\sqrt{b})}{K_0(V\sqrt{b})} \quad (2.3)$$

Na Equação (2.3), as grandezas V e b são a frequência normalizada e o índice efetivo normalizado, definidos na Equação (2.4) e na Equação (2.5) [32].

Tabela 1 – Comparação dos materiais de referência sobre modos de propagação.

Referência	Tipos de Modos	Número de Camadas	Dificuldades Encontradas
Snitzer, 1961 [27]	Exatos	2	Ignora o meio externo.
Gloge, 1971 [35]	LP	2	Ignora o meio externo.
Unger, 1977 [29]	Exatos	3	Apresenta alta complexidade na resolução das equações diferenciais.
<i>Ibid.</i>	LP	3	Trata as equações diferenciais no domínio dos números complexos, dificultando a solução computacional.
Adams, 1981 [30]	Exatos	2	Ignora o meio externo.
<i>Ibid.</i>	LP	3	Considera o índice do meio externo maior que o da casca.
Marcuse, 1982 [31]	Exatos	2	Ignora o meio externo.
Monerie, 1982 [36]	LP	3	Apresenta alta sensibilidade dos campos em torno da interface casca-ambiente ao erro de arredondamento do índice efetivo.
Marcuse, 1991 [37]	LP	2	Ignora o meio externo.
Erdogan, 1997 [32, 33]	Exatos	3	Apresenta erros de digitação, mesmo após a publicação da errata. A constante de normalização gera campos inconsistentes.
Kawano, 2001 [34]	Exatos	2	Ignora o meio externo.
<i>Ibid.</i>	LP	2	Ignora o meio externo.

Fonte: elaborada pelo autor (2023).

Nota: [33] é uma errata de [32] publicada em 2000.

$$V = \frac{2\pi r_1}{\lambda} \sqrt{n_1^2 - n_2^2} \quad (2.4)$$

$$b = \frac{n_{\text{eff}}^2 - n_2^2}{n_1^2 - n_2^2} \quad (2.5)$$

Nas Equações (2.3) a (2.5), $J_i(\cdot)$, com $i \in \{0, 1\}$, é a função de Bessel da primeira espécie e ordem i , $K_i(\cdot)$ 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 [32].


Para o modo LP_{01} , a dependência radial $\psi(r)$ das componentes axiais dos campos é descrita como [32, 36]:

$$\psi(r) = \begin{cases} A_{\text{co}} J_0 \left(V \sqrt{1-b} \frac{r}{r_1} \right), & \text{se } r \leq r_1, \\ A_{\text{co}} \frac{J_0 \left(V \sqrt{1-b} \right)}{K_0 \left(V \sqrt{b} \right)} K_0 \left(V \sqrt{b} \frac{r}{r_1} \right), & \text{se } r > r_1, \end{cases} \quad (2.6)$$

em que A_{co} é uma constante de normalização e representa o valor do campo em $r = 0$.

A Figura 2 mostra o perfil radial das componentes transversais de campo no modo LP_{01} e também a intensidade dos campos ao longo da seção reta da fibra, com os valores de intensidade maiores em cores mais claras. É possível observar que a intensidade está fortemente concentrada no núcleo.

Figura 2 – Campo transversal no modo LP fundamental de núcleo: (a) perfil radial; (b) intensidade ao longo da seção reta.



Fonte: elaborada pelo autor (2023).

As Equações (2.3) e (2.6) são baseadas em uma aproximação da fibra que considera a casca com raio infinito. Essa aproximação é válida tendo em vista que os campos que compõem o modo fundamental estão altamente concentrados no núcleo, decaindo rapidamente ao passarem à casca. Dessa forma, ao chegarem à interface da casca com o

meio externo, os campos já terão valores insignificantes se a casca tiver um raio grande o suficiente. Todas as fibras práticas são projetadas para que isso aconteça [37].

Por outro lado, quando se considera a propagação em modos de casca e, principalmente, sua interação com o meio externo, é necessária uma análise mais completa. Utilizando a abordagem do guiamento fraco, Unger [29] e Monerie [36] analisaram o caso de fibras com três camadas: núcleo, casca e uma camada externa. O trabalho de Erdogan [32, 33] também considera três camadas, porém utilizando os modos exatos, vetoriais. Dessa forma, apresentam maior complexidade no equacionamento e estão mais sujeitos a erro. De fato, mesmo após a publicação da errata [33], existem inconsistências na modelagem matemática que dificultam a simulação computacional. Sendo assim, a aproximação do guiamento fraco foi escolhida para modelar os modos de casca, como mostrado a seguir. A equação característica para um modo de casca com ordem azimutal l é [36]:

$$\frac{[\hat{J}_l(u) - \hat{Y}_l(u'c)] [\hat{K}_l(v) - \hat{J}_l(u')]}{[\hat{J}_l(u) - \hat{J}_l(u'c)] [\hat{K}_l(v) - \hat{Y}_l(u')]} = \frac{J_{l+1}(u'c) Y_{l+1}(u')}{J_{l+1}(u') Y_{l+1}(u'c)}, \quad (2.7)$$

em que $Y_i(\cdot)$ é a função de Bessel da segunda espécie e ordem i , e foi utilizada a seguinte abreviação:

$$\hat{Z}_l(x) = \frac{Z_l(x)}{x Z_{l+1}(x)}, \quad (2.8)$$

com Z representando qualquer uma das funções de Bessel. Além disso, os seguintes parâmetros foram utilizados [36]:

$$u = r_1 \sqrt{k_0^2 n_1^2 - \beta^2}, \quad (2.9)$$

$$u' = r_2 \sqrt{k_0^2 n_2^2 - \beta^2}, \quad (2.10)$$

$$v = r_2 \sqrt{\beta^2 - k_0^2 n_3^2}, \quad (2.11)$$

em que k_0 é o número de onda no espaço livre, $\beta = k_0 n_{\text{eff}}$ é a constante de propagação, n_3 é o índice de refração do meio externo, e $c = r_1/r_2$.

A Equação (2.7) é transcendental e requer métodos gráficos ou numéricos para sua solução. O cálculo fornecerá os valores dos índices efetivos dos modos de casca de ordem azimutal l . A dependência radial $\psi(r)$ das componentes axiais dos campos fica descrita como [36]:

$$\psi(r) = \begin{cases} A_{cl} J_l \left(u \frac{r}{r_1} \right) & \text{se } r \leq r_1, \\ A_1 J_l \left(u' \frac{r}{r_2} \right) + A_2 Y_l \left(u' \frac{r}{r_2} \right) & \text{se } r_1 < r \leq r_2, \\ A_3 K_l \left(v \frac{r}{r_2} \right) & \text{se } r > r_2, \end{cases} \quad (2.12)$$

em que A_i , com $i \in \{1, 2, 3\}$, são constantes definidas a partir da constante de normalização A_{cl} da seguinte forma [36]:


$$A_1 = \frac{\pi A_{cl}}{2} [u J_{l+1}(u) Y_l(u'c) - u'c J_l(u) Y_{l+1}(u'c)] \quad (2.13a)$$

$$A_2 = \frac{\pi A_{cl}}{2} [u'c J_{l+1}(u'c) J_l(u) - u J_{l+1}(u) J_l(u'c)] \quad (2.13b)$$

$$A_3 = \frac{1}{K_l(v)} [A_1 J_l(u') + A_2 Y_l(u')] \quad (2.13c)$$

A Figura 3 mostra o perfil radial das componentes transversais de campo nos modos LP_{02} , LP_{03} , LP_{04} e LP_{05} . Nota-se que os campos dos modos de ordem radial mais alta estão mais distribuídos ao longo da casca.


Figura 3 – Perfil radial do campo transversal nos modos LP de casca.



Fonte: elaborada pelo autor (2023).

A Figura 4 mostra a distribuição da intensidade dos campos transversais na seção reta da fibra para alguns modos de casca. Como ilustrado nos gráficos, os modos de ordem azimutal igual a 0 têm um pico de intensidade no núcleo, ao contrário dos modos de ordem azimutal maior do que 0, que apresentam intensidade de campo significativa apenas na casca. Isso é especialmente importante para o acoplamento de energia entre modos. Como o acoplamento depende da superposição dos campos, segue que o modo fundamental de núcleo estará mais suscetível ao acoplamento para modos de casca que tenham ordem azimutal igual a 0, comparativamente aos de ordem maior que 0.

Figura 4 – Intensidade do campo transversal ao longo da seção reta da fibra nos modos: (a) LP₀₂; (b) LP₁₁; (c) LP₂₁; (d) LP₀₃; (e) LP₁₂; (f) LP₂₂;



Fonte: elaborada pelo autor (2023).

Uma grade de difração na fibra promove o acoplamento de energia entre modos. Se a grade só existir no núcleo da fibra, o perfil longitudinal do índice de refração é [32]:

$$n(r, z) = \begin{cases} n_1 \left\{ 1 + \sigma(z) \left[1 + m \cos \left(\frac{2\pi}{\Lambda} z \right) \right] \right\}, & r \leq r_1; \\ n_2, & r_1 < r \leq r_2; \\ n_3, & r > r_2, \end{cases} \quad (2.14)$$

em que $\sigma(z)$ é o envelope da grade, seu formato geral, m , com $0 \leq m \leq 1$, é o seu índice de modulação, e Λ é o período da perturbação no índice de refração. Para quantificar o acoplamento entre modos, é necessário calcular os coeficientes de acoplamento. A análise apresentada a seguir considera apenas os coeficientes de acoplamento transversais $K_{\nu\mu}^t$, já que os longitudinais $K_{\nu\mu}^z$ têm valores muito menores, considerados desprezíveis. A definição do coeficiente de acoplamento transversal entre os modos ν e μ é [32, 38]:

$$K_{\nu\mu}^t(z) = \frac{\omega}{4} \int_0^{2\pi} d\phi \int_0^\infty r dr \Delta\varepsilon(r, z) \mathbf{E}_\nu^t(r, \phi) \cdot \mathbf{E}_\mu^{t*}(r, \phi), \quad (2.15)$$

em que o índice t significa apenas componentes transversais, $\Delta\varepsilon$ representa a perturbação na constante dielétrica e \mathbf{E}_ν e \mathbf{E}_μ são os campos elétricos dos modos ν e μ . Para simplificar os cálculos, convém definir a constante de acoplamento $\kappa_{\nu\mu}$ de acordo com a Equação (2.16) [32]. Apesar do nome, $\kappa_{\nu\mu}$ pode ter uma variação em z devido ao efeito de $\sigma(z)$.

$$K_{\nu\mu}^t(z) = \kappa_{\nu\mu}(z) \left[1 + m \cos \left(\frac{2\pi}{\Lambda} z \right) \right], \quad (2.16)$$

Com essas definições e na condição de que a perturbação no índice seja pequena, é possível calcular a constante de acoplamento do modo fundamental de núcleo para o modo de núcleo contrapropagante como:

$$\kappa_{01-01}(z) = \frac{\pi}{2} \sigma(z) \frac{k_0 n_1^2 A_{co}^2 r_1^2}{Z_0} \left[J_0^2(V\sqrt{1-b}) + J_1^2(V\sqrt{1-b}) \right], \quad (2.17)$$

em que $Z_0 = \sqrt{\mu_0/\varepsilon_0}$ é a impedância característica do vácuo. Já a constante de acoplamento entre o modo fundamental de núcleo e um modo de casca $LP_{0\nu}$ é:

$$\kappa_{01-0\nu}(z) = \pi \sigma(z) \frac{k_0 n_1^2 A_{co} A_{cl} r_1^2}{Z_0 (u_{co}^2 - u_{cl}^2)} \left[u_{co} J_1(u_{co}) J_0(u_{cl}) - u_{cl} J_0(u_{co}) J_1(u_{cl}) \right], \quad (2.18)$$

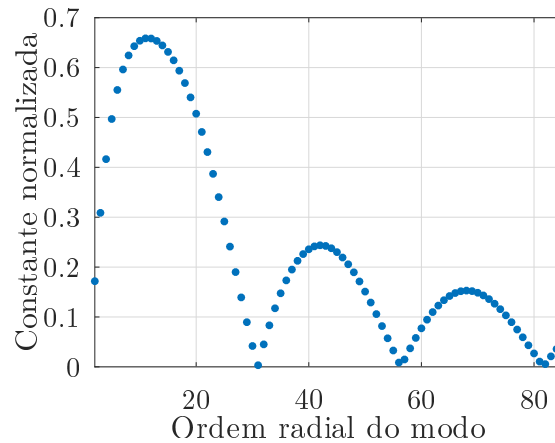
em que u_{co} e u_{cl} correspondem ao parâmetro u definido na Equação (2.9) calculado para o modo de núcleo e de casca, respectivamente, conforme mostra a Equação (2.19).

$$u_{co} = r_1 \sqrt{k_0^2 n_1^2 - \beta_{co}^2} \quad (2.19a)$$

$$u_{cl} = r_1 \sqrt{k_0^2 n_1^2 - \beta_{cl,\nu}^2} \quad (2.19b)$$

A Figura 5 mostra as constantes de acoplamento de 84 modos LP de casca em uma fibra monomodo padrão, normalizadas por $\sigma(z)$ para remover a dependência em z .

Figura 5 – Constantes de acoplamento normalizadas de modos LP em uma fibra monomodo padrão.



Fonte: elaborada pelo autor (2023).

A Equação (2.20) descreve a alteração nos campos de um modo μ em ambas as direções causada pela presença de outros modos ν nas proximidades de uma perturbação no índice [38, 39].

$$\begin{aligned} \frac{dA_\mu}{dz} = & i \sum_\nu A_\nu \left(K_{\nu\mu}^t + K_{\nu\mu}^z \right) \exp [i (\beta_\nu - \beta_\mu) z] \\ & + i \sum_\nu B_\nu \left(K_{\nu\mu}^t - K_{\nu\mu}^z \right) \exp [-i (\beta_\nu + \beta_\mu) z], \end{aligned} \quad (2.20a)$$

$$\begin{aligned} \frac{dB_\mu}{dz} = & -i \sum_\nu A_\nu \left(K_{\nu\mu}^t - K_{\nu\mu}^z \right) \exp [i (\beta_\nu + \beta_\mu) z] \\ & - i \sum_\nu B_\nu \left(K_{\nu\mu}^t + K_{\nu\mu}^z \right) \exp [-i (\beta_\nu - \beta_\mu) z], \end{aligned} \quad (2.20b)$$

em que $A_\mu(z)$ é a amplitude do campo transversal do modo na direção $+z$ e $B_\mu(z)$ é a amplitude do campo transversal do modo na direção $-z$. Desprezando o efeito de $K_{\nu\mu}^z$ e o acoplamento dos modos de casca entre si, e fazendo as devidas substituições, é possível descrever as interações entre modos contrapropagantes em uma grade de período curto como [32]:

$$\begin{aligned} \frac{dA^{\text{co}}}{dz} = & i\kappa_{01-01}A^{\text{co}} + i\frac{m}{2}\kappa_{01-01}B^{\text{co}} \exp(-i2\delta_{01-01}z) \\ & + i \sum_\nu \frac{m}{2}\kappa_{01-0\nu}B_\nu^{\text{cl}} \exp(-i2\delta_{01-0\nu}z), \end{aligned} \quad (2.21a)$$

$$\frac{dB^{\text{co}}}{dz} = -i\kappa_{01-01}B^{\text{co}} - i\frac{m}{2}\kappa_{01-01}A^{\text{co}} \exp(+i2\delta_{01-01}z), \quad (2.21b)$$

$$\frac{dB_\nu^{\text{cl}}}{dz} = -i\frac{m}{2}\kappa_{01-0\nu}A^{\text{co}} \exp(+i2\delta_{01-0\nu}z), \quad (2.21c)$$

em que A^{co} e B^{co} são as amplitudes do modo de núcleo e B_ν^{cl} é a amplitude do modo de casca de ordem radial ν na direção $-z$. Os parâmetros δ_{01-01} e $\delta_{01-0\nu}$, para redes de período curto, são definidos da seguinte forma [32]:

$$\delta_{01-01} = \frac{1}{2} \left(2\beta_{\text{co}} - \frac{2\pi}{\Lambda} \right) \quad (2.22)$$

$$\delta_{01-0\nu} = \frac{1}{2} \left(\beta_{\text{co}} + \beta_{\text{cl},\nu} - \frac{2\pi}{\Lambda} \right) \quad (2.23)$$

Por outro lado, para grades de período longo, as interações entre modos copropagantes são descritas por [32]:

$$\frac{dA^{\text{co}}}{dz} = i\kappa_{01-01}A^{\text{co}} + i \sum_\nu \frac{m}{2}\kappa_{01-0\nu}A_\nu^{\text{cl}} \exp(-i2\delta_{01-0\nu}z), \quad (2.24a)$$

$$\frac{dA_\nu^{\text{cl}}}{dz} = i\frac{m}{2}\kappa_{01-0\nu}A^{\text{co}} \exp(+i2\delta_{01-0\nu}z), \quad (2.24b)$$

em que A_ν^{cl} é a amplitude do modo de casca de ordem radial ν na direção $+z$. O parâmetro δ_{01-01} é o mesmo da Equação (2.22). Porém, $\delta_{01-0\nu}$ é diferente em redes de período longo e pode ser calculado como [32]:

$$\delta_{01-0\nu} = \frac{1}{2} \left(\beta_{\text{co}} - \beta_{\text{cl},\nu} - \frac{2\pi}{\Lambda} \right) \quad (2.25)$$

Dessa forma, fica estabelecido o modelo matemático dos dispositivos ópticos utilizados neste trabalho. O cálculo dos espectros de transmissão e de reflexão dos dispositivos pode ser obtido resolvendo-se o sistema de equações diferenciais acopladas da Equação (2.21) ou o da Equação (2.24), de acordo com o dispositivo em questão. O *software* apresentado no Apêndice A oferece uma implementação desses cálculos, permitindo a simulação do acoplamento entre modos promovido por grades de difração.

2.3 GRADES DE DIFRAÇÃO EM FIBRAS

Os dispositivos ópticos no foco deste trabalho são as grades, ou redes, 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 (*Fiber Bragg Grating* - FBG) e a grade de período longo (*Long-Period Grating* - LPG). 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 nas Subseções **2.3.1** e **2.3.2**.

As grades possuem diversas aplicações, como filtros para sinais multiplexados por divisão em comprimento de onda (*Wavelength Division Multiplexing* - WDM), equalizadores de ganho para amplificadores de fibra dopada com érbio (*Erbium Doped Fiber Amplifier* - EDFA), compensadores de dispersão, entre outros [12, 40, 41]. 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 a outros tipos de sensores em fibra. Sensores a grade são simples, imunes à interferência eletromagnética, leves, pequenos, sua produção é barata 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 [12].


2.3.1 Grades de período curto

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 a fibra óptica a um padrão periódico de luz

ultravioleta. Como resultado, as grades são regiões com índices de refração alternadamente altos e baixos no interior do núcleo da fibra, conforme a Figura 6. 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 [20]. O comprimento de onda do pico de reflexão é conhecido como comprimento de onda de Bragg λ_B e é dado pela Equação (2.26), em que n_{eff} é o índice de refração efetivo e Λ é o período da grade [19].

$$\lambda_B = 2n_{\text{eff}}\Lambda \quad (2.26)$$


Figura 6 – Estrutura de uma grade de Bragg.



Fonte: elaborada pelo autor (2023).

A Figura 7 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 (*Full Width at Half Maximum* - FWHM) do pico de reflexão é tipicamente da ordem de 1 nm [11].

Figura 7 – Espectros resultantes do funcionamento de uma FBG.

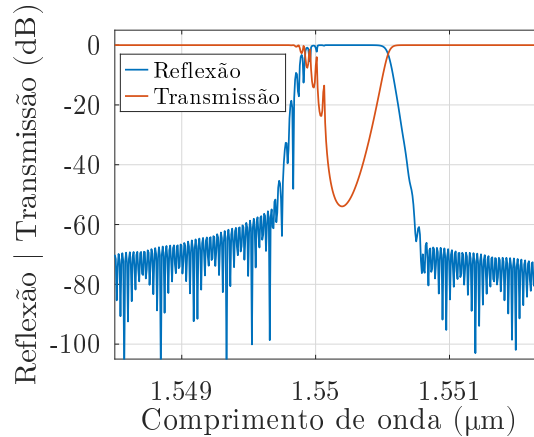


Fonte: elaborada pelo autor (2023).

A Figura 8 mostra o resultado da simulação dos espectros de reflexão e de transmissão de uma FBG inscrita em uma fibra monomodo padrão com período de 0,53 μm

e apodização gaussiana, ou seja, o formato $\sigma(z)$ da grade é uma função gaussiana. No pico, a reflexão promovida pela grade é de 99,99 % do sinal. A largura de 3 dB do pico de reflexão é de 0,6 nm.

Figura 8 – Simulação dos espectros de reflexão e de transmissão de uma FBG.



Fonte: elaborada pelo autor (2023).

As FBGs são sensíveis à deformação axial devido à alteração no período da grade Λ e ao efeito fotoelástico, que promove uma alteração no índice de refração efetivo n_{eff} . Também são sensíveis à temperatura devido ao efeito da expansão térmica na grade, que modifica o seu período, e devido ao efeito termo-óptico, que modifica o valor do índice efetivo. Portanto, uma FBG sujeita à deformação $\Delta\ell$ e à variação de temperatura ΔT exibe um deslocamento no comprimento de onda do seu pico de ressonância, que pode ser descrito pela Equação (2.27) [11].

$$\Delta\lambda_B = 2 \left(\Lambda \frac{\partial n_{\text{eff}}}{\partial \ell} + n_{\text{eff}} \frac{\partial \Lambda}{\partial \ell} \right) \Delta\ell + 2 \left(\Lambda \frac{\partial n_{\text{eff}}}{\partial T} + n_{\text{eff}} \frac{\partial \Lambda}{\partial T} \right) \Delta T \quad (2.27)$$

Em uma fibra óptica típica, a sensibilidade à deformação no comprimento de onda de 1550 nm é de 1,2 pm/ $\mu\epsilon$ [11]. As respostas típicas à temperatura são 6,8 pm/ $^{\circ}\text{C}$, 10 pm/ $^{\circ}\text{C}$ e 13 pm/ $^{\circ}\text{C}$ nos comprimentos de onda de 830 nm, 1300 nm e 1550 nm, respectivamente [11]. É importante notar que o valor da sensibilidade é constante para dado comprimento de onda de operação, isto é, a resposta da FBG à deformação ou à variação de temperatura é linear.

Sensores de deformação baseados em FBG já foram utilizados para a medição indireta de diversos parâmetros, como pressão [42], força [43], deslocamento [44], vibração [45], nível de líquidos [46] e campo magnético [47]. Sensores de temperatura baseados em FBGs comuns podem funcionar bem até aproximadamente 300 $^{\circ}\text{C}$. 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) [11].

Sensores FBG também têm sido utilizados em uma variedade de aplicações, como no sensoriamento de índice de refração [48], de umidade [49, 50], de aceleração [51], na detecção de torque em eixos giratórios [52] e no imageamento ultrassônico de modelos físicos sísmicos [53].

2.3.2 Grades de período longo

LPGs são grades que acoplam energia do modo propagante para modos de casca copropagantes [4, 13, 54–57]. 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 na Equação (2.28), 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 [12, 58, 59].

$$\frac{2\pi N}{\Lambda} = \beta_1 - \beta_2 \quad (2.28)$$


Nas grades de Bragg, 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 [4, 55, 60, 61].

Os modos de casca decaem rapidamente devido a perdas por espalhamento na interface casca-ar e a 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 [4].

A Figura 9 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 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 λ_ν correspondentes aos respectivos modos, de acordo com a Equação (2.29), em função dos índices efetivos do núcleo, $n_{\text{eff}}^{\text{co}}$, e da casca, $n_{\text{eff},\nu}^{\text{cl}}$ [4, 39, 54, 62]. A modelagem matemática desse dispositivo foi apresentada em [32] e, desde então, vem sendo revista [33, 63–67].

$$\lambda_\nu = \left(n_{\text{eff}}^{\text{co}} - n_{\text{eff},\nu}^{\text{cl}} \right) \Lambda \quad (2.29)$$

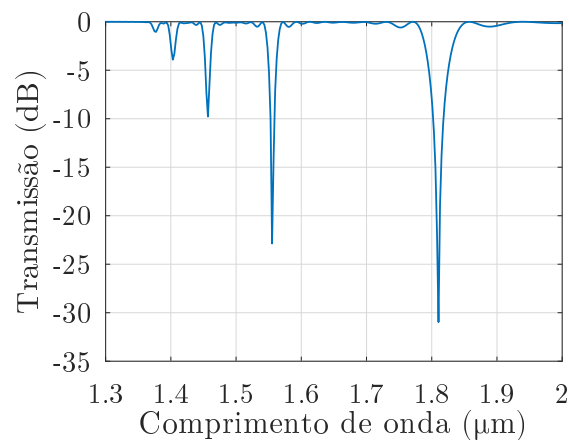
Figura 9 – Espectro resultante do funcionamento de uma LPG.



Fonte: elaborada pelo autor (2023).

A Figura 10 mostra a característica de transmissão de luz por uma LPG inscrita em fibra monomodo padrão com período de $570 \mu\text{m}$ e comprimento de 25 mm . Nessa figura, é possível ver as bandas de atenuação associadas aos modos de casca copropagantes LP_{02} , LP_{03} , LP_{04} , LP_{05} e LP_{06} . A banda de ressonância do modo LP_{05} está centrada em 1555 nm e sua largura de meia potência é de 12 nm . Já o vale do modo LP_{06} está centrado em 1810 nm e tem uma largura de 3 dB de 37 nm .

Figura 10 – Característica espectral de transmissão de luz por uma LPG.



Fonte: elaborada pelo autor (2023).

O formato e os comprimentos de onda centrais das bandas de atenuação são sensíveis ao período da LPG, ao seu comprimento e às grandezas relacionadas ao ambiente em que a fibra está inserida: temperatura, deformação, tração, curvatura e índice de refração do meio [41, 55–57]. 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 ou em uma alteração na profundidade do vale [41]. Essa sensibilidade das bandas de atenuação a parâmetros do ambiente permite o uso de LPGs em aplicações de sensoriamento por meio

do rastreamento do comprimento de onda ressonante de uma ou mais ordens de modos de casca no espectro de transmissão da LPG.

As LPGs vêm sendo utilizadas desde o seu princípio como equalizadores de ganho para amplificadores de fibra dopada com érbio (*Erbium Doped Fiber Amplifier* - EDFA) [54]. Como sensores, podem ser utilizadas para medir o índice de refração do meio externo [68, 69], torção axial [70], turbidez [71] e salinidade [72] de água, concentração de gases como metano [73] e dióxido de carbono [74], 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 [75, 76]. Nota-se que as LPGs têm uma ampla variedade de aplicações bem documentadas devido à sua alta sensibilidade e baixa perda de retorno [41, 55, 77].

A sensibilidade da LPG à deformação e à temperatura se deve ao efeito direto dessas grandezas no período da grade, além dos efeitos fotoelástico e termo-óptico, analogamente ao caso da FBG. Por outro lado, a sensibilidade da LPG ao índice de refração do meio externo resulta da dependência dos índices efetivos dos modos de casca com o índice de refração do meio [41, 78]. Devido a um aumento no índice de refração externo, os comprimentos de onda ressonantes se deslocam em direção a comprimentos de onda mais curtos. Além disso, a sensibilidade da LPG aumenta com a ordem do modo de casca acoplado, de acordo com [79, 80]:

$$\Delta\lambda_\nu = \frac{\mu_\nu^2 \lambda_0^3 \Lambda}{8\pi^3 n_2 r_2^3} \left[\frac{1}{\sqrt{n_2^2 - \bar{n}_3^2}} - \frac{1}{\sqrt{n_2^2 - n_3^2}} \right], \quad (2.30)$$


em que $\Delta\lambda_\nu$ é o deslocamento em relação à referência do comprimento de onda ressonante, μ_ν é a ν -ésima raiz da função de Bessel de primeira espécie e ordem zero, λ_0 é o comprimento de onda ressonante (λ_ν) quando o meio externo é o meio de referência e \bar{n}_3 é o índice de refração externo alterado em relação à referência n_3 .

2.4 INTERROGAÇÃO DE SENSORES A FIBRA

A interrogação de sensores em fibras ópticas é tradicionalmente realizada mediante a análise do espectro do dispositivo, especialmente utilizando um analisador de espectro óptico (*Optical Spectrum Analyzer* - OSA) [81–85] ou dispositivos específicos para interrogação [86, 87]. A Figura 11 mostra como a variação da banda de atenuação ressonante de uma LPG pode indicar a variação da temperatura ou do índice de refração ao redor desse dispositivo. Em laboratório, um OSA pode interrogar esse tipo de sensor de forma direta. A visualização da resposta espectral pode fornecer informações relevantes para a pesquisa.

Em campo, no entanto, é necessária uma forma mais prática de interrogar o sensor. Normalmente isso é feito envolvendo um processo de filtragem. Filtros na faixa de excursão do sensor traduzem a variação em comprimento de onda para uma variação em intensidade,

Figura 11 – Resposta espectral de uma LPG: (a) sujeita a diferentes temperaturas; (b) sujeita a diferentes índices externos.



Fonte: elaborada pelo autor (2023).

que pode ser percebida usando fotodetectores. Fallon *et al.* propuseram a utilização de uma LPG como filtro para interrogar uma FBG [88]. A espectroscopia derivativa é outra estratégia de interrogação possível, que usa FBGs com resposta modulada em conjunto com análise de harmônicos para obter a saída do sensor [89, 90].

Outros trabalhos propuseram técnicas de interrogação alternativas, principalmente devido ao alto custo do equipamento de interrogação. Patrick *et al.* utilizaram duas FBGs e uma LPG em um sistema de medição e detecção híbrido capaz de realizar medições simultâneas de temperatura e deformação [91]. Díaz-Herrera *et al.* demonstraram a utilização de duas FBGs para interrogar um sensor a fibra por ressonância de plásmem de superfície [92]. Giordana *et al.* propuseram um sistema de interrogação de FBG utilizando outras duas FBGs, espacialmente deslocadas e termicamente estabilizadas, cuja leitura era feita com um osciloscópio [93]. Wei *et al.* utilizaram um filtro ajustável baseado em fibra multimodo e em controle de polarização para interrogar um sensor FBG de temperatura [94]. Song *et al.* desenvolveram um sistema de interrogação para sensores FBG multiponto baseado na utilização de laser caótico de comprimento de onda ajustável [22]. Esse último sistema também é capaz de localizar os sensores espacialmente.

A utilização de reflectômetro óptico no domínio do tempo (*Optical Time-Domain Reflectometer* - OTDR) também já foi demonstrada para interrogação de sensores FBG. Zhang *et al.* propuseram a utilização de um OTDR para interrogar sensores FBG multiplexados de deformação e de temperatura [95]. Hann *et al.* apresentaram um sistema de monitoramento de redes ópticas passivas que utiliza FBGs como refletores e um OTDR para realizar a leitura [96]. Lo e Xu demonstraram métodos de interrogação de sensores de curvatura e de índice de refração utilizando FBGs e OTDR para interrogar [97]. Bravo *et al.* e depois Giraldo *et al.* apresentaram sistemas de interrogação com OTDR para LPGs usando espelhos e com a possibilidade de multiplexação usando acopladores [98, 99]. Wang *et al.* desenvolveram um sistema de interrogação de sensores FBG multiponto

e multiparamétricos utilizando uma LPG como filtro e um OTDR [100, 101]. Dey *et al.* utilizaram um OTDR e uma seção de fibra monomodo-multimodo-monomodo para interrogar um sensor FBG de temperatura e de deformação [102].

Nota-se que a proposição de técnicas de interrogação alternativas é mais avançada em sensores FBG do que em LPG. Possíveis motivos para isso são as amplas larguras de banda e faixas de excursão dos vales ressonantes das LPGs, que podem dificultar a interrogação por filtragem.

Nos últimos anos, pesquisas desenvolvidas no Laboratório de Instrumentação e Telemetria (LITel) da Universidade Federal de Juiz de Fora (UFJF) vêm demonstrando o uso de técnicas computacionais modernas com bons resultados na confecção de interrogadores. Demonstrou-se a interrogação de um sensor FBG com um banco de filtros em FBG e um processamento com rede neural artificial (RNA) [103]. Barino *et al.* compararam diferentes métodos de regressão e demonstraram a interrogação de um sensor LPG de carga transversal utilizando também uma rede neural artificial [104, 105]. As pesquisas relatadas nos Capítulos 4 e 5 utilizam técnicas de inteligência artificial, como as redes neurais artificiais, e de reconhecimento de padrões, como a extração de características, para realizar a interrogação de sensores LPG.

3 FERRAMENTAS COMPUTACIONAIS

Este capítulo estabelece a base teórica dos métodos computacionais utilizados para processar os dados dos sensores com o objetivo da interrogação. As seções abaixo descrevem as técnicas na ordem em que são utilizadas nos Capítulos 4 e 5. A Seção 3.1 trata das redes neurais artificiais (RNAs), das suas bases teóricas e de algumas das suas aplicações. Em seguida, a Seção 3.2 apresenta a técnica da regressão linear múltipla, que ajusta um modelo a dados utilizando mais de uma variável explicativa. A extração de características, que é assunto da Seção 3.3, tem o objetivo de retornar dados relevantes e simultaneamente não redundantes, promovendo uma redução de dimensionalidade, que facilita o processo de treino e a generalização em aplicações de aprendizado de máquina. A Seção 3.4 aborda a análise de componentes principais (*Principal Component Analysis* - PCA), que aplica uma transformação no sistema de coordenadas a fim de permitir a redução da dimensionalidade, mantendo a capacidade de explicar a maior parte da variância, em um problema com muitas dimensões. Por fim, a Seção 3.5 apresenta a validação cruzada *k-fold*, que é uma forma de estimar a capacidade de generalização de um modelo estatístico em um conjunto de dados independente, especialmente se o conjunto de treino for pequeno, a fim de comparar e selecionar modelos.

3.1 REDES NEURAIAS ARTIFICIAIS

Redes neurais artificiais (RNAs) são sistemas de processamento de informação que têm certas características em comum com redes neurais biológicas [106]. São sistemas paralelos distribuídos compostos por unidades de processamento simples que calculam determinadas funções matemáticas, geralmente não lineares [107]. O funcionamento das RNAs é inspirado em processos observados no cérebro humano, que possui diversas características desejáveis em sistemas artificiais [108].

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

As RNAs foram desenvolvidas como generalizações de modelos matemáticos da cognição humana ou da biologia neural, baseado nas seguintes suposições: (i) o processamento da informação ocorre em diversos elementos simples chamados de neurônios;

(ii) sinais são transmitidos entre neurônios através de conexões; (iii) cada conexão tem um peso associado, que, em uma rede neural típica, multiplica o sinal transmitido e (iv) cada neurônio aplica uma função de ativação, geralmente não linear, à sua entrada total, ou seja, à soma dos sinais de entrada ponderados, para determinar seu sinal de saída [106]. 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.

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 sinápticos, chamado de algoritmo de aprendizado, ou de algoritmo de treinamento e (iii) sua função de ativação [106].

Os primeiros artigos sobre RNAs foram publicados há 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: (i) a análise de imagens obtidas por satélites artificiais; (ii) a classificação de padrões de fala e de escrita; (iii) o reconhecimento facial com visão computacional; (iv) o controle de trens de alta velocidade; (v) a previsão de valores de ações no mercado financeiro; (vi) a identificação de anomalias em imagens médicas; (vii) a identificação automática de perfis de crédito de clientes de instituições financeiras e (viii) o controle de dispositivos eletrônicos e eletrodomésticos, como lavadoras de roupa, fornos de micro-ondas, geladeiras, cafeteiras, fritadeiras, câmeras de vídeo, entre outros [109].

As RNAs apresentam diversas características que podem ser exploradas no processamento de informação, dentre elas [109]:

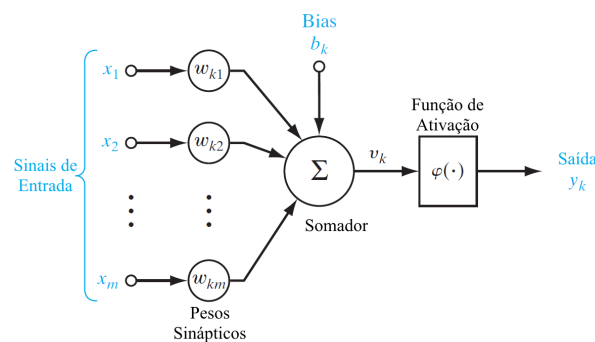
- a) a **adaptação a partir da experiência**: os pesos sinápticos são ajustados pela examinação de exemplos sucessivos, permitindo a aquisição de conhecimento pela experiência;
- b) a **capacidade de aprendizado**: através do uso de um método de aprendizado, a rede pode extrair a relação existente entre as diversas variáveis da aplicação;
- c) a **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) a **organização de dados**: baseada em informações inerentes a um processo específico, a rede pode organizar essa informação, permitindo o agrupamento de padrões com características comuns;
- e) a **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;

- f) o **armazenamento distribuído**: o conhecimento sobre o comportamento de um dado processo aprendido pela rede é armazenado em cada uma das diversas sinapses entre os neurônios artificiais, melhorando a robustez da arquitetura em caso de perda de algum neurônio; e
- g) a **prototipagem facilitada**: dependendo das particularidades da aplicação, muitas arquiteturas neurais podem ser facilmente implementadas em *hardware* ou em *software*, visto que os resultados, após o processo de treinamento, são geralmente 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 12. Em um neurônio k com m sinapses na entrada, cada sinal de entrada x_j , com $j \in \mathbb{N} \mid j \leq m$ representando o número da sinapse, é multiplicado por um peso sináptico w_{kj} correspondente. Esses valores ponderados são, então, somados e a soma pode incluir um valor constante b_k chamado *bias*, que não depende de nenhuma entrada do neurônio. O resultado v_k dessa soma passa por uma função de ativação $\varphi(\cdot)$ para gerar a saída y_k do neurônio. A função geralmente é não linear, com o objetivo de limitar faixa de excursão do sinal de saída a um valor finito. Matematicamente, o modelo do neurônio pode ser descrito utilizando-se a Equação (3.1) [110].

$$y_k = \varphi(v_k) = \varphi\left(\sum_{j=1}^m w_{kj}x_j + b_k\right) \quad (3.1)$$

Figura 12 – Modelo não linear de um neurônio.



Fonte: adaptada de [110].


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 na Equação (3.2) [110]. Um neurônio que utilize tal função como função de ativação terá uma saída binária.

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq 0 \\ 0, & \text{se } v < 0 \end{cases} \quad (3.2)$$

As funções sigmóides 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 na Equação (3.3), em que a é o parâmetro que controla a inclinação da curva [110]. A Figura 13 ilustra os dois tipos de função de ativação.

$$\varphi(v) = \frac{1}{1 + \exp(-av)} \quad (3.3)$$

Figura 13 – Tipos de função de ativação: (a) função de limiar (degrau); (b) funções sigmóides logísticas com diferentes inclinações.



Fonte: adaptada de [110].

Os dois exemplos de função de ativação citados geram saídas y_k que assumem valores no intervalo $[0, 1]$. Em diversas aplicações, é interessante que a saída possa assumir valores no intervalo $[-1, 1]$ [110]. A função sinal, descrita conforme a Equação (3.4), é um exemplo de função de limiar com saída no intervalo $[-1, 1]$. Analogamente, a tangente hiperbólica, conforme a Equação (3.5), é um exemplo de função sigmoide que assume valores nesse mesmo intervalo.

$$\varphi(v) = \begin{cases} 1, & \text{se } v > 0 \\ 0, & \text{se } v = 0 \\ -1, & \text{se } v < 0 \end{cases} \quad (3.4)$$

$$\varphi(v) = \tanh(v) \quad (3.5)$$

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, é conveniente utilizar a normalização dos dados de entrada e, conseqüentemente, a desnormalização dos dados de saída ao final

do processo. Dessa forma, aproveita-se mais especificamente a região ativa da função de ativação, isto é, a região em que há a inclinação, sem alterar a relação entre as variáveis reais de entrada e de saída.

A disposição dos neurônios e a estrutura de interconexão entre eles é chamada de arquitetura da RNA. O tipo de arquitetura está intimamente ligado às aplicações e ao algoritmo de aprendizado da rede. Existem, basicamente, três tipos fundamentais de arquiteturas de redes.

As redes com arquitetura mais simples são as redes diretas de camada única. Sua estrutura está ilustrada na Figura 14(a). 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.

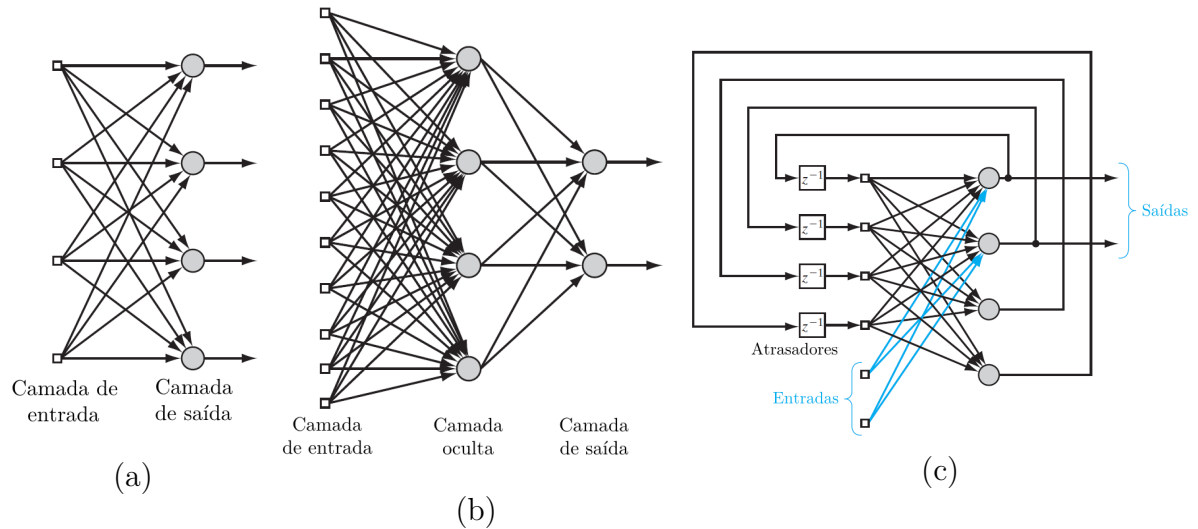
As redes diretas de múltiplas camadas também possuem fluxo de informação em apenas uma direção, porém, não apresentam conexões entre os nós de entrada e a camada de saída. Essa conexão é feita através de pelo menos uma camada oculta. A presença de camadas ocultas permite que a rede extraia estatísticas de mais alta ordem a partir de suas entradas [110]. 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. Se a rede desse tipo tiver funções de ativação diferenciáveis e alta conectividade, pode ser chamada de *perceptron* multicamadas. As RNAs consideradas neste trabalho serão *perceptrons* multicamadas. A Figura 14(b) mostra a estrutura de uma rede desse tipo.

O terceiro tipo de arquitetura consiste nas redes recorrentes, ou realimentadas. Esse tipo de rede possui pelo menos uma malha de realimentação em sua estrutura, ou seja, saídas anteriores da rede têm efeitos nos processamentos subsequentes. Devido aos atrasadores presentes na estrutura e ao comportamento não linear dos neurônios, as redes recorrentes exibem uma resposta dinâmica não linear às entradas [110]. Um exemplo de rede recorrente é mostrado na Figura 14(c).

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, na 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.

O processo de treinamento pode ser supervisionado, caso em que existe a figura do “especialista”, ou não supervisionado. No aprendizado supervisionado, o especialista é responsável por fornecer uma saída de referência para valores de entrada apresentados à

Figura 14 – Tipos de arquitetura de rede: (a) rede direta de camada única; (b) rede direta de múltiplas camadas; (c) rede recorrente.



Fonte: adaptada de [110].

rede. A comparação da resposta da rede a essas entradas com a saída de referência gera um sinal de erro que pode ser utilizado para atualizar os pesos sinápticos a fim de tornar o sinal de saída da rede mais próximo ao desejado, ou seja, à referência do especialista. No aprendizado não supervisionado, por outro lado, não há um especialista ou um sinal de referência; a rede deve aprender por meio da interação com as variáveis do ambiente e da experiência prévia. Neste trabalho, os processos de treinamento utilizados são do tipo supervisionado.

Pode-se treinar uma RNA para diversos objetivos. As RNAs são utilizadas tipicamente no reconhecimento de padrões, na aproximação de funções e em sistemas de controle. Em particular, 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. De fato, o teorema da aproximação universal garante que uma rede de arquitetura direta com uma camada oculta pode representar qualquer função contínua com precisão arbitrária, desde que tenha um número suficiente de neurônios na camada oculta [111–114]. 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 na simulação de sistemas e na modelagem de sistemas inversos.

Um método comum para o treinamento de redes de múltiplas camadas é a utilização de algoritmos do tipo *back-propagation*. O processo ocorre em duas fases e requer um conjunto de dados de exemplo para o treinamento. Primeiramente, os pesos sinápticos

iniciais, que podem ser atribuídos aleatoriamente ou de acordo com alguma heurística apropriada, são utilizados para gerar um sinal de saída para uma entrada do conjunto de treinamento. Em seguida, essa saída permite o cálculo de 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 atingir a meta de otimização ou algum critério de parada antecipada. Nesse processo, quando todos os exemplos disponíveis forem apresentados à rede, diz-se que foi completada uma época. Muitas épocas podem ser necessárias até a conclusão do treinamento.

A minimização do erro comumente envolve alguma implementação do método do gradiente descendente, que busca na superfície de erro a direção de máximo declive e avança nessa direção segundo uma taxa de aprendizado. Assim, um gradiente de magnitude baixa pode significar que um ponto de mínimo foi encontrado. Antes do treinamento, uma parte dos dados é reservada para validação e só é apresentada à rede para controle dos próprios parâmetros do treinamento. Além disso, um terceiro conjunto de dados é reservado para testes e não é apresentado à rede durante o treinamento. Portanto, a rede aprende utilizando o conjunto de treinamento, o conjunto de validação é usado para verificar a capacidade de generalização do conhecimento adquirido, e o conjunto de teste mede efetivamente o desempenho do aprendizado ao final do processo. Após um número predefinido de épocas, caso a rede se especialize nos dados de treinamento, mas perca desempenho no conjunto de validação, diz-se que houve uma falha de validação. 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 sobreajuste, ou *overfitting*. Um número grande de falhas de validação consecutivas durante o treinamento é um indicativo de sobreajuste.

Os critérios de parada mais comuns nos algoritmos de treinamento de redes neurais são o número máximo de épocas, o valor mínimo do gradiente da superfície de erro e o número máximo de falhas de validação. Como a parada antecipada é um tipo de regularização, que tem por objetivo evitar o sobreajuste, ao atingir um critério de parada, o algoritmo de aprendizado retorna os parâmetros da rede ao estado em que se encontravam quando o melhor desempenho foi encontrado, e esta será a configuração da rede treinada.

A utilização de um método do tipo gradiente descendente para atualização dos pesos dá origem a uma desvantagem importante: a escolha da taxa de aprendizado afeta criticamente o tempo de convergência. Se a taxa for muito pequena, são necessários muitos passos até encontrar uma solução aceitável. Por outro lado, se for muito grande, o algoritmo pode oscilar em torno do ponto ótimo sem a possibilidade de encontrá-lo, a depender do formato da função de erro. Algoritmos adaptativos, que alteram a taxa de aprendizado ao longo das iterações, surgiram com o objetivo de resolver esse problema: utilizam uma taxa de aprendizado alta sempre que possível para acelerar a convergência, mas a reduzem ao se aproximarem de um ponto ótimo para mitigar as oscilações. Muitos algoritmos adaptativos

usam a derivada da função de erro para atualizar a taxa de aprendizado [115], o que pode gerar um efeito negativo no desempenho do algoritmo devido ao comportamento imprevisível dessa derivada. RPROP [115] é um algoritmo adaptativo simples, que usa apenas o comportamento do sinal da derivada ao longo das iterações na atualização dos pesos, em vez de utilizar a sua magnitude. Sendo assim, é um algoritmo robusto, de rápida convergência e foi escolhido para o treinamento das redes neste trabalho.

Uma vez treinada, a rede possui valores otimizados dos pesos w_{kj} e b_k que permitem o cálculo das saídas de cada neurônio através da Equação (3.1). Neste trabalho, utilizaram-se as implementações de RNAs e de algoritmos de treinamento contidas no MATLAB durante as fases de projeto e de treinamento das redes. Nota-se que a operação da rede treinada envolve apenas operações matemáticas básicas, que podem ser implementadas em dispositivos simples.

3.2 REGRESSÃO LINEAR MÚLTIPLA

Regressão linear é o nome do processo de determinação dos parâmetros de um modelo linear [116]. O tipo mais simples de modelo linear busca explicar a relação entre uma variável dependente y , também chamada de variável resposta, e uma variável independente x , também chamada de preditor ou variável explicativa, da seguinte forma:

$$y = \beta_0 + \beta_1 x + \varepsilon, \quad (3.6)$$

em que β_0 é a interseção da reta de regressão com o eixo y e β_1 é o gradiente ou a inclinação da reta de regressão e ε é um erro aleatório [117, 118]. Em uma série de observações, a entrada x_i é associada à saída y_i com um erro ε_i . Geralmente se supõe que os erros ε_i são variáveis aleatórias independentes, normalmente distribuídas, com valor esperado $E(\varepsilon_i)$ igual a zero e variância $\text{Var}(\varepsilon_i) = \sigma^2$ [118]. O ajuste desse modelo é chamado regressão linear simples.

Uma forma de ajustar os parâmetros β_0 e β_1 é utilizar o método dos mínimos quadrados. Esse método visa encontrar as estimativas b_0 e b_1 tais que a soma dos quadrados das distâncias entre a resposta real y_i e a resposta predita $\hat{y}_i = \beta_0 + \beta_1 x_i$ atinja o mínimo entre todas as possíveis escolhas dos coeficientes de regressão β_0 e β_1 , ou seja:

$$(b_0, b_1) = \arg \min_{(\beta_0, \beta_1)} \sum_{i=1}^n [y_i - (\beta_0 + \beta_1 x_i)]^2, \quad (3.7)$$

em que n é o número de observações [118]. Nesse caso, $\hat{y} = b_0 + b_1 x$ é a reta de regressão ajustada, e a diferença entre y_i e o valor ajustado \hat{y}_i , $e_i = y_i - \hat{y}_i$, é chamada resíduo. Nota-se que os resíduos e_i são observáveis: podem ser calculados a partir das respostas observadas y_i e dos valores ajustados \hat{y}_i , ao contrário do termo de erro aleatório ε da

Equação (3.6), que representa o quanto uma observação difere do seu valor esperado [118]. O método dos mínimos quadrados é uma forma interessante de ajuste, porque é capaz de fornecer o melhor estimador linear não enviesado [117].

Em muitos problemas, a variável resposta y sofre a influência de mais de uma variável explicativa (x_1, x_2, \dots, x_k) . Nesses casos, utiliza-se a regressão linear múltipla. Um modelo linear múltiplo genérico pode ser escrito como na Equação (3.8) [118].

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon \quad (3.8)$$

É importante notar que x_1, x_2, \dots, x_k podem conter preditores e suas potências de mais alta ordem, ou ainda, funções de preditores, desde que essas funções não contenham parâmetros desconhecidos. Um modelo é dito linear quando apresenta linearidade nos parâmetros, isto é, quando é linear em relação aos β s. Todos os modelos na Equação (3.9) são exemplos de modelos lineares [118].

$$\begin{aligned} y &= \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \varepsilon \\ y &= \beta_0 + \beta_1 x_1 + \beta_2 x_1^2 + \beta_3 x_2 + \varepsilon \\ y &= \beta_0 + \beta_1 x_1 + \beta_2 x_1^2 + \beta_3 x_2 + \beta_4 x_1 x_2 + \varepsilon \\ y &= \beta_0 + \beta_1 x_1 + \beta_2 \ln(x_1) + \beta_3 \ln(x_2) + \varepsilon \end{aligned} \quad (3.9)$$

Por outro lado, para comparação, a Equação (3.10) mostra exemplos de modelos não lineares, que demandam uma análise que foge ao escopo deste trabalho [118].

$$\begin{aligned} y &= \beta_0 + \beta_1 x_1 + \beta_2 x_2^\gamma + \varepsilon \\ y &= \frac{1}{\lambda + \exp(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k)} + \varepsilon \end{aligned} \quad (3.10)$$

Para o ajuste de um modelo de regressão linear múltipla utilizando o método dos mínimos quadrados, é conveniente usar a notação matricial. O modelo:

$$y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_k x_{ki} + \varepsilon_i, \quad (3.11)$$

em que $\beta_0, \beta_1, \beta_2, \dots, \beta_k$ são os coeficientes da regressão a determinar e $i \in \mathbb{N} \mid i \leq n$, pode ser escrito na forma matricial como:

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}, \quad (3.12)$$

em que, usando a notação $[\cdot]^T$ para a transposição de matriz:

$$\mathbf{y} = [y_1 \ y_2 \ \dots \ y_n]^T, \quad (3.13a)$$

$$\mathbf{X} = \begin{bmatrix} 1 & x_{11} & x_{12} & \cdots & x_{1k} \\ 1 & x_{21} & x_{22} & \cdots & x_{2k} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & \cdots & x_{nk} \end{bmatrix}, \quad (3.13b)$$

$$\boldsymbol{\beta} = \begin{bmatrix} \beta_0 & \beta_1 & \beta_2 & \cdots & \beta_k \end{bmatrix}^T, \quad (3.13c)$$

$$\boldsymbol{\varepsilon} = \begin{bmatrix} \varepsilon_1 & \varepsilon_2 & \cdots & \varepsilon_n \end{bmatrix}^T. \quad (3.13d)$$

A estimativa \mathbf{b} para o vetor de coeficientes $\boldsymbol{\beta}$, de acordo com o método dos mínimos quadrados, fica:

$$\mathbf{b} = \arg \min_{\boldsymbol{\beta}} \left[(\mathbf{y} - \mathbf{X}\boldsymbol{\beta})^T (\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) \right], \quad (3.14)$$

em que \mathbf{b} é um vetor de estimativas de acordo com:

$$\mathbf{b} = \begin{bmatrix} b_0 & b_1 & b_2 & \cdots & b_k \end{bmatrix}^T. \quad (3.15)$$

A solução da Equação (3.14) será dada pela Equação (3.16), desde que $\mathbf{X}^T \mathbf{X}$ seja uma matriz não singular [118]. Essa condição é equivalente à de que as colunas de \mathbf{X} sejam independentes.

$$\mathbf{b} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y} \quad (3.16)$$

A partir da obtenção do valor de \mathbf{b} , é possível calcular a predição $\hat{\mathbf{y}}$ do modelo para \mathbf{y} como sendo:

$$\hat{\mathbf{y}} = \mathbf{X}\mathbf{b}, \quad (3.17)$$

com resíduo $\mathbf{e} = \mathbf{y} - \hat{\mathbf{y}}$.

3.3 EXTRAÇÃO DE CARACTERÍSTICAS

A extração de características é uma parte da teoria de reconhecimento de padrões. Pode ser descrita como uma transformação que mapeia o ponto \mathbf{x} de um espaço de dados m -dimensional para um ponto \mathbf{y} em um espaço de características q -dimensional, com $q < m$ [110]. Essa transformação pode ser vista como uma redução de dimensionalidade, ou compressão de dados, o que simplifica a tarefa de processamento que ocorrerá em seguida [110].

O tipo de análise utilizado neste trabalho segue a metodologia de extração de características de sinais de áudio. Sinais de áudio são unidimensionais no tempo e seus espectros são unidimensionais na frequência, bem como os traços de OTDR são

unidimensionais no comprimento da fibra. Verifica-se que algumas análises utilizadas em sinais de áudio, incluindo seus espectros, são capazes de revelar informação sobre os traços de OTDR em questão.

Nas tarefas de mineração de dados e de reconhecimento de padrões, encontrar um conjunto de características compacto e eficaz é considerado um passo crucial no processo de solução de problemas [119]. No contexto de sinais de áudio, existem diferentes conjuntos de descritores de características. Dois esquemas comuns são o de descritores baseados no padrão MPEG-7 e o de coeficientes mel-cepstrais (*Mel-Frequency Cepstrum Coefficients* - MFCC) [119]. No entanto, descritores de características baseadas em percepção são mais simples e são capazes de evidenciar a informação desejada nos conjuntos de dados utilizados neste trabalho. Esses descritores serão apresentados a seguir.

Um descritor de características importante em sinais de áudio é a raiz do valor quadrático médio (*Root Mean Square* - RMS), ou valor eficaz. O valor RMS de um sinal $x[n]$ com N pontos é calculado da seguinte forma:

$$\text{RMS} = \sqrt{\frac{1}{N} \sum_{n=1}^N x^2[n]}, \quad (3.18)$$

e pode ser usado como uma medida da magnitude do sinal [119]. Trivialmente, o valor quadrático médio (VQM) é o quadrado do valor RMS e também está relacionado com o tamanho do sinal, especificamente com a sua energia.

$$\text{VQM} = \frac{1}{N} \sum_{n=1}^N x^2[n] \quad (3.19)$$

Seja $P(f_k)$ a magnitude do espectro de um sinal de áudio no k -ésimo intervalo de frequências, e f_k a frequência central desse intervalo. O sinal está dividido em K intervalos de frequência. O centroide espectral (CE) é a média das frequências ponderadas pelo espectro, conforme a Equação (3.20) [119], e representa a localização do centro de massa da figura formada abaixo do gráfico do espectro. Essa grandeza pode ser considerada um descritor de característica tendo em vista que a localização do centroide espectral indica em torno de quais frequências o espectro está distribuído.

$$\text{CE} = \frac{\sum_{k=1}^K P(f_k) f_k}{\sum_{k=1}^K P(f_k)} \quad (3.20)$$

A partir do valor do centroide espectral, pode-se definir a largura de banda (LB) como o intervalo de frequências do sinal ponderado pelo seu espectro, conforme a Equação 3.21 [119]. Essa grandeza pode ser vista como indicador da concentração do espectro em torno do seu centroide.

$$\text{LB} = \frac{\sum_{k=1}^K |\text{CE} - f_k| P(f_k)}{\sum_{k=1}^K P(f_k)} \quad (3.21)$$

Ainda no domínio do espectro, pode-se definir o fluxo espectral (FE) como a quantidade de variação espectral local, calculada como o quadrado da diferença entre as magnitudes normalizadas de distribuições espectrais consecutivas, como na Equação (3.22) [119].

$$\text{FE} = \sum_{k=2}^K \left| P(f_k) - P(f_{k-1}) \right|^2 \quad (3.22)$$

O cálculo dos descritores acima apresenta um grande potencial de redução da dimensionalidade de um sinal de áudio. Basta notar que um sinal com N pontos pode ser representado por uma combinação dos seus descritores: valor quadrático médio, centroide espectral, largura de banda e fluxo espectral. Ao reduzir a dimensionalidade de um conjunto de dados, é necessário evitar a perda de informação relevante, o que depende da aplicação específica. Sinais redundantes, por exemplo, sinais que apresentam variação lenta e amostras adjacentes similares, têm maior chance de manter a informação relevante em uma representação resumida desse tipo. Caso uma representação no espaço de características tenha sucesso, o processamento subsequente terá sua complexidade reduzida devido à redução da dimensionalidade em relação ao espaço de dados.

3.4 ANÁLISE DE COMPONENTES PRINCIPAIS

A análise de componentes principais (*Principal Component Analysis* - PCA), também conhecida na teoria de comunicações como transformada de Karhunen-Loève, é uma transformação linear que leva vetores de um espaço de dados para um espaço de características de uma maneira que evidencia quais componentes têm maior contribuição para explicar a variância dos dados, ao maximizar a taxa de decréscimo da variância ao longo das componentes [110]. As variáveis desse novo espaço são chamadas de componentes principais, são descorrelacionadas entre si e são ordenadas de forma que as primeiras variáveis contêm a maior parte da variância presente em todas as variáveis do espaço original [120].

A seguir, será apresentada a definição da PCA conforme Jolliffe [120]. Seja \mathbf{x} um vetor de p variáveis aleatórias, em que as variâncias das p variáveis aleatórias e a estrutura das covariâncias ou correlações entre as p variáveis sejam de interesse. Em geral, a mera observação das p variâncias e das $\frac{1}{2}p(p-1)$ correlações ou covariâncias oferece pouco entendimento sobre o problema, a menos que este seja simples. Uma alternativa é buscar variáveis secundárias que, em número muito menor que p , preservem o máximo da

informação oferecida por essas variâncias e correlações ou covariâncias. O primeiro passo seria buscar uma função linear $\boldsymbol{\alpha}_1^T \mathbf{x}$ dos elementos de \mathbf{x} tendo máxima variância, em que $\boldsymbol{\alpha}_1$ é um vetor de p constantes $\alpha_{11}, \alpha_{12}, \dots, \alpha_{1p}$, e $(\cdot)^T$ denota transposição, de forma que:

$$\boldsymbol{\alpha}_1^T \mathbf{x} = \alpha_{11}x_1 + \alpha_{12}x_2 + \dots + \alpha_{1p}x_p = \sum_{j=1}^p \alpha_{1j}x_j. \quad (3.23)$$

Em seguida, busca-se uma função linear $\boldsymbol{\alpha}_2^T \mathbf{x}$, descorrelacionada de $\boldsymbol{\alpha}_1^T \mathbf{x}$, tendo máxima variância, e assim por diante, até que, no k -ésimo passo, encontra-se uma função linear $\boldsymbol{\alpha}_k^T \mathbf{x}$ que tenha máxima variância, restrita a ser descorrelacionada de $\boldsymbol{\alpha}_1^T \mathbf{x}, \boldsymbol{\alpha}_2^T \mathbf{x}, \dots, \boldsymbol{\alpha}_{k-1}^T \mathbf{x}$. A k -ésima variável secundária $\boldsymbol{\alpha}_k^T \mathbf{x}$ é a k -ésima componente principal. Pode-se encontrar até p componentes principais, mas, em geral, espera-se que a maior parte da variância contida em \mathbf{x} seja explicada por m componentes principais, com $m \ll p$. Em particular, escolher $m = 2$ pode oferecer uma forma razoavelmente fiel de representar dados multidimensionais graficamente.

Seja $\boldsymbol{\Sigma}$ a matriz de covariância do vetor de variáveis aleatórias \mathbf{x} . Nessa matriz, o elemento (i, j) é a covariância entre o i -ésimo e o j -ésimo elementos de \mathbf{x} , quando $i \neq j$, ou a variância do j -ésimo elemento de \mathbf{x} , quando $i = j$. Caso a matriz de covariância $\boldsymbol{\Sigma}$ não seja conhecida, pode-se substituí-la por uma matriz de covariância amostral \mathbf{S} . Para $k \in \mathbb{N} \mid k \leq p$, a k -ésima componente principal é dada por $z_k = \boldsymbol{\alpha}_k^T \mathbf{x}$, em que $\boldsymbol{\alpha}_k$ é um autovetor de $\boldsymbol{\Sigma}$ correspondente ao seu k -ésimo maior autovalor λ_k . Além disso, se $\boldsymbol{\alpha}_k$ for escolhido para ter comprimento unitário ($\boldsymbol{\alpha}_k^T \boldsymbol{\alpha}_k = 1$), então $\text{var}(z_k) = \lambda_k$, em que $\text{var}(z_k)$ denota a variância de z_k .

Para demonstrar essas afirmativas no caso da primeira componente principal $\boldsymbol{\alpha}_1^T \mathbf{x}$, sabe-se que o vetor $\boldsymbol{\alpha}_1$ deve maximizar $\text{var}(\boldsymbol{\alpha}_1^T \mathbf{x})$. Usando a matriz de covariância como um operador linear, pode-se escrever:

$$\text{var}(\boldsymbol{\alpha}_1^T \mathbf{x}) = \boldsymbol{\alpha}_1^T \boldsymbol{\Sigma} \boldsymbol{\alpha}_1. \quad (3.24)$$

Para maximizar essa variância, sujeita à condição de que $\boldsymbol{\alpha}_1$ seja um vetor unitário, ou $\boldsymbol{\alpha}_1^T \boldsymbol{\alpha}_1 = 1$, utiliza-se a técnica dos multiplicadores de Lagrange. A função de Lagrange, nesse caso, é:

$$\mathcal{L}(\boldsymbol{\alpha}_1, \lambda) = \boldsymbol{\alpha}_1^T \boldsymbol{\Sigma} \boldsymbol{\alpha}_1 - \lambda (\boldsymbol{\alpha}_1^T \boldsymbol{\alpha}_1 - 1), \quad (3.25)$$

em que λ é um multiplicador de Lagrange. O valor de máximo procurado, sujeito à condição acima, será um dos pontos críticos da função de Lagrange. Igualar a zero a derivada em relação a $\boldsymbol{\alpha}_1$ fornece:

$$2\boldsymbol{\alpha}_1^T \boldsymbol{\Sigma} - 2\lambda \boldsymbol{\alpha}_1^T = \mathbf{0}, \quad (3.26)$$

que, simplificando e aplicando a transposição, leva a:

$$\mathbf{\Sigma}\boldsymbol{\alpha}_1 - \lambda\boldsymbol{\alpha}_1 = \mathbf{0}, \quad (3.27)$$

que também pode ser escrita na forma:

$$(\mathbf{\Sigma} - \lambda\mathbf{I}_p)\boldsymbol{\alpha}_1 = \mathbf{0}, \quad (3.28)$$

em que \mathbf{I}_p é a matriz identidade $p \times p$. Portanto, por definição, λ é um autovalor de $\mathbf{\Sigma}$, e $\boldsymbol{\alpha}_1$ é o autovetor correspondente. Para decidir qual dos p autovalores fornece $\boldsymbol{\alpha}_1^T \mathbf{x}$ com a máxima variância, nota-se que a quantidade a ser maximizada é:

$$\boldsymbol{\alpha}_1^T \mathbf{\Sigma} \boldsymbol{\alpha}_1 = \boldsymbol{\alpha}_1^T \lambda \boldsymbol{\alpha}_1 = \lambda \boldsymbol{\alpha}_1^T \boldsymbol{\alpha}_1 = \lambda, \quad (3.29)$$

de forma que λ deve ser o maior possível. Finalmente, $\boldsymbol{\alpha}_1$ é o autovetor correspondente ao maior autovalor de $\mathbf{\Sigma}$, e $\text{var}(\boldsymbol{\alpha}_1^T \mathbf{x}) = \boldsymbol{\alpha}_1^T \mathbf{\Sigma} \boldsymbol{\alpha}_1 = \lambda_1$, o maior autovalor.

No caso da segunda componente principal, $\boldsymbol{\alpha}_2^T \mathbf{x}$ maximiza $\boldsymbol{\alpha}_2^T \mathbf{\Sigma} \boldsymbol{\alpha}_2$, sujeita às condições de que $\boldsymbol{\alpha}_2$ seja um vetor unitário ($\boldsymbol{\alpha}_2^T \boldsymbol{\alpha}_2 = 1$) e de que $\boldsymbol{\alpha}_2^T \mathbf{x}$ seja descorrelacionada de $\boldsymbol{\alpha}_1^T \mathbf{x}$ ($\text{cov}(\boldsymbol{\alpha}_1^T \mathbf{x}, \boldsymbol{\alpha}_2^T \mathbf{x}) = 0$). A condição de descorrelação pode ser escrita de diferentes formas:

$$\text{cov}(\boldsymbol{\alpha}_1^T \mathbf{x}, \boldsymbol{\alpha}_2^T \mathbf{x}) = \boldsymbol{\alpha}_1^T \mathbf{\Sigma} \boldsymbol{\alpha}_2 = \boldsymbol{\alpha}_2^T \mathbf{\Sigma} \boldsymbol{\alpha}_1 = \boldsymbol{\alpha}_2^T \lambda_1 \boldsymbol{\alpha}_1 = \lambda_1 \boldsymbol{\alpha}_2^T \boldsymbol{\alpha}_1 = \lambda_1 \boldsymbol{\alpha}_1^T \boldsymbol{\alpha}_2 = 0 \quad (3.30)$$

A função de Lagrange pode ser escrita usando qualquer um desses termos. Escolhendo $\boldsymbol{\alpha}_2^T \boldsymbol{\alpha}_1 = 0$, tem-se:

$$\mathcal{L}(\boldsymbol{\alpha}_2, \lambda, \phi) = \boldsymbol{\alpha}_2^T \mathbf{\Sigma} \boldsymbol{\alpha}_2 - \lambda (\boldsymbol{\alpha}_2^T \boldsymbol{\alpha}_2 - 1) - \phi \boldsymbol{\alpha}_2^T \boldsymbol{\alpha}_1, \quad (3.31)$$

em que λ, ϕ são multiplicadores de Lagrange. Igualando a zero a derivada em relação a $\boldsymbol{\alpha}_2$:

$$2\boldsymbol{\alpha}_2^T \mathbf{\Sigma} - 2\lambda \boldsymbol{\alpha}_2^T - \phi \boldsymbol{\alpha}_1^T = \mathbf{0}, \quad (3.32)$$

aplicando a transposição:

$$2\mathbf{\Sigma} \boldsymbol{\alpha}_2 - 2\lambda \boldsymbol{\alpha}_2 - \phi \boldsymbol{\alpha}_1 = \mathbf{0}, \quad (3.33)$$

e pré-multiplicando por $\boldsymbol{\alpha}_1^T$, chega-se a:

$$2\boldsymbol{\alpha}_1^T \mathbf{\Sigma} \boldsymbol{\alpha}_2 - 2\lambda \boldsymbol{\alpha}_1^T \boldsymbol{\alpha}_2 - \phi \boldsymbol{\alpha}_1^T \boldsymbol{\alpha}_1 = 0. \quad (3.34)$$

A condição de decorrelação zero os dois primeiros termos na Equação (3.34), enquanto a normalização de α_1 significa que $\alpha_1^T \alpha_1 = 1$. Portanto, a equação se reduz a $\phi = 0$. Com isso, $\Sigma \alpha_2 - \lambda \alpha_2 = 0$, ou, equivalentemente, $(\Sigma - \lambda \mathbf{I}_p) \alpha_2 = 0$, então λ é, mais uma vez, um autovalor de Σ , e α_2 o autovetor correspondente. Novamente, $\lambda = \alpha_2^T \Sigma \alpha_2$, então λ deve ser o maior possível. Supondo que Σ não tenha autovalores repetidos, λ não pode ser igual a λ_1 . Logo, λ é o segundo maior autovalor de Σ , e α_2 é o autovetor correspondente.

Analogamente, pode-se demonstrar que, para as próximas componentes principais, os vetores de coeficientes α_k serão os autovetores de Σ na ordem decrescente da magnitude dos autovalores λ_k correspondentes. Além disso, $\text{var}(\alpha_k^T \mathbf{x}) = \lambda_k$, com $k \in \mathbb{N} \mid k \leq p$.

Para realizar efetivamente a redução da dimensionalidade, dois problemas devem ser considerados: (i) como determinar a quantidade m de componentes principais que deve ser mantida para minimizar a perda de informação e (ii) como escolher m dentre as p variáveis originais x_k , com $k \in \mathbb{N} \mid k \leq p$, que devem ser mantidas, de forma que a perda de informação seja mínima. O primeiro problema pode ser resolvido usando um critério baseado na porcentagem da variância total explicada pelas primeiras componentes principais ou usando um critério baseado nas magnitudes das variâncias das componentes principais, entre outros critérios. O critério utilizado neste trabalho se baseia no desempenho do modelo em um método de validação cruzada, conforme definido na Seção 3.5. O número de variáveis mantidas foi incrementado progressivamente até que o desempenho parasse de mostrar melhora, e o número m de variáveis escolhidas foi o mínimo necessário para obter a precisão desejada. Já o segundo problema pode ser resolvido de uma das três formas sugeridas por Jolliffe [120] e descritas abaixo.

- a) Associar uma variável a cada uma das últimas m_1^* ($= p - m_1$) componentes principais e descartar essas m_1^* variáveis. Isso pode ser feito uma vez ou iterativamente. Nesse último caso, uma segunda PCA é calculada nas m_1 variáveis restantes, e um novo conjunto de m_2^* variáveis é descartado, se for apropriado. Esse processo pode se repetir até que não seja considerado necessário descartar mais variáveis.
- b) Associar um conjunto de m^* variáveis, em bloco, às últimas m^* componentes principais e descartar essas variáveis. Esse método mostrou resultados insatisfatórios comparativamente aos outros dois.
- c) Associar uma variável com cada uma das m primeiras componentes principais, em particular, a variável ainda não escolhida que apresente o maior coeficiente, em módulo, em cada componente principal sucessiva. Essas m variáveis são mantidas, e as $m^* = p - m$ restantes são descartadas.

Neste trabalho, o método descrito no item c) foi considerado mais conveniente, do ponto de vista da implementação, e foi escolhido nas duas aplicações da PCA para

redução de dimensionalidade, apresentadas nas Seções 5.3 e 5.5.

3.5 VALIDAÇÃO CRUZADA K-FOLD

A validação cruzada é um procedimento realizado na tentativa de otimizar a complexidade de um modelo de forma que minimize o erro de classificação ou de aproximação em um conjunto de dados independente [121]. Pode-se usar a validação cruzada para determinar o melhor número de neurônios na camada oculta de uma RNA ou para descobrir quando é adequado interromper um processo de treinamento [110]. Em uma aplicação envolvendo aprendizado de máquina, idealmente, se existir um número suficiente de observações, após separar uma parte dos dados para teste, o conjunto de dados deveria ser dividido em um subgrupo de treinamento e um de validação, cada um com 50 % dos dados [122]. Na prática, no entanto, os conjuntos de dados dificilmente têm um número de observações suficiente para fazer isso e alcançar um desempenho adequado. Uma solução, em conjuntos de dados pequenos, é usar repetidamente os mesmos dados, mas particionados de formas diferentes, o que é chamado de validação cruzada [122].

Na validação cruzada do tipo *k-fold*, um conjunto de dados \mathbf{X} é dividido aleatoriamente em k partes \mathbf{X}_i do mesmo tamanho, com $i \in \mathbb{N} \mid i \leq k$ [122]. Cada parte \mathbf{X}_i também pode ser chamada de *fold*. Uma das partes é usada como conjunto de validação, e as $k - 1$ restantes são combinadas para formar o conjunto de treino. Isso é feito k vezes, cada vez escolhendo uma parte diferente como validação. O desempenho do sistema sob ajuste é medido em cada conjunto de validação, e a média do desempenho em cada um dos k diferentes conjuntos de validação é definida como o desempenho do modelo na validação cruzada [123]. Esse valor pode ser usado para comparar diferentes modelos ou diferentes configurações de um mesmo modelo.

Em um problema de classificação, é importante que, em cada um dos subconjuntos \mathbf{X}_i , as classes estejam representadas na mesma proporção em que ocorrem no conjunto total \mathbf{X} para não perturbar as probabilidades *a priori* das classes [122]. Isso é chamado de estratificação. Em problemas de regressão, esse procedimento não é essencial, visto que cada ponto experimental pode ser diferente, mas ainda pode ser feito de acordo com similaridades entre as observações em \mathbf{X} .

Ao final do procedimento de validação cruzada *k-fold*, um modelo é selecionado. Porém, o modelo selecionado não está imediatamente pronto para uso em técnicas de classificação ou de regressão. É necessário realizar um novo treinamento, considerando o conjunto de dados inteiro \mathbf{X} [118]. Finalmente, para avaliar o desempenho do modelo final, é necessário um novo conjunto de dados para teste, que pode ter sido reservado antes do procedimento de validação cruzada ou pode conter observações experimentais totalmente novas.

4 SISTEMA DE INTERROGAÇÃO BASEADO EM BANCO DE FILTROS E REDE NEURAL ARTIFICIAL

Neste capítulo, será apresentado o sistema de interrogação para sensores do tipo grade de período longo (*Long-Period Grating* - LPG) proposto e publicado em [124]. O sistema é baseado na separação do sinal oriundo do sensor em diferentes sub-bandas e posterior processamento por uma rede neural artificial (RNA) treinada para esse fim. A principal vantagem desse sistema é a dispensa do uso de um analisador de espectro óptico (*Optical Spectrum Analyzer* - OSA), que pode chegar às centenas de milhares de reais, ou de outros equipamentos de alto custo. Os resultados mostram que o sistema pode ser utilizado de forma eficaz para interrogação em uma faixa dinâmica limitada apenas pela largura de banda da fonte de luz.

O dispositivo central desta pesquisa é uma LPG funcionando como sensor de temperatura. O foco da pesquisa é a interrogação, já que o sistema sensor é bem conhecido. Em laboratório, a resposta do sensor é comumente obtida através do uso de um OSA, que é um dispositivo pouco portátil e de alto custo. Em aplicações de campo, técnicas de interrogação alternativa são preferíveis, frequentemente envolvendo a filtragem óptica do sinal de saída do sensor. Métodos alternativos de interrogação são discutidos em [125, 126], em que são usadas grades de Bragg (*Fiber Bragg Gratings* - FBGs) como filtros ópticos. A principal vantagem do uso de métodos alternativos de interrogação é a redução de custos, juntamente com a portabilidade e a facilidade de automação.

Os métodos de interrogação que utilizam filtragem óptica demandam algum processamento para extrair corretamente a informação de alto nível que se busca. Técnicas de inteligência artificial têm sido aplicadas com sucesso no processamento de dados de sensores para o propósito da interrogação, especialmente usando RNAs [127–129]. Tais técnicas tendem a apresentar maior exatidão do que procedimentos convencionais de ajuste de curvas [130]. Em um trabalho anterior [103], propôs-se um sistema de interrogação para um sensor FBG, o qual é estendido neste trabalho para a interrogação de um sensor LPG.

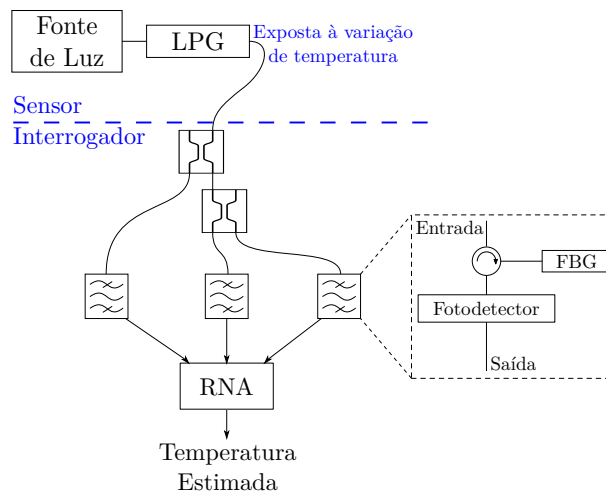
Neste capítulo, a Seção 4.1 apresenta a composição e a configuração do sistema proposto. A Seção 4.2 explica o princípio de funcionamento deste sistema desde a saída do sensor até a produção da estimativa da temperatura medida. A arquitetura e o funcionamento da rede neural são apresentados na Seção 4.3. Na Seção 4.4, é apresentada a relação entre a quantidade dos filtros e a faixa dinâmica do interrogador, e entre o espaçamento entre os filtros e a exatidão do sistema. Os testes e resultados utilizando o sistema proposto estão expostos na Seção 4.5. Finalmente, a Seção 4.6 encerra o capítulo com uma discussão dos resultados obtidos.

4.1 CONFIGURAÇÃO DO SENSOR E DO INTERROGADOR

O sistema sensor é composto de uma fonte de luz, uma seção de fibra e uma LPG. A inovação dessa pesquisa encontra-se no método de interrogação. A luz é emitida pela fonte, um diodo superluminescente (*Superluminescent Diode* - SLD), e propaga-se através da fibra até um sensor LPG. A LPG insere bandas de atenuação centradas em comprimentos de onda ressonantes que dependem da temperatura do meio externo. O sistema de interrogação, que é composto de acopladores, de circuladores, de filtros baseados em FBG e de fotodetectores, deve processar a informação recebida do sensor e retornar o valor estimado da temperatura. Para atingir esse objetivo, o sinal de saída do sensor é filtrado por FBGs centradas em comprimentos de onda adequados, a fim de permitir a identificação da resposta do sensor. A saída de cada filtro é, então, coletada por um fotodetector, digitalizada e enviada à RNA para o processamento. A RNA é responsável por identificar a temperatura do entorno do sensor a partir das saídas dos fotodetectores e por retornar o valor estimado da temperatura em graus Celsius.

A Figura 15 mostra a configuração descrita acima para um interrogador baseado em três filtros. Tendo em vista que os filtros devem cobrir, conjuntamente, toda a faixa de excursão do sensor, pode ser necessária uma quantidade maior de filtros. A Seção 4.4 aprofunda a discussão sobre faixa dinâmica e exatidão neste sistema.

Figura 15 – Configuração do sensor e do interrogador baseado em três filtros.



Fonte: adaptada de [124].

4.2 PRINCÍPIO DE INTERROGAÇÃO

A interrogação é baseada na separação do sinal do sensor em sub-bandas e na análise da potência óptica contida em cada sub-banda. A separação do sinal é realizada

pelo conjunto de filtros mostrado na Figura 15, em que cada filtro tem um comprimento de onda de ressonância diferente, cobrindo a faixa de excursão do sensor. Na saída de cada filtro, o fotodetector produz uma corrente elétrica proporcional à potência óptica contida na respectiva sub-banda, que varia com a temperatura à medida que o vale ressonante da LPG é deslocado. A dependência da potência filtrada com a temperatura é explicada pelo deslocamento da resposta do sensor LPG em direção a comprimentos de onda mais longos ou mais curtos de acordo com a variação de temperatura, que altera a distribuição de energia entre as sub-bandas. Portanto, para temperaturas diferentes, cada filtro experimenta uma diferente intensidade de potência de entrada na região espectral do seu comprimento de onda central. Sendo assim, a informação da temperatura encontra-se modulada nos valores de saída dos filtros, e é a responsabilidade da rede neural associar esses valores à respectiva temperatura.

Os valores de saída dos fotodetectores são interpretados como um vetor $\mathbf{x} \in \mathbb{R}^{N_f \times 1}$, em que N_f é o número de filtros. Esse vetor \mathbf{x} é a entrada da RNA. Nota-se que a RNA terá tantas entradas quantos forem os filtros, e uma saída: a temperatura estimada. As entradas da RNA são normalizadas antes do processamento, usando a fórmula de normalização:

$$\hat{\mathbf{x}} = \frac{2(\mathbf{x} - x_{\min})}{x_{\max} - x_{\min}} - 1, \quad (4.1)$$

que mapeia a informação de \mathbf{x} no intervalo $[-1, 1]$, gerando o vetor normalizado $\hat{\mathbf{x}}$. Os parâmetros de normalização x_{\min} e x_{\max} são os valores mínimo e máximo, respectivamente, de saída dos fotodetectores obtidos durante o treinamento. Esse processo de normalização é comum em aplicações de RNA e decorre da saturação inerente às funções de ativação. Como a RNA processa os valores normalizados dos fotodetectores, qualquer flutuação da fonte de luz, sentida por todos os filtros simultaneamente, não será considerada pelo procedimento de estimação da temperatura.

4.3 A REDE NEURAL ARTIFICIAL

Uma RNA é uma técnica de aprendizado de máquina que leva em consideração as não linearidades entre os dados de entrada e a grandeza que se quer estimar. A RNA em questão é um *perceptron* multicamadas (*Multilayer Perceptron* - MLP) que foi treinado usando o algoritmo de aprendizado *resilient propagation* (RPROP), cujo processo de aprendizado não é influenciado pela magnitude da derivada, dependendo apenas do comportamento temporal do seu sinal [115].

Utilizou-se uma camada oculta para processar os dados de entrada e testaram-se diferentes quantidades de neurônios para essa camada. A função de ativação na camada oculta é uma tangente hiperbólica. Na camada de saída, a função de ativação é linear.

Esses parâmetros estão de acordo com a utilização típica de redes neurais em problemas de aproximação de funções e com o teorema da aproximação universal [111–114].

Neste trabalho, adotou-se uma RNA rasa apresentando três camadas: a camada de entrada (camada 0), a camada oculta (camada 1) e a camada de saída (camada 2). Sejam $\hat{\mathbf{x}} \in \mathbb{R}^{N_0 \times 1}$ o *feature* normalizado (ou vetor de entrada), $\mathbf{W}_i \in \mathbb{R}^{N_i \times N_{i-1}}$ a matriz de pesos da i -ésima camada, $\mathbf{b}_i \in \mathbb{R}^{N_i \times 1}$ o vetor de *bias* da i -ésima camada e $N_i \in \mathbb{N}$ o número de neurônios na i -ésima camada. O potencial de ativação da camada oculta $\mathbf{v}_1 \in \mathbb{R}^{N_1 \times 1}$ é dado por [131]:

$$\mathbf{v}_1 = \mathbf{W}_1 \hat{\mathbf{x}} + \mathbf{b}_1 \quad (4.2)$$

O vetor de saída da camada oculta $\mathbf{y}_1 \in \mathbb{R}^{N_1 \times 1}$ pode ser calculado por [131]:

$$\mathbf{y}_1 = \varphi(\mathbf{v}_1), \quad (4.3)$$

em que $\varphi(\cdot) : \mathbb{R}^{N_1 \times 1} \rightarrow \mathbb{R}^{N_1 \times 1}$ é um operador que aplica a função hiperbólica $\tanh(\cdot)$ a cada elemento. O potencial de ativação da camada de saída $\mathbf{v}_2 \in \mathbb{R}^{N_2 \times 1}$ é, portanto:

$$\mathbf{v}_2 = \mathbf{W}_2 \mathbf{y}_1 + \mathbf{b}_2 \quad (4.4)$$

A camada de saída, que tem função de ativação linear, produz um vetor $\mathbf{y}_2 \in \mathbb{R}^{N_2 \times 1}$ dado por:

$$\mathbf{y}_2 = \mathbf{v}_2 \quad (4.5)$$


Como está estabelecido que a rede terá apenas uma saída, ou um neurônio na última camada, então a estrutura da RNA utilizada fornece como saída um valor $\hat{y} \in \mathbb{R}$ que se dá em função da entrada $\hat{\mathbf{x}}$ da seguinte maneira:

$$\hat{y} = \mathbf{W}_2 \varphi(\mathbf{W}_1 \hat{\mathbf{x}} + \mathbf{b}_1) + \mathbf{b}_2, \quad (4.6)$$

em que \mathbf{W}_i e \mathbf{b}_i (para $i \in \{1, 2\}$) contêm os parâmetros ajustáveis da RNA, que se calculam na fase de treinamento. A saída normalizada \hat{y} é, então, desnormalizada, produzindo-se a saída significativa do sistema y ; nesse caso, a temperatura estimada.

A Figura 16 apresenta uma visualização gráfica da rede descrita acima para o caso de um sistema com três entradas e três neurônios na camada oculta. Ao longo dos testes ambos os valores serão ajustados em busca de um sistema otimizado. Nessa figura, cada neurônio exibe o gráfico da sua função de ativação. Nota-se que a arquitetura altamente paralela da RNA favorece a sua implementação em um arranjo de porta programável em campo (*Field Programmable Gate Array* - FPGA), que permite acelerar o processamento dos dados de forma paralela e não linear [132].

Figura 16 – RNA com três entradas e três neurônios na camada oculta.



Fonte: elaborada pelo autor (2023).

4.4 FAIXA DINÂMICA E EXATIDÃO

A faixa dinâmica do sistema é definida pela largura de banda da fonte de luz usada, considerando a sensibilidade do sensor. Para um dado sensor LPG, a faixa dinâmica pode ser ampliada utilizando-se uma fonte de banda mais larga, que permite a interrogação do sensor numa faixa de excursão maior. Esse procedimento aumenta a faixa dinâmica ainda que insira ressonâncias dos modos adjacentes da LPG na banda da fonte. Como a RNA deve ser treinada adequadamente usando o padrão criado por cada montagem específica, a existência de novos modos não prejudica a interrogação que utiliza esse método. Pelo contrário, ao incluir informação independente adicional, o processo de estimação tende a apresentar maior exatidão, às custas de um aumento no tempo de treinamento [131].

A exatidão do processo de estimação depende do volume de informação independente obtido pelos filtros, especialmente quando métodos de decorrelação não são empregados [131]. Se o espaçamento espectral entre os filtros for grande, as lacunas podem dar origem a leituras ambíguas, no sentido de que as saídas dos filtros podem ser as mesmas para temperaturas diferentes. Dados ambíguos são uma importante fonte de erro, já que a RNA pode tornar-se incapaz de identificar a temperatura correta. A fim de impedir que isso ocorra, o número de filtros e o espaçamento espectral entre eles devem ser projetados adequadamente.

Dessa forma, a escolha do número de filtros e do espaçamento entre as suas ressonâncias deve contemplar dois objetivos: (i) cobrir integralmente a faixa espectral de emissão da fonte de luz, para maior aproveitamento da faixa dinâmica e (ii) evitar a formação de lacunas entre as faixas espectrais de filtros adjacentes, para obter boa exatidão.

4.5 TESTES E RESULTADOS

O objetivo dos testes foi interrogar a maior faixa dinâmica possível para o sensor em questão. Utilizou-se uma LPG inscrita em fibra monomodo padrão com raio do núcleo igual a 4,15 μm e da casca igual a 62,5 μm , índice de refração do núcleo igual a 1,449 e da casca igual a 1,444. O período da LPG é 522,9 μm . Observou-se a banda de atenuação correspondente ao modo LP_{05} , que tem o comprimento de onda ressonante próximo a 1550 nm a 25 $^{\circ}\text{C}$, sob as condições mencionadas. A fonte de luz é um SLD com largura de banda óptica de 100 nm centrada em 1550 nm. Considerando que a LPG em questão tem uma sensibilidade à temperatura de 6,3 nm/ $^{\circ}\text{C}$, a faixa dinâmica teórica é de 17,1 a 32,9 $^{\circ}\text{C}$. A referência de temperatura foi obtida usando um termômetro digital com precisão de 0,1 $^{\circ}\text{C}$.

Dois conjuntos de dados independentes foram criados: um para treinar a RNA e um para testar seu desempenho. Os conjuntos de dados contêm várias entradas consistindo na potência óptica medida para cada filtro (\boldsymbol{x}) e na correspondente temperatura no entorno do sensor (y). Os dados foram obtidos em duas etapas: primeiro, experimentalmente, sob temperatura controlada e usando LPGs projetadas e fabricadas no Laboratório de Instrumentação e Telemetria (LITel) da Universidade Federal de Juiz de Fora (UFJF); posteriormente, criou-se um modelo para simulação do sistema, que foi validado com sucesso utilizando-se os dados experimentais, de modo que se utilizou esse modelo de simulação para popular ambos os conjuntos de dados com entradas adicionais, a fim de aprimorar o desempenho de aprendizado da RNA.

O processo de treinamento funciona da seguinte forma: a rede é inicializada com valores aleatórios para as matrizes de pesos \boldsymbol{W}_i e para os vetores de *bias* \boldsymbol{b}_i ; então, ela é iterativamente abastecida com uma entrada \boldsymbol{x} retirada do conjunto de dados de treinamento, gerando uma saída \tilde{y} com algum erro ϵ relativo à saída esperada y ; esse erro é, então, usado para atualizar os pesos e *bias* da camada anterior, de acordo com o algoritmo *resilient backpropagation*. O processo continua até se encontrarem os pesos e *bias* otimizados para todas as camadas ou até um dos critérios de parada ser atingido. Os critérios de parada utilizados foram: (i) máximo de 2000 épocas; (ii) erro nulo; (iii) gradiente mínimo de 1×10^{-5} e (iv) 200 falhas de validação consecutivas.

Durante o processo de treinamento, o conjunto de dados de treinamento foi subdividido para proporcionar um conjunto de dados de validação, consistindo em entradas selecionadas aleatoriamente dentre as do conjunto original. A validação auxilia na minimização da probabilidade de produzir uma solução enviesada devido ao fato de a função de risco verdadeira ser distinta da função de risco empírica, um problema denominado *overtraining* ou *overfitting* [133]. Dessa forma, a RNA aprendeu utilizando o conjunto de dados de treinamento, enquanto seu desempenho foi avaliado utilizando-se o conjunto de validação para a parada antecipada [134]. O desempenho da RNA foi, então, medido

utilizando-se como parâmetro o erro quadrático médio (EQM) avaliado no conjunto de dados de teste. Todas as entradas no conjunto de dados de teste são independentes daquelas do conjunto de dados de treinamento.

Realizaram-se testes com diferentes números N de filtros na configuração, com $N \in \{3, 5, 7\}$. Adotando-se $N = 3$, o espaçamento entre os comprimentos de onda centrais deve ser alto para cobrir a faixa dinâmica teórica, o que prejudica a exatidão do interrogador. Os filtros foram projetados para 1505 nm, 1500 nm e 1595 nm. A Tabela 2 apresenta os resultados dos testes para diferentes tamanhos da camada oculta, considerando o EQM como parâmetro de desempenho. Um valor mais baixo de EQM significa que o sistema tem maior exatidão. Utilizando-se a validação cruzada k -fold (com $k = 10$) para a seleção do modelo, os resultados do sistema com três filtros mostram que a melhor configuração para a camada oculta é aquela com três neurônios.

Tabela 2 – Erro quadrático médio das RNAs treinadas para diferentes tamanhos da camada oculta.

Número de Neurônios na Camada Oculta	EQM [$(^{\circ}\text{C})^2$]		
	Três filtros	Cinco filtros	Sete filtros
1	4,0	3,4	2,9
2	3,8	2,7	1,9
3	3,0	4,8	1,6
4	3,4	3,0	1,4
5	4,2	2,9	0,9
6	4,0	3,4	0,7
7	7,8	1,5	2,8
8	3,8	3,6	0,8
9	3,8	2,6	1,3
10	4,4	2,8	4,4
11	5,7	4,6	3,6
12	4,2	6,5	4,5
13	4,6	1,3	7,6
14	4,9	2,1	2,3
15	4,3	5,2	5,6

Fonte: adaptada de [124].

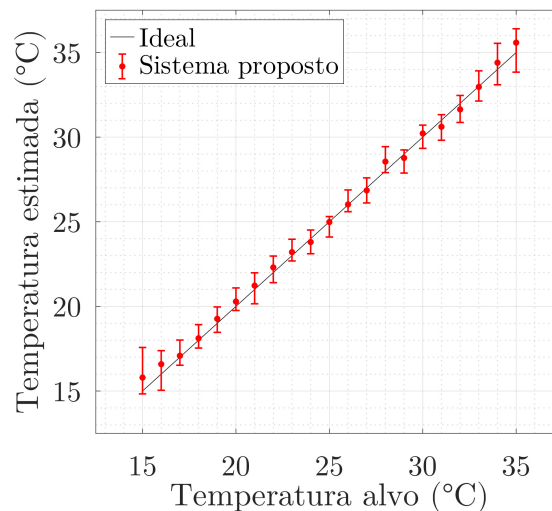
Nota: Os valores realçados representam os menores erros em cada configuração.

A fim de aprimorar a exatidão, deve-se diminuir o espaçamento espectral entre os filtros. Para que isso ocorra sem deixar de cobrir a faixa dinâmica original, deve-se, também, aumentar o número de filtros. Portanto, testou-se o sistema com cinco filtros,

projetados para os seguintes comprimentos de onda: 1500 nm, 1525 nm, 1550 nm, 1575 nm e 1600 nm. Os resultados desse teste também podem ser vistos na Tabela 2. Nota-se que a exatidão do sistema é, de fato, melhor do que a obtida no teste anterior. Para essa configuração, descobriu-se que a RNA tem o melhor desempenho se a camada oculta tiver 13 neurônios, conforme indicado pelo procedimento de validação *k-fold* para a seleção da arquitetura [134].

O último teste realizado foi uma tentativa de aprimorar a exatidão ao reduzir ainda mais o espaçamento espectral entre os filtros. Nesse teste, sete filtros foram utilizados com os seguintes comprimentos de onda ressonantes: 1505 nm, 1520 nm, 1535 nm, 1550 nm, 1565 nm, 1580 nm e 1595 nm. A configuração da camada oculta que apresentou o melhor desempenho, nesse caso, foi aquela com seis neurônios, como pode ser visto na Tabela 2. A Figura 17 mostra o desempenho dessa configuração de filtros usando uma RNA cuja camada oculta tem seis neurônios. O eixo horizontal indica a temperatura alvo, enquanto o eixo vertical indica a saída do sistema. A linha preta contínua representa um sistema sensor/interrogador ideal, que retornaria a temperatura com erro nulo. Os pontos vermelhos representam a saída do sistema proposto neste trabalho. As barras de erro representam a excursão total de cada valor, ou seja, o valor máximo e o mínimo estimados em cada temperatura. Nota-se que, nessa configuração, o erro médio de estimação no pior caso foi de 1,8% do valor alvo.

Figura 17 – Estimação de temperatura do sistema de interrogação composto por sete filtros usando seis neurônios na camada oculta.



Fonte: adaptada de [124].

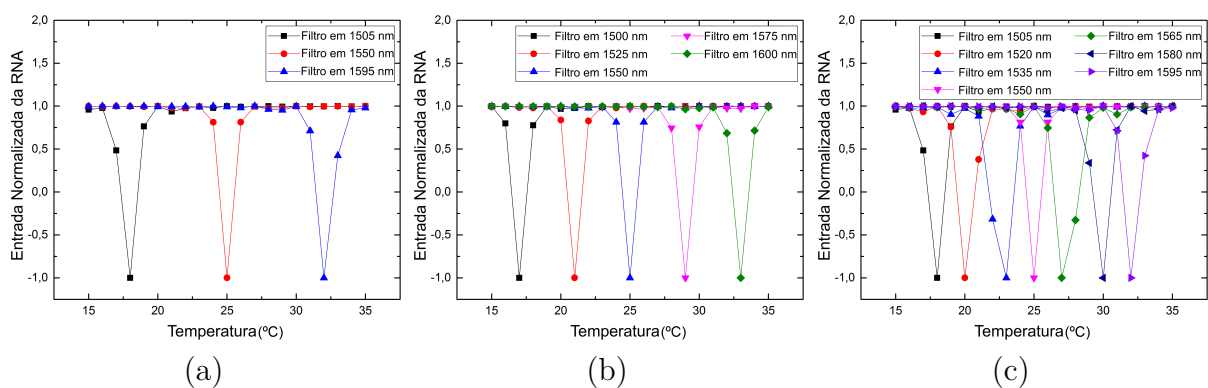
A fim de fornecer um meio de comparação, utilizou-se o mesmo conjunto de dados para produzir uma série de regressões usando o método dos mínimos quadrados. A

regressão com maior exatidão encontrada foi para o sistema com sete filtros usando um polinômio de quarto grau nas variáveis de entrada, permitindo termos cruzados dois a dois. Nesse caso, encontrou-se um EQM igual a $4,9 (\text{°C})^2$.

O tempo de treinamento da rede com maior exatidão foi de 6,42 segundos. Em contrapartida, o tempo de treinamento da regressão por mínimos quadrados foi de 0,08 segundos. Após os treinamentos, a RNA produz uma saída em 6,04 ms, que é comparável aos 5,99 ms do algoritmo usando mínimos quadrados. Todos os testes foram executados por um processador AMD FX-6300 de seis núcleos.

A Figura 18 mostra os valores normalizados de entrada da RNA em função da temperatura nos três testes. Na Figura 18(a), há duas regiões de ambiguidade perceptíveis, em torno de 22 °C e de 28 °C . Isso se deve ao grande espaçamento espectral entre os filtros do interrogador na configuração de três filtros. As regiões de ambiguidade são diminuídas na configuração de cinco filtros, como pode ser visto na Figura 18(b), e são praticamente inexistentes na configuração de sete filtros, como mostrado na Figura 18(c). A eliminação da ambiguidade acarreta uma grande vantagem no desempenho da RNA e justifica os resultados na Tabela 2. É possível notar que nas extremidades, em torno de 15 °C e de 35 °C , ainda existe uma lacuna de informação, mesmo na Figura 18(c). Isso se deve à diminuição da intensidade da fonte nas regiões espectrais respectivas e causa um aumento no erro da resposta da RNA nessas temperaturas que pode ser visto na Figura 17. Desse modo, a interrogação poderia ser feita numa faixa de temperaturas maior, bastando, para isso, aumentar a largura de banda da fonte e ajustar o projeto dos filtros.

Figura 18 – Valores de entrada normalizados da RNA para o sistema com: (a) três filtros; (b) cinco filtros; (c) sete filtros.



Fonte: adaptada de [124].

4.6 DISCUSSÃO

Este trabalho apresenta uma montagem de interrogação capaz de interrogar com eficácia toda a faixa dinâmica de um sensor de temperatura baseado em LPG e excitado por

uma fonte de luz SLD. Mostrou-se que, ao usar o sistema apresentado, é possível ajustar a faixa e a exatidão da interrogação configurando-se o número de filtros e o espaçamento espectral entre eles. Nota-se que o equipamento utilizado para construir o sistema consiste em componentes básicos de sistemas ópticos, como acopladores, FBGs e fotodetectores. Isso possibilita um sistema com boa relação custo-benefício que pode ser replicado em qualquer laboratório de óptica. O método avançado de estimação foi avaliado usando três, cinco e sete filtros para separar o sinal do sensor em sub-bandas, usando vários tamanhos para a camada oculta da RNA, e descobriu-se que a melhor exatidão ocorre quando se usa o sistema com sete filtros com uma camada oculta composta de seis neurônios. Uma comparação com um método clássico de regressão por mínimos quadrados mostra que o interrogador apresentado tem exatidão significativamente melhor, enquanto mantém um tempo de processamento similar durante a operação regular. Essa técnica é especialmente útil no campo, onde o uso de um OSA não é viável, ou em laboratórios em que um OSA não esteja disponível.

5 SISTEMA DE INTERROGAÇÃO BASEADO EM REFLECTOMETRIA ÓPTICA NO DOMÍNIO DO TEMPO

Neste capítulo, será apresentado o sistema de interrogação para sensores do tipo grade de período longo através de um método inovador que utiliza um reflectômetro óptico no domínio do tempo (*Optical Time-Domain Reflectometer* - OTDR) e aplica técnicas de extração de características apropriadas para realizar a interrogação. A escolha do OTDR como componente principal é justificada por se tratar de um instrumento que é comumente encontrado em laboratórios de óptica e tem um preço entre 15 e 20 mil reais, significativamente mais acessível do que um analisador de espectro óptico, que pode custar algumas centenas de milhares de reais, resultando em uma solução vantajosa para a interrogação, considerando sua relação custo-benefício. Além disso, a multiplexação de sensores nesse tipo de montagem é consideravelmente facilitada.

O pacote de simulação apresentado no apêndice deste trabalho é capaz de modelar o comportamento de um OTDR e de simular o traço medido por esse instrumento. A simulação computacional de traços de OTDR em montagens com sensores LPG indica que características dos traços podem revelar informações sobre o estado do sensor. Dessa forma, o conhecimento obtido através da análise dos resultados do simulador contribuiu para o desenvolvimento das configurações experimentais apresentadas abaixo.

Para realizar a interrogação, a informação contida no traço de OTDR precisa ser processada para expor algum conhecimento a respeito da grandeza de interesse. Nota-se que a aplicação de técnicas de processamento de sinais e de extração de características a traços de reflectometria com o objetivo da interrogação de sensores ainda não havia sido suficientemente explorada. Com o objetivo de realizar esse processamento, aplicou-se ao traço de OTDR um conjunto de descritores comumente utilizados em processamento de áudio, já estabelecidos na literatura específica para aplicações semelhantes.

A metodologia proposta foi utilizada para a construção de um classificador de amostras de peso [135] e, posteriormente, de amostras de líquidos diferentes [136], como prova de conceito. Por fim, a mesma metodologia foi utilizada para desenvolver um sistema de sensoriamento de salinidade [137]. A principal contribuição deste capítulo é apresentar uma alternativa à interrogação convencional de sensores LPG, com a possibilidade de utilizar um OTDR associado a técnicas de reconhecimento de padrões para esse propósito. Bem como o sistema apresentado no Capítulo 4, o que se apresenta a seguir dispensa o uso do analisador de espectro óptico ou de outros equipamentos de análise espectral. Os resultados experimentais apresentados apontam para a validade da utilização desse método para a interrogação de LPGs.


A seguir, a Seção 5.1 apresenta a montagem comum a todos os experimentos contidos neste capítulo. Na Seção 5.2, busca-se elucidar o princípio de funcionamento do método, ao analisar o efeito que a LPG exerce no traço do OTDR. As Seções 5.3

e 5.4 apresentam os testes qualitativos conduzidos: um classificador de pesos e um de meios externos. Na Seção 5.5, é apresentado um sistema completo sensor/interrogador de salinidade utilizando o método descrito neste capítulo. A Seção 5.6 encerra o capítulo discutindo os resultados obtidos.

5.1 CONFIGURAÇÃO DO SENSOR E DO INTERROGADOR

A montagem experimental consiste na seguinte sequência de componentes conectados em cascata: um OTDR Anritsu MT9083A2-073 [138], uma bobina de fibra óptica monomodo padrão, um sensor LPG desenvolvido especificamente para a aplicação, e uma segunda bobina de fibra que termina em aberto. A fibra óptica utilizada em ambas as bobinas foi a Corning SMF-28 Ultra [139]. A Figura 19 ilustra essa montagem. Nota-se que a terminação da segunda bobina não é relevante para a interrogação, já que o sinal transmitido não é necessário no procedimento proposto.

Figura 19 – Ilustração da montagem.



Fonte: adaptada de [136].

Foram utilizados trechos de fibra com 10 km ou 4 km, devido ao seu padrão de comercialização e, também, à praticidade de utilizar e, principalmente, de reutilizar as bobinas inteiras. O motivo principal de adicioná-las ao sistema é tornar os eventos do traço de OTDR suficientemente separados, a fim de facilitar a sua visualização e a sua identificação. Dessa forma, é admissível que os comprimentos das fibras sejam menores ou maiores, desde que ainda seja possível distinguir os eventos relativos ao início da fibra, ao sensor e ao fim da fibra. Em aplicações práticas, pode ser conveniente utilizar uma bobina longa entre o OTDR e a LPG, para realizar o sensoriamento remoto, e uma seção mais curta ao final, por praticidade. O limite inferior para o comprimento das bobinas é, portanto, dado pela resolução espacial do OTDR, para evitar a superposição entre eventos. Já o limite superior é dado pelo alcance do OTDR, para que o sinal luminoso tenha intensidade suficiente ao chegar aos eventos de interesse. Dependendo da configuração, o alcance do OTDR utilizado pode chegar a 300 km [138].

A princípio, poderia ser questionada a utilização de diferentes comprimentos de fibra com esta técnica devido à variação do nível de potência do sinal luminoso ao atingir a LPG. Porém, a metodologia proposta é capaz de lidar com essa variação por duas razões: por considerar apenas uma parte relevante do traço de OTDR e por prever um

procedimento de treinamento, que opera também como calibração. Apesar de a distância até a fonte de luz afetar o nível absoluto de potência na região de interesse, em torno do sensor, os valores relativos entre diferentes amostras nessa mesma região são apenas levemente perturbados. Além disso, o treinamento do estágio de processamento do sistema interrogador é projetado para se aproveitar ao máximo das características únicas de cada conjunto de medidas. Isso implica que o sistema possa ser utilizado com fibras de diferentes comprimentos, após uma calibração adequada.

A utilização de marcas ou modelos diferentes de fibra, sobretudo se houver mudança nos diâmetros ou nos índices da casca ou do núcleo, também poderia, a princípio, ser questionada. De fato, o formato do traço de OTDR pode variar conforme o tipo da fibra utilizada. Entretanto, similarmente à análise anterior, a estrutura de informação subjacente relacionada à amostra sob teste se mantém inalterada, e o objetivo dos descritores propostos é, justamente, que sejam capazes de revelar essa informação durante o estágio de processamento. A metodologia proposta inclui os passos de calibração necessários para evitar pequenas diferenças que possam surgir com o uso de componentes diferentes na montagem.

As LPGs utilizadas foram produzidas também com base na fibra Corning SMF-28 Ultra, por meio da técnica de arco elétrico ponto a ponto, utilizando uma máquina de fusão especialmente adaptada com a adição de um sistema de posicionamento manual de precisão micrométrica. O período da grade utilizado foi de 530 μm para produzir uma banda de atenuação na mesma região espectral da fonte de luz do OTDR, aproximadamente 1550 nm. Em cada um dos três tipos de teste abaixo, o sensor foi encapsulado adequadamente para a aplicação, conforme descrito nas respectivas seções.

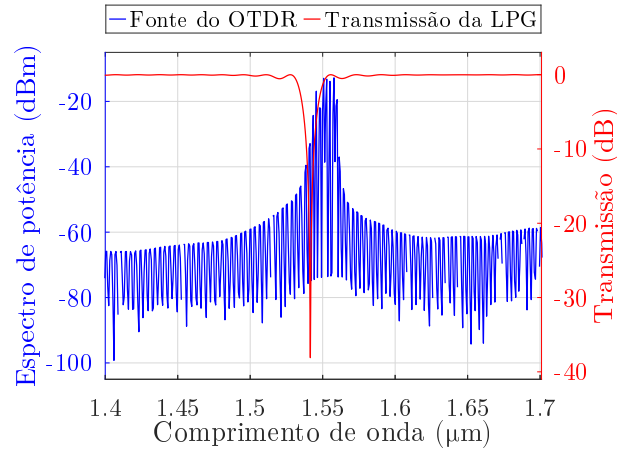
5.2 INTERROGAÇÃO DE LPG BASEADA EM OTDR

Os experimentos conduzidos neste capítulo são baseados nas leituras de um reflectômetro óptico no domínio do tempo, ou OTDR. Esse dispositivo lança um pulso luminoso no interior de uma fibra óptica e coleta o sinal refletido ao longo do tempo a fim de formar um perfil da atenuação ao longo do comprimento da fibra. Esse perfil de atenuação é chamado de traço de OTDR e possibilita a identificação de possíveis defeitos através do gráfico da intensidade da reflexão em função da coordenada axial da fibra.

Para entender o efeito da LPG no traço do OTDR, é preciso considerar inicialmente a resposta espectral da fonte de luz em questão. A fonte do instrumento utilizado neste trabalho ilumina apenas uma faixa limitada do espectro da LPG, já que emite luz em uma banda centrada em 1550 nm com uma largura de banda de 3 dB igual a 8 nm. Projeta-se a LPG para que tenha uma banda de atenuação selecionada localizada na mesma região espectral que a fonte do OTDR, nesse caso, com largura de banda de 3 dB igual a 13 nm. A Figura 20 mostra o espectro da fonte do OTDR conforme medido pelo OSA, em linha azul

e com valores referentes ao eixo vertical da esquerda, e também o espectro de transmissão da LPG projetada, em linha vermelha e com valores referentes ao eixo vertical da direita.

Figura 20 – Resposta espectral da fonte de luz e da LPG.




Fonte: elaborada pelo autor (2023).

Quando a luz chega à LPG e é acoplada do modo de núcleo para modos de casca, a perda por espalhamento é grandemente aumentada e isso se traduz em uma queda abrupta no traço de OTDR. Uma vez que o acoplamento do modo de núcleo para o respectivo modo de casca é afetado por variáveis externas à LPG, o vale na resposta espectral desse dispositivo é deslocado lateralmente e/ou muda de profundidade, conseqüentemente, a região espectral iluminada pela fonte passa a responder de forma diferente em relação à perda de energia para o meio externo. Assim, a potência óptica transmitida através da LPG para o segundo trecho de fibra é, também, afetada. Dessa forma, a atuação de variáveis externas na LPG traduz-se em variações na perda sofrida no entorno do sensor.

O OTDR, então, percebe tal alteração na perda detectada na região da LPG através de uma perda correspondente na potência retroespalhada. Nota-se que a luz retroespalhada também passa pela LPG, no sentido inverso, sofrendo mais uma vez o efeito do acoplamento para os modos de casca. Assim, a perda na LPG é inerentemente superestimada, o que contribui para a sensibilidade do método, haja vista a duplicação do efeito transdutor da grade, comparativamente a métodos que não utilizam reflectometria.

A Figura 21 mostra o traço de OTDR obtido no sistema proposto, com a LPG em repouso e exposta ao ar como meio externo. É possível visualizar os três eventos mencionados: (i) o início do primeiro trecho de fibra, em 0 km; (ii) a perda considerável causada pela LPG, em torno de 10 km e (iii) o fim do segundo trecho de fibra, próximo a 20 km. O pico imediatamente anterior ao sensor indica a ocorrência de reflexão de Fresnel no interior do conector utilizado. O efeito reflexivo do segundo conector encontra-se

Figura 21 – Traço de OTDR no sistema em repouso.



Fonte: elaborada pelo autor (2023).

mascarado pela associação de dois fatores: (i) o declínio abrupto causado pela perda na LPG e (ii) o tempo de recuperação do fotodetector no interior do OTDR.

Esquemas de interrogação que utilizam OTDR são relativamente comuns em sistemas de sensoriamento baseados em FBG [96, 97, 100–102], mas não em aplicações com LPG. Frazão *et al.* propuseram um sistema desse tipo para interrogação de LPG com vantagens em relação a sistemas de interrogação convencionais [140]. Sua abordagem é baseada na diferença entre a reflexão medida pelo OTDR antes e depois da LPG, isto é, no tamanho do degrau introduzido pela LPG, com o auxílio dos cursores do próprio instrumento. Essa técnica de interrogação apresenta algumas vantagens em relação à interrogação tradicional de LPG via análise espectral ou filtragem. A interrogação é realizada através do sinal refletido, o que é vantajoso para o sensoriamento remoto já que a transmissão e a recepção podem ocorrer no mesmo lugar usando menos fibra e menos componentes. A multiplexação de sensores pode ser realizada de forma simples e direta, visto que sensores em cascata aparecerão separados espacialmente no traço de OTDR. Além disso, os autores descobriram evidência de que essa configuração seja intrinsecamente insensível à temperatura, portanto, a sensibilidade cruzada é desprezível. Os sistemas apresentados por Bravo *et al.* e por Giraldi *et al.* interrogam LPGs com OTDR, mas a operação requer pelo menos dois acopladores, a multiplexação demanda acopladores adicionais, e cada LPG deve estar em um espelho de *loop* em fibra [98, 99].


O estudo apresentado neste capítulo mostra que é possível correlacionar o traço de OTDR nas proximidades da LPG com alguma variável externa de interesse. Uma forma imediata de fazer isso seria através da medição do tamanho do degrau inserido pela perda da LPG no traço, conforme sugerido em [140]. Entretanto, essa forma não ofereceria a robustez e a precisão necessárias para a generalização do método e dificultaria

a sua automação. A utilização de extratores de características permite um processamento de dados mais abrangente, devido à maior capacidade de extrair informação dos traços, incluindo informação relacionada à forma e à inclinação dos traços na região correspondente, ao mesmo tempo em que usa apenas as informações mais relevantes, obtidas através do procedimento descrito nas próximas seções.

5.3 CLASSIFICADOR DE PESOS

Nesta aplicação, publicada em [135], o sensor foi encapsulado com um invólucro impresso em poliácido láctico (*Polylactic Acid* - PLA) para oferecer maior resistência mecânica e para possibilitar o suporte a amostras de massa entre 7,2 g e 28,2 g. As medidas de referência foram obtidas com uma balança digital de precisão de 0,1 g. A Figura 22 mostra a configuração experimental montada em bancada. O sensor LPG foi submetido a cinco tipos diferentes de cargas, conforme indicado na Tabela 3. A diferença de massa entre dois tipos de carga é responsável por uma mudança no respectivo traço de OTDR significativa o suficiente para possibilitar a classificação.

Figura 22 – Montagem experimental.



Fonte: [135].

Tabela 3 – Tipos de carga e suas massas e pesos.

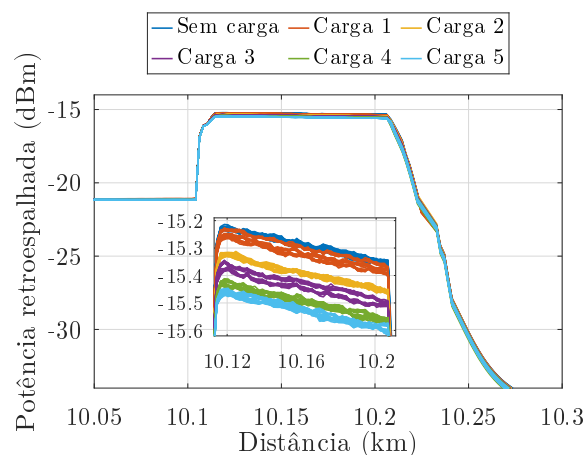
Tipo de carga	Massa (g)	Peso (mN)
Carga 1	7,2	71
Carga 2	14,1	138
Carga 3	20,2	198
Carga 4	24,6	241
Carga 5	28,2	276

Fonte: adaptada de [135].

Inicialmente, cada traço obtido experimentalmente foi analisado no *software* fornecido pelo fabricante, Anritsu TraceView, em que se verificaram a largura de pulso, o comprimento de onda de operação, os comprimentos de ambas as bobinas, a localização sensor na montagem e as perdas ao longo do caminho. Em seguida, para realizar uma análise numérica mais precisa, os arquivos gerados pelo OTDR foram tratados computacionalmente.

A curva de referência do sensor foi definida utilizando-se o comprimento de onda de 1550 nm e a largura de pulso de 1000 ns. Esses parâmetros foram mantidos em todos os testes realizados. Um exemplar dessa curva de referência foi mostrado na Figura 21. A Figura 23 mostra, em maior detalhe, os traços na região do entorno da LPG para diferentes configurações de carga. No gráfico, constam todas as curvas obtidas experimentalmente para cada tipo de carga, indicadas pela cor correspondente na legenda. O gráfico menor mostra o intervalo em que há a maior diferença entre as curvas. Mesmo assim, é possível notar que a maior distância entre duas curvas é de cerca de 0,3 dB. Observa-se que as curvas são muito próximas entre si e que nem todas seriam visualmente classificáveis sem o código de cores. Nesse conjunto de curvas, a mais notável diferença entre cada uma das situações de carga é o nível de potência retroespalhada correspondente à região da LPG. No entanto, outras alterações menos sensíveis podem ser detectadas com a aplicação dos descritores propostos. A obtenção de maiores informações pelos descritores pode ser utilizada como uma forma de resolver possíveis ambiguidades que um único descritor apresentaria.

Figura 23 – Traço no entorno do sensor para diferentes cargas.



Fonte: elaborada pelo autor (2023).

O *software* desenvolvido utiliza cada curva no intervalo em que é mais provável que se encontre informação discriminativa, correspondente aproximadamente ao que é mostrado na Figura 23, para calcular três descritores, baseados no centroide espectral (CE), na

largura de banda (LB) e na potência média (PM), de acordo com as Equações (5.1), (5.2) e (5.3). A escolha desses descritores foi motivada pelo seu uso com sucesso na classificação de sinais de áudio cujos espectros de frequência se assemelham à forma dos traços de OTDR em questão [119, 141].

No contexto dos sinais de áudio, o centroide espectral indica a localização do centro de gravidade do espectro de magnitude e serve como uma medida da forma do espectro. Por sua vez, a largura de banda está correlacionada com o intervalo de frequências dos dados ponderado pelo espectro. Finalmente, a potência média quantifica a intensidade do sinal no intervalo considerado. Apesar de as interpretações em termos de textura de áudio não serem válidas no presente contexto, já que a transformada de Fourier não é usada no método proposto, esses descritores mantêm suas capacidades de aquisição de informação no problema de interrogação considerado. Tendo em vista que o significado físico dos descritores foi alterado daquele utilizado no processamento de áudio, optou-se por omitir, adiante, a nomenclatura e utilizar apenas as abreviações CE, LB e PM.

Nas Equações (5.1), (5.2) e (5.3), $x[n]$ representa a distância, em metros, da fonte ao ponto na fibra correspondente ao n -ésimo ponto coletado pelo OTDR, $y[n]$ representa a potência do sinal refletido nesse ponto em relação à potência emitida pela fonte e N é o número total de pontos coletados em um experimento. O valor de y é encontrado através da linearização dos valores fornecidos pelo OTDR em decibéis. Nesta aplicação específica, os descritores CE e LB se dão em metros, e o descritor PM é adimensional.

$$\text{CE} = \frac{\sum_{n=1}^N x[n] \cdot y[n]}{\sum_{n=1}^N y[n]} \quad (5.1)$$

$$\text{LB} = \frac{\sum_{n=1}^N |\text{CE} - x[n]| \cdot y[n]}{\sum_{n=1}^N y[n]} \quad (5.2)$$

$$\text{PM} = \frac{1}{N} \sum_{n=1}^N y^2[n] \quad (5.3)$$

Com os valores dos três descritores, termos independentes adicionais foram calculados considerando-se:

- a) as potências dos descritores individuais: CE^i , LB^i , PM^i ;
- b) os produtos de dois fatores: $\text{CE}^i \cdot \text{LB}^j$, $\text{CE}^i \cdot \text{PM}^j$, $\text{LB}^i \cdot \text{PM}^j$;
- c) e os produtos de três fatores: $\text{CE}^i \cdot \text{LB}^j \cdot \text{PM}^k$,

com $i, j, k \in \mathbb{N} \mid i, j, k \leq 10$. Dessa forma, foram produzidas 1330 possíveis variáveis explicativas para cada experimento. A análise de componentes principais (*Principal*

Component Analysis - PCA) foi utilizada para determinar a melhor combinação dessas variáveis para explicar a variância nos dados e, conseqüentemente, para produzir um classificador.

Por fim, os termos mais relevantes, conforme indicados pela PCA, foram utilizados como variáveis independentes, em conjunto com um termo independente constante, em uma regressão de mínimos quadrados, a fim de fornecer um meio matemático para estimar o valor do peso aplicado. As duas etapas anteriores, a PCA e a regressão, são as responsáveis pela calibração do sistema proposto. Caso o mensurando ou os componentes do sistema viessem a ser alterados, um novo cálculo dessas duas etapas forneceria a calibração adequada. Nas próximas seções, são dados exemplos de medições de mensurandos diferentes utilizando essa mesma técnica.


Trinta experimentos foram realizados para cada tipo de carga, com o objetivo de demonstrar que é possível correlacionar o traço de OTDR na região em torno da LPG à intensidade da força aplicada ao dispositivo. No total, 180 observações foram feitas. A fim de garantir que o método seja repetível, cada experimento foi conduzido como segue:

- a) com o sensor em repouso, verifica-se que o OTDR mostra a curva padrão para o sensor em vazio;
- b) a carga é colocada sobre a LPG, que está suspensa pela estrutura de PLA;
- c) o traço de OTDR, agora modificado devido à resposta da LPG ao esforço mecânico, é gravado em uma mídia removível para posterior processamento;
- d) a carga é removida da LPG, que volta ao estado original.

O traço obtido em cada experimento foi analisado de acordo com a metodologia proposta, aplicando-se os três descritores. Na Figura 24, que apresenta os resultados de cada descritor, cada ponto corresponde a um dos traços analisados, portanto, a um experimento. Observa-se que, apesar de o descritor PM apresentar a maior quantidade de informação discriminativa entre as amostras, nenhum descritor é individualmente suficiente para identificar a carga inequivocamente, haja vista a existência de valores similares dos descritores encontrados em amostras de diferentes classes. Entretanto, é possível realizar tal identificação com uma combinação adequada de descritores, a partir da abordagem proposta.

A fim de construir o classificador, as observações foram aleatoriamente separadas em dois conjuntos de dados: um conjunto de treinamento contendo 70% das observações e um conjunto de teste contendo as demais amostras. Calculou-se uma matriz \mathbf{X} cujas linhas representam as observações do conjunto de treinamento e cujas colunas representam os 1330 termos mencionados anteriormente. O cálculo da PCA nessa matriz indicou que mais de 98,3% da variância total pode ser explicada pelas 5 primeiras componentes principais e mais de 99,8%, pelas primeiras 10. Seguindo-se o procedimento descrito na

Figura 24 – Resultados da aplicação dos descritores de acordo com o método proposto: (a) CE; (b) LB; (c) PM.



Fonte: adaptada de [135].

literatura [120], uma coluna de \mathbf{X} , portanto, um dos 1330 termos, foi selecionada para representar cada uma das L componentes principais mais relevantes. Então, calculou-se uma nova matriz \mathbf{X}_L , utilizando-se as observações do conjunto de teste como linhas e mantendo-se apenas as L colunas indicadas pela PCA como sendo as mais relevantes do conjunto de treinamento.

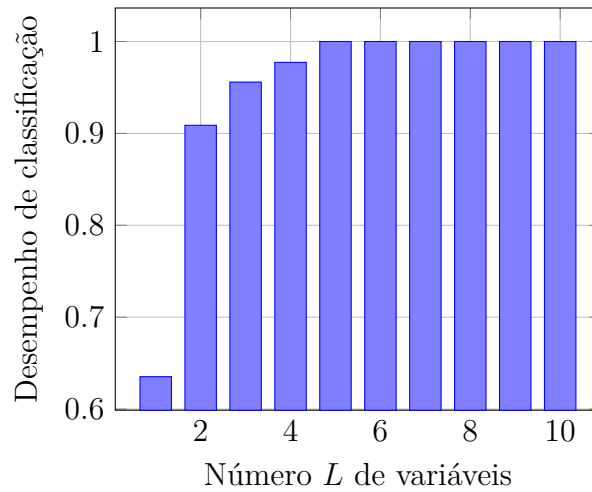
Finalmente, o classificador foi construído utilizando-se as L variáveis selecionadas e uma constante independente. O classificador é baseado em uma regressão linear calculada no conjunto de treino a fim de ajustar as variáveis selecionadas à saída esperada do interrogador, que é o peso aplicado. As classes são definidas de acordo com a saída da regressão e com a definição de limiares apropriados. Em seguida, o desempenho do classificador treinado foi estimado utilizando-se o conjunto de teste.

O valor de L foi selecionado aplicando-se a validação cruzada k -fold com $k = 10$, que é um critério comum para seleção de modelos [142], e os resultados estão apresentados na Figura 25. As barras na imagem representam a média do desempenho de classificação para cada valor de L , o número de variáveis usado para construir o classificador, calculada sobre as 10 iterações do k -fold.

O desempenho de classificação é uma métrica de quão corretamente o classificador construído com L variáveis pode separar os valores medidos nas seis classes propostas. Seu valor é calculado dividindo-se o número de classificações corretas pelo número total de observações no grupo de teste. Sendo assim, trata-se de uma grandeza adimensional. Um desempenho igual a 1 significa que todas as observações foram classificadas corretamente.

Tendo em vista que os valores de desempenho na validação cruzada k -fold para $5 \leq L \leq 10$ foram todos iguais a 1, segue que esse intervalo oferece escolhas ótimas de L . O menor valor, $L = 5$, foi escolhido para ilustrar a eficácia do método na forma mais simples. O classificador é baseado na Equação (5.4), em que p_e indica o peso estimado e

Figura 25 – Validação cruzada *k-fold*: desempenho de classificação médio no *fold* de teste usando as L variáveis mais relevantes.



Fonte: adaptada de [135].

$\mathbf{b}_{6 \times 1}$ é o vetor de 6 coeficientes encontrado na regressão linear.

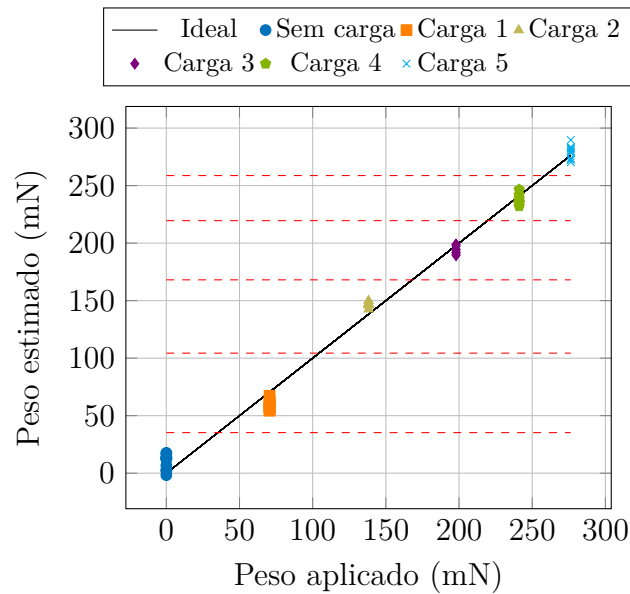
$$p_e = \left[\text{CE} \quad \text{PM} \quad \text{LB} \quad \text{PM}^2 \quad \text{PM}^3 \quad 1 \right] \cdot \mathbf{b}_{6 \times 1} \quad (5.4)$$

A Figura 26 mostra o resultado do classificador final. Nesse caso, os valores dos coeficientes encontrados durante a regressão são aqueles mostrados na Equação (5.5). Na figura, o eixo horizontal representa o peso efetivamente aplicado, enquanto o eixo vertical representa o valor estimado pelo sistema proposto. A linha preta sólida representa um estimador ideal, que retornaria o valor exato do peso aplicado. O gráfico de dispersão representa as saídas para cada observação no conjunto de teste. Cada saída foi classificada de acordo com a metodologia proposta. As diferentes classes são representadas por marcadores de diferentes cores e formas, conforme a legenda apresentada. Os limiares do classificador estão indicados como linhas vermelhas tracejadas. Foram escolhidos como limiares os pontos médios entre os pesos de cada classe, de acordo com a Tabela 4. É possível notar que todas as observações foram classificadas corretamente, confirmando o desempenho de classificação igual a 1 encontrado durante a validação cruzada *k-fold*.

$$\mathbf{b}_{6 \times 1} = \left[-363,79 \quad -180,19 \quad 324,98 \quad 441,88 \quad -327,53 \quad 207,41 \right]^T \quad (5.5)$$

O sistema desenvolvido, baseado em OTDR, satisfaz com sucesso o propósito desejado. Utilizando essa montagem, foi possível avaliar o sinal vindo do sensor LPG e classificar cada traço utilizando técnicas de processamento de sinais implementadas em *software* desenvolvido especificamente para esse fim. Verificou-se que o sistema apresentado

Figura 26 – Resultados do classificador com $L = 5$, calculados no conjunto de teste.



Fonte: adaptada de [135].

Tabela 4 – Condições e limiares do classificador.

Condição	Classificação
$p_e < 35$ mN	Sem carga
35 mN $\leq p_e < 104$ mN	Carga 1
104 mN $\leq p_e < 168$ mN	Carga 2
168 mN $\leq p_e < 220$ mN	Carga 3
220 mN $\leq p_e < 259$ mN	Carga 4
$p_e \geq 259$ mN	Carga 5

Fonte: elaborada pelo autor (2023).

se comportou como classificador de pesos, sendo capaz de diferenciar mesmo entre cargas pequenas, de valores próximos, a uma longa distância e usando uma montagem simples.

A configuração apresentada tinha como objetivo medir pesos, como prova de conceito, tendo em vista que essa é uma forma simples e direta de excitar uma resposta do sensor LPG. Entretanto, devido à vastidão das aplicações em que LPGs podem ser utilizadas como elemento sensor, o mesmo sistema pode ser usado para medir outras grandezas, como temperatura, índice de refração, torção. Naturalmente, um processo de calibração específico é necessário no *software*, se a medição de uma grandeza diferente for objetivada, mas a configuração experimental permanece essencialmente a mesma. Como mencionado, o procedimento de calibração foi descrito acima e faz parte da metodologia

proposta para a montagem do sistema. O uso desse sistema e da metodologia proposta em aplicações com outros mensurandos é objeto das próximas seções.

5.4 CLASSIFICADOR DE MEIOS

Nesta aplicação, publicada em [136], traços produzidos pelo OTDR em experimentos utilizando uma LPG em diferentes meios externos foram analisados usando novamente técnicas de processamento de sinais inspirados no processamento de áudio. O objetivo era demonstrar que, usando esse tipo de análise, é possível identificar corretamente o meio externo através das características do traço de reflectometria. Os resultados mostraram que as características extraídas dos traços permitiram a produção de bons classificadores, um dos quais atingiu 100 % de classificações corretas no conjunto de dados considerado. Essa tecnologia pode ser aplicada em cenários em que seja necessário distinguir dado conjunto de gases ou de líquidos uns dos outros de forma não destrutiva.

A resposta da LPG imersa em diferentes meios é afetada por diversos parâmetros, dos quais o índice de refração é de particular importância. A partir da Equação (2.30), que define o deslocamento do vale ressonante de uma LPG causado pela mudança no índice de refração do meio externo, e da discussão respectiva, espera-se que um analisador de espectro óptico seja capaz de interrogar um sensor de índice de refração baseado em LPG de forma direta. De fato, isso foi reportado diversas vezes na literatura específica. Pesquisadores brasileiros vêm investigando o uso de grades de período longo na medição do índice de refração e na detecção de substâncias químicas pelas últimas duas décadas. No começo dos anos 2000, Falate *et al.* reportaram um sensor LPG capaz de detectar a concentração de hidrocarbonetos de petróleo em diferentes soluções que poderia ser usado em controle de qualidade de combustíveis [143–145]. Mais tarde, seu trabalho originou um sensor refratométrico generalizado baseado em LPGs com deslocamento de fase com sensibilidade ao índice de refração suficiente para medir a salinidade da água [146] e, também, uma nova técnica refratométrica para monitorar a qualidade do biodiesel usando um sensor LPG [147]. Possetti *et al.* apresentaram medições de salinidade usando um refratômetro baseado em um interferômetro formado pela associação de duas LPGs em cascata [148] e a aplicação de sensores LPG no controle de qualidade de combustíveis através da detecção de diferentes componentes na mistura do combustível [149–151]. Terada *et al.* propuseram um dispositivo de encapsulamento como um aprimoramento para sensores LPG refratométricos que detectaram água, etanol e gasolina com reprodutibilidade melhorada [152]. Kawano *et al.* propuseram diferentes métodos para ajustar sensores LPG para medir a concentração de misturas de combustíveis [153]. Em 2012, Enríquez *et al.* propuseram uma montagem teórica usando uma LPG em cascata com uma FBG para permitir a medição simultânea do índice de refração e da temperatura do meio externo com resultados de simulação sustentando sua hipótese [154]. Heidemann *et al.*

foram capazes de aprimorar a sensibilidade a índice de refração de uma LPG revestida com nanopartículas de ouro em 2016 através do casamento da ressonância de plásmom de superfície localizado com as ressonâncias da grade [155] e produziram um sensor LPG plasmônico funcionalizado capaz de detectar e quantificar a concentração de glifosato em amostras de água [156].

O sistema proposto por Enríquez *et al.* foi verificado experimentalmente por Berretoni *et al.* usando um instrumento específico para a análise da interrogação da FBG, e a sensibilidade ao índice de refração e a exatidão atingidas foram comparáveis às de refratômetros comercialmente disponíveis [157]. Sun e Wu reportaram uma montagem diferente usando uma combinação de uma LPG e uma FBG com gorjeio que foi interrogada por um OSA associado a um medidor de potência e atingiu alta sensibilidade [158]. Mais recentemente, Xue *et al.* alcançaram altas sensibilidades ao índice de refração usando uma LPG impressa em uma fibra óptica plástica com formato em D [159]. Janik *et al.* propuseram o uso conjunto de uma LPG revestida e de um interferômetro de Mach-Zehnder em linha formado por uma microcavidade como sensores de índice de refração complementares e de alta sensibilidade, orientados ao sensoriamento multiparamétrico [160]. Caldas e Rego estudaram os parâmetros de interferômetros de Michelson e de Mach-Zehnder baseados em LPGs a fim de aprimorar as sensibilidades ao índice de refração e à temperatura [161]. Wang *et al.* foram capazes de medir índice de refração em uma ampla faixa com alta sensibilidade ao reduzirem o período da grade, conseguindo, também, uma baixa sensibilidade cruzada à temperatura [162]. Rana, Kandadai e Subbaraman propuseram um modelo reflexivo para LPGs usando um revestimento metálico em uma ponta da fibra e verificaram experimentalmente que as sensibilidades à temperatura e ao índice de refração foram mantidas [163, 164]. Jiang *et al.* apresentaram uma configuração baseada em LPGs em cascata que foi capaz de medir índice de refração e temperatura simultaneamente ao analisar ambas as modulações em comprimento de onda e em intensidade e obtiveram alta sensibilidade [165].

Os trabalhos citados apoiam-se na análise espectral do sinal do sensor, portanto, requerem instrumentos relacionados ao espectro, como o OSA ou um interrogador específico. Este trabalho representa avanços no sensoriamento baseado em LPG ao propor um novo esquema de interrogação usando uma montagem menor e mais barata baseada em reflectometria. Além de ser mais portátil e mais barato que um OSA ou que um interrogador específico, um OTDR também oferece vantagens na operação remota, já que o sinal é inerentemente analisado na mesma localização da fonte de luz, sem qualquer componente adicional como espelhos ou circuladores.

O objetivo é demonstrar que essa configuração é capaz de distinguir diferentes meios externos, portanto os resultados são qualitativos. Pretende-se mostrar evidência de que técnicas de reconhecimento de padrões podem ser aplicadas aos traços de OTDR de LPGs a fim de identificar o meio externo dentre classes conhecidas. As aplicações

desse tipo de tecnologia são variadas, especialmente na automação de processos industriais. Em aplicações industriais, é comum trabalhar com diferentes tipos de gases e pode ser necessário distingui-los uns dos outros de forma segura e não destrutiva. Na indústria alimentícia, é útil distinguir ingredientes líquidos de diferentes sabores sem contaminar as amostras. No monitoramento ambiental, pode ser útil classificar amostras de água em diferentes padrões de qualidade ou de pureza.

Nestes experimentos, o OTDR foi conectado a uma bobina de 4 km de fibra, que, por sua vez, foi conectada a uma pequena seção de fibra contendo uma LPG cujo comprimento de onda ressonante referente a um dos modos situava-se centrado em 1,55 μm , que foi conectada a uma bobina de 10 km terminada em aberto. O diagrama básico do sistema é o mesmo já mostrado na Figura 19. Como a LPG insere uma perda dependente do comprimento de onda ao redor do comprimento de onda ressonante, o pulso vindo do OTDR sofre essa perda em ambas as direções: na transmissão e na reflexão [135]. Portanto, no traço de OTDR, identifica-se a LPG como uma queda abrupta na intensidade do sinal refletido. O principal objetivo da segunda bobina é separar os eventos do traço relacionados à região da LPG do evento do fim da fibra para possibilitar o consequente estágio de processamento, que utiliza alguns metros do traço após a LPG nos cálculos. Portanto, a seção de fibra após a LPG deve ser muito maior que a resolução espacial do OTDR, mas não é necessário que seja maior que cem metros em uma aplicação prática.

A fim de demonstrar que esta técnica é capaz de identificar diferentes meios externos, a LPG foi inserida em diferentes líquidos e 50 traços de OTDR foram coletados para cada situação do meio externo. Entre duas medidas, secou-se, limpou-se com água e, então, secou-se novamente o sensor. Quando o meio externo era água, apenas secou-se o sensor entre as medidas.

Três líquidos foram usados como meio externo: a amostra 1 era água da torneira, a amostra 2 era uma solução de café pronta para o consumo e a amostra 3 era suco misto de frutas. Todas as amostras de um mesmo líquido foram retiradas de um único lote, de forma que se espera que exibam características físicas semelhantes. A Tabela 5 resume a informação relevante sobre os três líquidos, incluindo valores de referência do índice de refração desses líquidos a um comprimento de onda de aproximadamente 600 nm. Essa tabela deve ser interpretada apenas como referência geral, haja vista a diferença entre o comprimento de onda utilizado nos experimentos e aquele utilizado pelas fontes citadas. Nota-se que os sólidos dissolvidos na solução de café aumentam o valor do índice de refração comparativamente ao da água pura [166, 167] e que a sacarose presente no suco, juntamente com outras substâncias secundárias, é responsável por um aumento ainda maior no índice de refração em relação ao da água [168].

Após a obtenção dos dados, os traços foram analisados computacionalmente utilizando técnicas de processamento de sinais herdadas do processamento de áudio e de

Tabela 5 – Índices de refração dos líquidos utilizados como amostras.

Líquido	Índice de Refração	Referência
1 Água	1,332	[166]
2 Café	1,335	[167]
3 Suco	1,355	[168]

Fonte: adaptada de [136].

reconhecimento de padrões. O intervalo de interesse é em torno da LPG, portanto, os traços foram cortados no intervalo entre 4,23 km e 4,30 km, que foi onde se encontraram as diferenças significativas entre traços de diferentes meios externos. Considerando esses traços cortados como sinais, três descritores de características foram calculados e testados como possíveis variáveis explicativas para a classificação do meio externo. Dado que os descritores operam no âmbito dos traços cortados e que o efeito da LPG no traço é localizado, outras LPGs poderiam ser multiplexadas a fim de formar um sistema de medição multiponto. Cada LPG teria o seu próprio intervalo de interesse para o cálculo dos descritores de características.

O primeiro descritor é o centroide espectral (CE), que no processamento de áudio é uma medida da forma espectral do sinal [119]. Aqui, afastado do significado de áudio, está relacionado com o centro de gravidade da forma do traço. O segundo descritor é a potência média (PM), que é uma característica comum no processamento de sinais e está relacionada com o tamanho do sinal. Finalmente, o terceiro descritor é a largura de banda (LB), que no processamento de áudio está relacionada com a faixa de frequências em que o espectro é significativo [119]. Novamente, esse significado é preterido nesta aplicação porque o descritor é aplicado diretamente ao sinal, e não ao espectro. É importante notar que, embora a interpretação física dos descritores de características tenha sido alterada, ainda se mantém a habilidade que têm de produzir saídas que resumem informação sobre um sinal, como a forma ou a intensidade, e que podem ser usadas em problemas de reconhecimento de padrões ou de classificação como variáveis explicativas em potencial.

Os descritores de características selecionados foram calculados de acordo com as Equações (5.6), (5.7) e (5.8). Nessas equações, N é o número total de pontos no traço dentro do intervalo selecionado, $x[n]$ é a distância do n -ésimo ponto até a fonte de luz do OTDR, medida em metros, e $y[n]$ é a intensidade do sinal refletido associado ao n -ésimo ponto, medido relativamente à intensidade do pulso de luz emitido e, portanto, adimensional. A partir das unidades das variáveis, infere-se que CE é dado em metros, PM é adimensional e LB é dado também em metros. É importante notar que essas unidades não refletem o significado físico dos descritores de características, conforme discutido.

$$\text{CE} = \frac{\sum_{n=1}^N x[n] \cdot y[n]}{\sum_{n=1}^N y[n]} \quad (5.6)$$

$$\text{PM} = \frac{1}{N} \sum_{n=1}^N y^2[n] \quad (5.7)$$

$$\text{LB} = \frac{\sum_{n=1}^N |\text{CE} - x[n]| \cdot y[n]}{\sum_{n=1}^N y[n]} \quad (5.8)$$

As saídas de cada descritor de características foram normalizadas ao intervalo $[0, 1]$, tornando-se, portanto, adimensionais, a fim de oferecer uma melhor comparação do desempenho dos diferentes descritores. A normalização foi feita de acordo com a Equação (5.9), em que \mathbf{D} é um vetor contendo os valores de qualquer dos três descritores de características.

$$\mathbf{D}_{\text{norm}} = \frac{\mathbf{D} - \min\{\mathbf{D}\}}{\max\{\mathbf{D}\} - \min\{\mathbf{D}\}} \quad (5.9)$$

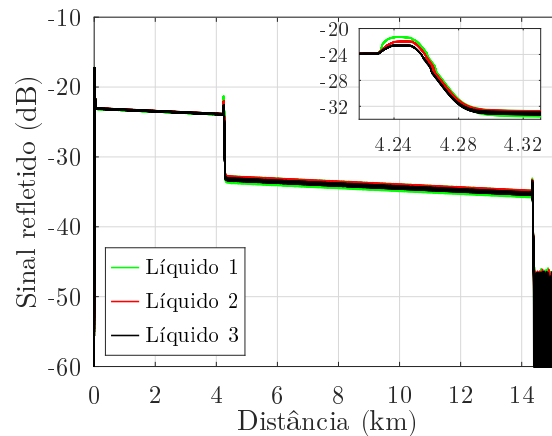
Para cada descritor de características, desenvolveu-se um classificador utilizando suas saídas normalizadas como variável explicativa. O melhor modelo de classificador foi selecionado utilizando a validação cruzada *k-fold* com $k = 10$. Nos grupos de treino, os limiares de classificação foram definidos como a média entre os valores médios do descritor para cada classe, e o modelo treinado foi avaliado através do cálculo do desempenho de classificação no grupo de teste. O desempenho de classificação foi calculado como a razão entre as classificações corretas de amostras e o total de dados no grupo de teste, na média entre todos os grupos, e dado como uma porcentagem.

Nota-se que o classificador é treinado para distinguir os dados através do aprendizado dos dados em si, dos padrões contidos nos traços, independentemente das causas subjacentes das diferenças entre os traços. É treinado para prover uma conexão direta do traço para a classe resultante. Qualquer grandeza intermediária é transparente. Como mencionado, o índice de refração é um parâmetro importante com um efeito direto e significativo na LPG e, portanto, no traço. No entanto, é o efeito combinado do índice de refração, da turbidez e de outros parâmetros no respectivo traço que cria um padrão que o classificador aprende a reconhecer.

Após a coleta de todos os dados, foi possível gerar o gráfico mostrado na Figura 27. Esse gráfico contém todos os traços de OTDR coletados durante os experimentos. A cor de cada traço indica qual líquido foi usado como meio externo no respectivo experimento. O gráfico menor mostra a região em torno da LPG em maior detalhe. É possível ver que

os traços são muito semelhantes até a localização da LPG, em aproximadamente 4,2 km. Após esse ponto, os traços exibem uma queda significativa, tornam-se mais ruidosos e começam a mostrar alguma diferença em relação ao nível do sinal. É importante notar que a metodologia descrita aqui foi capaz de se aproveitar dessas diferenças sutis no nível e na forma dos traços para produzir valores suficientemente diferentes dos descritores em cada experimento a fim de permitir a classificação. Uma vantagem desse sistema, usando o procedimento proposto de análise de dados, é que o índice de refração juntamente com outras propriedades físicas do meio que afetam a LPG são levados em consideração durante o treinamento. Isso contribui para reduzir a probabilidade de confusão entre classes que apresentem similaridade em um dos parâmetros. Além disso, a inclinação, a forma, a altura e detalhes mais finos nos traços podem influenciar os valores calculados dos descritores.

Figura 27 – Traços de OTDR que são a base para a análise proposta. O gráfico menor mostra a região da LPG em maior detalhe.




Fonte: adaptada de [136].

A Figura 28 mostra graficamente os classificadores desenvolvidos a partir da aplicação dos descritores de características CE, PM e LB aos traços de OTDR com a LPG imersa em diferentes meios externos. Em cada gráfico, o eixo horizontal representa a identificação do líquido que serviu como meio externo para a LPG, de acordo com a Tabela 5. O eixo vertical representa os valores calculados dos descritores de características, normalizados ao intervalo $[0, 1]$. Cada ponto nos gráficos representa um experimento: um traço de OTDR coletado com o líquido correspondente como meio externo que foi processado usando o descritor de características e, finalmente, normalizado. As estrelas marcam as médias dos valores normalizados do descritor para o respectivo líquido. Determina-se que o descritor produz um bom classificador se os pontos que representam experimentos do mesmo líquido formarem classes bem definidas, ou *clusters*, distinguíveis umas das outras.

No caso em questão, as classes devem ser distinguidas usando apenas uma dimensão: o valor normalizado do descritor, e, portanto, limiares unidimensionais devem ser considerados. Dessa forma, dois limiares devem ser encontrados a fim de produzir três regiões distintas no intervalo de variação do valor normalizado, um para cada classe, ou líquido. Finalmente, as linhas tracejadas representam os limiares de classificação treinados para cada classificador, selecionado através do procedimento de validação cruzada *k-fold*.

Figura 28 – Classificadores lineares baseados em apenas um descritor: (a) CE; (b) PM; (c) LB.



Fonte: adaptada de [136].

Um classificador ideal deve exibir apenas um grupo de pontos de dados em cada região definida pelas linhas dos limiares. Se um ponto aparecer fora da região definida para conter a respectiva classe, isso é registrado como um erro de classificação, reduzindo o desempenho geral do classificador. Tais erros podem ser encontrados na Figura 28(a), nas classes 2 e 3, e na Figura 28(c), em menor grau, porém, em todas as classes. Por outro lado, a Figura 28(b) não apresenta erros de classificação.

A partir das Figuras 28(a)–(c), torna-se visualmente claro que o classificador baseado no descritor PM tem vantagens em relação aos outros dois. Como mostrado na Figura 28(b): as médias dos valores de PM são bem separadas entre diferentes classes; a dispersão em cada *cluster* é a menor e, finalmente, esse classificador exibe a classificação correta para todos os experimentos conduzidos.

A análise anterior é sustentada mais profundamente pelos dados numéricos mostrados na Tabela 6. Essa tabela mostra o nome do descritor e o valor médio juntamente com o desvio padrão para cada classe. Devido à normalização, os resultados dos diferentes descritores são adimensionais e passíveis de comparação. A distância média entre as médias de cada classe é 0,445 no classificador baseado no descritor PM, comparado a 0,320 no baseado em CE e 0,345 naquele baseado em LB. O desvio padrão médio das classes no classificador baseado em PM é 0,027, comparado a 0,077 no CE e 0,067 no LB.

A Tabela 7 fornece dados numéricos sobre os classificadores treinados e adicionalmente sustenta a análise visual. Para cada classificador, essa tabela mostra o nome do

Tabela 6 – Comparação da média e do desvio padrão das saídas normalizadas dos descritores de características.

Descritor	Líquido 1	Líquido 2	Líquido 3
CE	0,20 ± 0,08	0,73 ± 0,07	0,84 ± 0,08
PM	0,92 ± 0,03	0,43 ± 0,03	0,03 ± 0,02
LB	0,16 ± 0,07	0,59 ± 0,06	0,85 ± 0,07

Fonte: adaptada de [136].

respectivo descritor, o valor normalizado de ambos os limiares, bem como o desempenho de classificação obtido durante a validação cruzada *k-fold*. O classificador baseado em PM exhibe a maior distância entre os limiares. Além disso, também atingiu um desempenho de classificação de 100 % durante a validação cruzada, o que significa que foi capaz de classificar corretamente todas as amostras no conjunto de dados em análise.

Tabela 7 – Comparação dos classificadores baseados em limiares de uma variável.

Descritor	Limiar Inferior	Limiar Superior	Desempenho de Classificação
CE	0,46	0,78	83,2 %
PM	0,23	0,68	100 %
LB	0,38	0,72	97,2 %

Fonte: adaptada de [136].

Os experimentos apresentados demonstram a capacidade de uma combinação de um sensor LPG e reflectometria óptica no domínio do tempo com técnicas de processamento de sinais para classificar meios externos com base nas características dos respectivos traços. Três líquidos diferentes foram usados como meios nos experimentos e três descritores de características foram usados como variáveis explicativas em diferentes classificadores de uma variável. Os resultados mostram que é possível atingir bons desempenhos de classificação usando esses descritores, especialmente o descritor PM, que permitiu a construção de um classificador capaz de atingir 100 % de classificações corretas no conjunto de dados usado.

5.5 INTERROGADOR DE SALINIDADE

A salinidade é uma variável chave no entendimento de diversos problemas relacionados desde à saúde pública até à segurança alimentar. Medições de salinidade *in-situ* geralmente são feitas usando métodos condutivimétricos e podem ser desafiadoras devido a temperaturas extremas, ambientes corrosivos e oxidação. Métodos baseados em fibra

e outros métodos alternativos propostos anteriormente trouxeram algumas vantagens, mas apresentam fragilidade no sensor, configurações caras ou complexas, sensibilidade cruzada à temperatura, falta de portabilidade ou tempos de resposta proibitivamente longos. Esta pesquisa, publicada em [137], apresenta um sistema de sensoriamento de salinidade simples e compacto que, associado a uma técnica de interrogação moderna, é capaz de atingir boa exatidão mesmo em sensoriamento remoto e em baixas concentrações de sal. O sensor é uma grade de período longo fabricada usando o método do arco elétrico ponto a ponto. O interrogador é baseado em reflectometria óptica no domínio do tempo com auxílio de técnicas de processamento de sinais inspiradas no processamento de áudio. Dados experimentais mostram que o sistema é capaz de estimar a salinidade na faixa entre 0,0 g/L e 80,0 g/L com erro não superior a 0,5 g/L na média, com o sensor a 4 km de distância da fonte de luz.

A salinidade da água é um parâmetro fundamental no monitoramento ambiental, primariamente em oceanos e em estuários, e no monitoramento da qualidade da água relacionado à saúde pública. A concentração de sal na água de irrigação tem o potencial de afetar a eficiência da agricultura e, conseqüentemente, a segurança alimentar. A salinidade da água do mar é um fator importante na sua equação de estado, que é usada em modelos oceânicos e climáticos [169, 170]. A salinidade também é uma das grandezas indispensáveis no gerenciamento das águas subterrâneas costeiras [171]. Além disso, o monitoramento da salinidade de águas subterrâneas também é importante na prevenção da intrusão salina, um problema ambiental agravado pelo aumento do nível do mar causado pela mudança climática [172]. Com o crescimento populacional mundial e com a crescente demanda por água doce, espera-se que a dessalinização tenha um papel importante na garantia do fornecimento de água, e a medição da salinidade é essencial no controle de qualidade do processo de dessalinização [173]. Sabendo-se que a obtenção de boa qualidade de água é um dos Objetivos de Desenvolvimento Sustentável da ONU, e que a coleta e a disponibilização de medições de salinidade são críticas para um entendimento aprofundado de questões relacionadas a esse tema, a importância do monitoramento desse parâmetro fica clara [174].

A forma atual mais típica de monitoramento da salinidade da água é a medição da condutividade elétrica da água usando fios e eletrodos [175]. No entanto, essa abordagem está sujeita a algumas limitações. A condutividade elétrica tem uma forte dependência da temperatura que pode afetar a medição [176]. Componentes não condutivos que têm efeito na densidade da solução podem levar a erros de medição, e os eletrodos estão sujeitos à interferência eletromagnética [172]. Essa configuração não é vantajosa em cenários de sensoriamento remoto [177]. Sua operação *in-situ* é dificultada em temperaturas extremas e seu tamanho e a complexidade da sua estrutura a tornam inviável para o uso em pequena escala [178]. Além disso, essa técnica pode causar a polarização da água, requer manutenção a fim de manter os eletrodos limpos, e também requer recalibração para

compensar a oxidação e a corrosão do material dos eletrodos [179].

Esquemas alternativos de medição de salinidade têm sido assunto de pesquisas recentes. A técnica proposta por Heydari *et al.* é muito precisa, especialmente em concentrações muito pequenas, mas também não é prática para sensoriamento remoto ou ambientes severos, visto que seu escopo é primariamente água potável [175]. Amiri *et al.* desenvolveram um sensor de salinidade usando absorvedores perfeitos com metamaterial [177]. Sua abordagem é vantajosa com relação a sensores tradicionais por condutividade, especialmente quanto à possibilidade de sensoriamento remoto e à ausência de manutenção, mas é, ainda, sujeito à interferência eletromagnética, haja vista a utilização de antenas operando em cerca de 3 GHz. Taha *et al.* projetaram um sensor de salinidade usando um cristal fonônico que, teoricamente, apresenta alta exatidão tanto em concentrações baixas quanto em altas, mas, experimentalmente, não se sabe como o sensor baseado em ondas sonoras se comportaria *in-situ*, principalmente sob condições ambientais adversas [180]. Rahman *et al.* propuseram um esquema de sensoriamento compacto e de baixo custo baseado em antenas, mas que também pode ser levado a erro pela interferência eletromagnética [181].

O sensoriamento de salinidade também foi um assunto de interesse para a pesquisa em instrumentação óptica, com vantagens em relação a sensores elétricos e químicos, como a segurança, a ausência de poluição, a resistência à corrosão e à oxidação, a praticidade no sensoriamento remoto e a resistência à interferência eletromagnética [182]. Foi demonstrado que o índice de refração da água depende da salinidade, da temperatura e do comprimento de onda [183]. Sun *et al.* desenvolveram um sensor de salinidade com alta exatidão baseado em FBG revestida com poli-imida lamelar [172]. No entanto, seu sensor tem um processo de fabricação rigoroso e apresenta um longo atraso no tempo de resposta devido ao revestimento. Zhang *et al.* propuseram um sensor de salinidade baseado na diferença de caminho óptico de feixes laser usando uma configuração de interferômetro de Michelson [179]. Seu sensor é muito exato, mas não é portátil e, portanto, não é adequado para medição em campo. O sensor proposto por Yin *et al.* apresenta altas sensibilidade e compacidade, mas requer um processo de fabricação longo e delicado que reduz a resistência física do sensor e requer um OSA para a interrogação, tornando o sistema mais caro e menos portátil [178]. Todos os trabalhos citados tiveram que abordar a questão da sensibilidade cruzada à temperatura. As soluções propostas foram a compensação de temperatura ou a medição simultânea. Alguns autores apenas apontaram a existência do problema, deixando a solução para trabalhos futuros.

Em sensoriamento a fibra, é sabido que LPGs são muito sensíveis a mudanças no índice de refração [41]. Como o índice de refração da água salgada muda de acordo com a salinidade, o espectro de transmissão de uma LPG imersa nessa solução também é alterado, exibindo um deslocamento no comprimento de onda ressonante. Portanto, uma LPG pode ser usada como sensor de salinidade. Possetti *et al.* desenvolveram um sensor

de salinidade usando duas LPGs para produzir um interferômetro de Mach-Zehnder no interior da fibra [148]. Sua abordagem atingiu uma sensibilidade considerável com uma montagem simples e compacta, com as vantagens do sensoriamento a fibra. Entretanto, a necessidade de duas LPGs quase idênticas e a interrogação dependente do OSA são desvantagens relativas, além da questão da sensibilidade cruzada à temperatura.

O objetivo desta seção é apresentar uma configuração simples e portátil usando uma única LPG e uma abordagem moderna de interrogação baseada em reflectometria óptica no domínio do tempo, que se aproveita de técnicas de processamento de sinais para realizar sensoriamento remoto com boa exatidão e todas as vantagens do sensoriamento a fibra.


A montagem experimental consiste em um OTDR Anritsu MT9083A2-073, uma bobina de 4 km de fibra, uma pequena seção de fibra contendo a LPG encapsulada em um invólucro retangular impresso em 3D e, por fim, uma bobina de 10 km. É importante que ambas as bobinas tenham comprimento suficiente para separar, no traço, o evento da LPG do começo da fibra e do seu fim. A LPG não deve ser colocada excessivamente distante do OTDR de forma que sua faixa dinâmica seja insuficiente para capturar o evento da LPG. Usando fibra monomodo padrão, o OTDR certifica com exatidão distâncias de mais de 100 km, chegando a 300 km dependendo da configuração [138], o que confere uma faixa apreciável para o sensoriamento remoto. Com exceção dessas restrições, as bobinas podem ser tão longas quanto a aplicação demande.

A LPG foi inscrita em fibra monomodo padrão através da técnica do arco elétrico ponto a ponto, usando uma máquina de fusão especialmente modificada com o auxílio de um sistema de posicionamento manual de precisão micrométrica. O período da grade foi de 530 μm a fim de produzir uma banda de atenuação na mesma região espectral da fonte de luz do OTDR, em aproximadamente 1550 nm. A Figura 29 mostra o espectro de transmissão da LPG imersa em água pura juntamente com o espectro de emissão da fonte de luz do OTDR. Como indicado pelas setas, o espectro da LPG se refere ao eixo vertical da esquerda, enquanto o espectro do OTDR se refere ao eixo vertical da direita.

O invólucro é um recipiente retangular de topo aberto impresso em 3D. Antes de fundir os conectores, a LPG é inserida no invólucro e fixada no lugar com uma tensão mínima usando adesivo instantâneo. A Figura 30 mostra um modelo da LPG encapsulada. O adesivo é aplicado dos dois lados do invólucro, apenas nas paredes externas, a fim de não interagir com as amostras no interior. Seringas são usadas para inserir as soluções no recipiente através do topo, para remover as soluções e para realizar a rotina de limpeza entre as medições. O invólucro foi colado a uma base de vidro para prover estrutura. A Figura 31 mostra a LPG encapsulada em primeiro plano com o OTDR ao fundo durante uma medição.


A primeira rodada de experimentos tinha o objetivo de estabelecer uma referência

Figura 29 – Espectros de transmissão da LPG utilizada e de emissão da fonte do OTDR.



Fonte: adaptada de [137].

Figura 30 – Modelo da LPG e do seu invólucro.



Fonte: [137].

através da obtenção do traço de OTDR do sistema com a LPG imersa em água destilada. Nessa rodada, não houve procedimento de limpeza entre os experimentos, porque não havia contaminação entre as amostras. A temperatura ambiente foi mantida aproximadamente constante ao longo dos experimentos. Cada experimento seguiu o seguinte processo: uma seringa foi usada para encher o invólucro da LPG com água destilada, o traço foi coletado e gravado em uma memória externa, a água foi removida do recipiente com a seringa e, por fim, descartada. Essa rodada terminou depois da coleta de 30 traços.

Mais cinco rodadas de experimentos foram realizadas usando soluções de sal comercial em água destilada a diferentes concentrações $\rho \in \{40,0; 50,0; 60,0; 70,0; 80,0\}$ (g/L). A água destilada foi usada como solvente e, também, no procedimento de limpeza, a

Figura 31 – Montagem experimental durante uma medição.

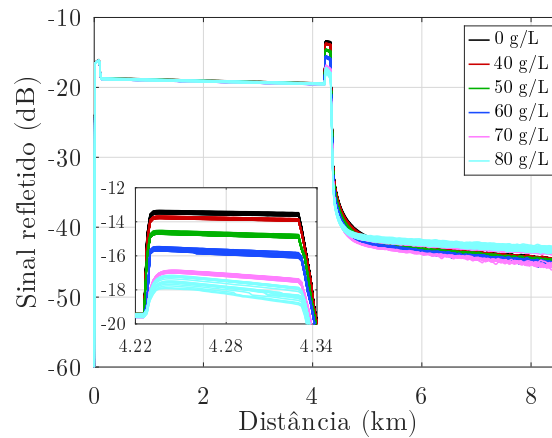


Fonte: adaptada de [137].

fim de garantir um experimento controlado e de evitar a contaminação das amostras. O sal comercial é composto principalmente de cloreto de sódio (NaCl), mas adiciona-se iodato de potássio (KIO_3) à concentração 45 mg/Kg durante a fabricação, além de outros aditivos secundários. As concentrações de KIO_3 e de outros aditivos nas soluções preparadas foram consideradas desprezíveis. As soluções foram preparadas pesando a quantidade adequada de sal em uma balança digital com precisão de 0,1 g e adicionando essa quantidade a 500,0 mL de água destilada, quantificada usando a mesma balança. As soluções foram misturadas até adquirirem uma aparência homogênea antes de cada experimento. Cada rodada consistiu em 30 experimentos. Nessas rodadas, cada experimento foi realizado conforme segue: uma seringa foi usada para encher o invólucro da LPG com a solução sob teste, o traço foi coletado e gravado em uma memória externa, a solução foi removida do recipiente com a seringa e descartada, então, outra seringa foi usada para lançar um jato de água destilada no recipiente e descartá-la, repetindo esse passo duas vezes. O procedimento de limpeza segue a evidência experimental de que sensores a fibra imersos em água salgada recuperam suas características originais após um simples jato de água doce [184]. Esse procedimento também ajuda a garantir que cada rodada de experimentos seja repetível. Em uma aplicação de campo em que o sensor esteja permanentemente imerso em água salgada, a rotina de limpeza não é viável e um mecanismo de agitação é aconselhável se a água for parada, a fim de evitar a deposição de sal no sensor.

Cada experimento produziu um traço de OTDR como resultado intermediário. A

Figura 32 – Traços de OTDR com a LPG sujeita a amostras de diferentes salinidades.



Fonte: adaptada de [137].

Figura 32 mostra todos os traços coletados durante os experimentos, classificados segundo a salinidade em cada experimento de acordo com a legenda. O gráfico menor mostra os detalhes dos traços na região em torno da LPG. O traço, nessa região, foi submetido a um processamento durante o qual um conjunto de quatro descritores de características $x_i \mid i \in \{1, 2, 3, 4\}$ foi calculado. A escolha dos descritores de características foi inspirada em técnicas de processamento de áudio. Apesar de os descritores não terem mais seus significados físicos associados ao contexto de um sinal de áudio, mantém-se sua habilidade de extrair informação resumida da estrutura de dados subjacente. O primeiro descritor, x_1 , é a abscissa do centroide do traço, analogamente ao centroide espectral em sinais de áudio. Esse descritor marca a localização do centro de gravidade da forma localizada entre o traço e o eixo horizontal, que pode ser influenciada, por exemplo, pela inclinação do traço na faixa selecionada. O descritor x_2 é baseado na potência média, que está relacionada com a intensidade do sinal em processamento de áudio e, nesse caso, à intensidade média do sinal retroespalhado medido pelo OTDR na faixa selecionada. O descritor x_3 é baseado na largura de banda, que, em processamento de áudio, é a faixa de frequências ponderada pelo espectro. Nesta aplicação, esse descritor representa a faixa selecionada de distâncias do traço ponderada pela potência refletida e pode ser influenciado principalmente pelo formato do traço nessa faixa. O descritor x_4 é baseado no fluxo espectral, uma medida da mudança espectral local em sinais de áudio. Seu significado físico nesta aplicação está relacionado à intensidade da diferença posterior do traço, que é influenciada principalmente por variações abruptas do traço no intervalo selecionado. As Equações (5.10)–(5.13) definem os quatro descritores de características matematicamente:

$$x_1 = \frac{\sum_{n=1}^N P(\ell_n) \ell_n}{\sum_{n=1}^N P(\ell_n)}, \quad (5.10)$$

$$x_2 = \frac{1}{N} \sum_{n=1}^N [P(\ell_n)]^2, \quad (5.11)$$

$$x_3 = \frac{\sum_{n=1}^N |x_1 - \ell_n| P(\ell_n)}{\sum_{n=1}^N P(\ell_n)}, \quad (5.12)$$

$$x_4 = \sum_{n=2}^N |P(\ell_n) - P(\ell_{n-1})|^2, \quad (5.13)$$

em que ℓ_n é a abscissa do n -ésimo ponto do traço selecionado, isto é, a distância do OTDR ao n -ésimo ponto da região relevante no traço, $P(\ell_n)$ é a potência refletida medida originada à distância ℓ_n do OTDR e N é o número de pontos na região selecionada.

Depois de calcular os descritores de características para uma rodada de experimentos, seus valores foram normalizados ao intervalo $[0, 1]$ a fim de: (i) evitar enviar os consequentes estágios de processamento devido à grande diferença de magnitude entre os descritores; (ii) prover uma base para a comparação entre os diferentes descritores e (iii) tornar os descritores adimensionais, refletindo o fato de que seus significados físicos tenham sido preteridos. Seja \mathbf{D} um vetor contendo os valores de qualquer descritor x_i em uma rodada de experimentos. Os valores normalizados do descritor $\tilde{\mathbf{D}}$ foram obtidos usando a Equação (5.14):

$$\tilde{\mathbf{D}} = \frac{\mathbf{D} - \min\{\mathbf{D}\}}{\max\{\mathbf{D}\} - \min\{\mathbf{D}\}}. \quad (5.14)$$

Para cada experimento, um vetor de características expandido $\mathbf{x} \in \mathbb{R}^{1 \times N_f}$ foi, então, construído usando os descritores de características normalizados \tilde{x}_i , suas potências \tilde{x}_i^k , com $k \in \mathbb{N} \mid k \leq 7$, seus produtos cruzados até o expoente 7, e um valor constante. A definição dos elementos do vetor de características pode ser resumida como $\prod_{i=1}^4 \tilde{x}_i^{k_i}$, para todo $k_i \in \mathbb{Z} \mid 0 \leq k_i \leq 7$. Usando essa definição, o tamanho N_f do vetor de características é 4096. A forma geral do vetor de características expandido é definida na Equação (5.15):

$$\mathbf{x} = \left[1 \quad \tilde{x}_1 \quad \tilde{x}_2 \quad \tilde{x}_3 \quad \tilde{x}_4 \quad \cdots \quad \tilde{x}_1^7 \tilde{x}_2^7 \tilde{x}_3^7 \tilde{x}_4^7 \right]_{1 \times N_f}. \quad (5.15)$$

Considerando todas as rodadas, N_e experimentos foram feitos, gerando N_e traços de OTDR, e N_e vetores de características. Os vetores de características \mathbf{x}_j , com $j \in \mathbb{N} \mid j \leq N_e$, foram concatenados formando uma matriz $\mathbf{X}_{[N_e \times N_f]}$, em que cada linha representa um experimento e cada coluna representa uma característica, conforme a Equação (5.16):

$$\mathbf{X} = \begin{bmatrix} \mathbf{x}_1 \\ \mathbf{x}_2 \\ \vdots \\ \mathbf{x}_{N_e} \end{bmatrix}_{N_e \times N_f} . \quad (5.16)$$

A importância de cada característica ao descrever os experimentos não é uniforme. Algumas características carregam mais informação única e, portanto, são mais importantes. A fim de reduzir a dimensionalidade de \mathbf{X} e ao mesmo tempo manter a maior quantidade possível de informação, uma abordagem baseada na análise de componentes principais foi utilizada. O objetivo era decidir quantas e quais características deveriam ser mantidas. Para determinar quais características deveriam ser mantidas, um procedimento delineado em [120] foi utilizado: a característica (ainda não selecionada) com o maior coeficiente associado a cada uma das primeiras componentes principais foi mantida. Para determinar quantas características deveriam ser mantidas, um cuidado adicional foi necessário a fim de prevenir o sobreajuste.

Tendo em vista que esse estágio está efetivamente selecionando um modelo para representar o sistema sensor/interrogador, usou-se a validação cruzada *k-fold*, com $k = 10$, para garantir que o modelo final, treinado, seja capaz de generalizar esse conhecimento para um conjunto de dados independente. Dessa forma, as linhas de \mathbf{X} foram aleatoriamente subdivididas em 10 grupos, então, vetores de características com diferentes tamanhos foram construídos através do algoritmo baseado em PCA usando 9 dos grupos, e o grupo restante foi usado como validação. Esse processo foi realizado 10 vezes, e cada grupo foi usado como validação uma vez. Para cada valor do tamanho do vetor de características, uma regressão linear múltipla foi usada para estimar a salinidade medida usando os grupos de treino, e o erro padrão calculado no grupo de validação foi usado como critério para determinar o melhor modelo. O erro padrão representa o desvio médio que os valores observados apresentam em relação à linha de regressão. O modelo selecionado indica as características que devem compor o vetor de características final. Uma implementação treinada desse modelo oferece um meio de estimar a salinidade medida.

Finalmente, 70 % dos dados experimentais foram usados para ajustar o modelo selecionado e os 30 % restantes foram usados para calcular os resultados mostrados abaixo. Isso serve para garantir que os resultados não sejam específicos dos dados de treinamento, mas sim que possam ser generalizados.


Esse é o último passo da metodologia proposta. O sistema está, então, preparado para medir salinidade em amostras novas. Em resumo, a metodologia pode ser explicada como segue. A LPG reage à salinidade na água e exibe mudanças no seu espectro de transmissão que refletem as alterações nas perdas sofridas pela luz que se propaga no seu interior. O traço de OTDR do sistema é obtido. Devido à interação da luz oriunda da

fonte do OTDR com a LPG em diferentes condições de salinidade, o traço é modulado na região em torno da LPG. Usa-se, então, a extração de características para obter informação relevante a partir dos traços de forma numérica. Finalmente, os valores resultantes dos descritores de características são usados em um algoritmo de regressão para produzir uma estimativa da salinidade da amostra sob teste.

Os experimentos foram realizados de acordo com o procedimento descrito acima. Como 30 repetições foram feitas em cada uma das 6 diferentes concentrações de sal, o número total de experimentos foi 180. Todos os traços obtidos durante os experimentos foram mostrados na Figura 32.

O primeiro passo no pós-processamento dos resultados é o cálculo dos descritores de características normalizados. A Figura 33 mostra os resultados desse passo. Os marcadores indicam a média aritmética dos valores encontrados para os respectivos descritores em cada concentração. As barras de erro indicam o intervalo de variação dos valores encontrados, isto é, os valores máximos e mínimos em cada concentração. Como mostrado na Figura 33, os descritores não são lineares quanto à salinidade da amostra. Em alguns casos, há pouca mudança em um descritor entre concentrações adjacentes. No entanto, uma combinação adequada de descritores é capaz de estimar o valor da salinidade corretamente.

Figura 33 – Valores normalizados dos descritores de características.




Fonte: adaptada de [137].

O próximo passo é determinar as melhores características para compor o modelo a ser ajustado. Essa seleção de modelo é feita usando a validação cruzada *k-fold* e a regressão linear, como descrito acima. Verificou-se que ao incluir mais de 56 características havia uma tendência relevante ao sobreajuste ou o ajuste não era adequado. Portanto, os desempenhos dos modelos de até 56 características na validação cruzada *k-fold* são mostrados na Figura 34. Tendo em vista que o critério de desempenho escolhido foi o erro padrão da regressão linear baseada no vetor de características de cada tamanho, uma

pontuação menor representa um ajuste melhor, e o modelo com o respectivo tamanho e composto das características selecionadas é um candidato melhor. Descobriu-se que o melhor tamanho para o vetor de características é 23, com um erro padrão de 1,3 g/L. Esse valor é calculado considerando apenas dados não utilizados no treinamento, para evitar o sobreajuste.

Figura 34 – Pontuação dos modelos na validação cruzada *k-fold*.



Fonte: adaptada de [137].

Finalmente, o conjunto de dados original foi particionado em um subgrupo de treino contendo 70 % dos experimentos e um subgrupo de teste com os 30 % restantes. O modelo selecionado foi ajustado aos dados usando o subgrupo de treino, que contém 126 experimentos. A Tabela 8 mostra os coeficientes associados a cada característica no modelo final. A estimativa da salinidade medida é o resultado da regressão, dado pela soma dos produtos dos coeficientes pelos valores das características na Tabela 8, usando o subgrupo de teste, que contém 54 experimentos.

A Figura 35 mostra os resultados da regressão e os resíduos do modelo final ajustado, com um valor de R^2 igual a 0,9993. Os pontos no gráfico principal representam a média aritmética dos resultados da regressão para cada concentração de sal, enquanto a linha reta representa um estimador ideal para comparação. Em todos os casos, alta exatidão foi alcançada: a média está próxima do valor esperado, que é a salinidade alvo. Além disso, a estimação é precisa: as barras de erro, que representam o intervalo de valores encontrados em cada concentração, mostram que há uma variação pequena em torno do valor central. No gráfico menor, cada ponto representa o resíduo de um experimento do grupo de teste.


A Tabela 9 apresenta informações numéricas detalhadas sobre os resultados. Nota-se que todas as médias estimadas estão a, no máximo, 0,4 g/L do valor alvo. Na média, o erro absoluto não passa de 0,7 g/L em cada concentração e foi calculado como 0,5 g/L de forma global. O pior caso de erro absoluto encontrado foi de 1,6 g/L. O erro padrão

Tabela 8 – Coeficientes do modelo de regressão final.

Coeficiente	Característica	Coeficiente	Característica
576,000	1	-191,084	\tilde{x}_2^6
279,017	\tilde{x}_1	-2 631,655	\tilde{x}_3^6
-2 073,524	\tilde{x}_2	48,744	\tilde{x}_1^7
-1 265,795	\tilde{x}_3	1 665,088	\tilde{x}_3^7
298,787	\tilde{x}_4	-289,309	$\tilde{x}_1\tilde{x}_3$
-30,722	\tilde{x}_1^2	-17,764	$\tilde{x}_1\tilde{x}_3^7$
1 591,529	\tilde{x}_2^2	135,788	$\tilde{x}_1^3\tilde{x}_3^7$
-291,119	\tilde{x}_3^2	-39,848	$\tilde{x}_1^7\tilde{x}_3^2$
-99,631	\tilde{x}_2^3	-547,288	$\tilde{x}_1\tilde{x}_4^2$
2 029,320	\tilde{x}_3^3	2 102,660	$\tilde{x}_2\tilde{x}_3$
-67,432	\tilde{x}_1^4	55,362	$\tilde{x}_2^7\tilde{x}_4^7$
11,132	\tilde{x}_1^6		

Fonte: adaptada de [137].

Figura 35 – Resultados da regressão e resíduos do modelo ajustado.



Fonte: adaptada de [137].

desse modelo foi de 0,6 g/L. Uma análise do gráfico Q-Q dos resíduos mostra que eles estão distribuídos de forma aproximadamente normal, de modo que se espera que 95 % das estimativas estejam a no máximo duas vezes o erro padrão, ou 1,2 g/L, do valor alvo.

O sistema de sensoriamento de salinidade foi apresentado em detalhes e verificado experimentalmente. Dada a relevância da salinidade da água em questões importantes

Tabela 9 – Informação numérica sobre os resultados da regressão.

Salinidade (g/L)	Salinidade Estimada Média (g/L)	Erro Absoluto Médio (g/L)	Erro Absoluto Máximo (g/L)	Erro Padrão (g/L)
0,0	0,0	0,4	1,4	0,5
40,0	39,7	0,7	1,5	0,8
50,0	50,0	0,5	1,4	0,6
60,0	59,9	0,7	1,6	0,9
70,0	70,4	0,4	1,3	0,4
80,0	80,1	0,3	1,1	0,5
	Global	0,5	1,6	0,6

Fonte: adaptada de [137].

discutidas acima e as restrições que a sua medição apresenta a métodos atuais, as vantagens do sistema proposto aqui podem ser atrativas para várias aplicações. Este sistema sensor baseado em fibra é compacto, portátil, barato, seguro, resistente à corrosão e à oxidação, imune à interferência eletromagnética, tem um tempo de resposta curto, permite o sensoriamento remoto de forma direta, requer uma manutenção simples e usa poucos componentes. O interrogador é baseado em medições feitas por OTDR e se aproveita de técnicas de processamento de sinais para realizar sensoriamento remoto com boa exatidão e precisão. A literatura sugere que uma configuração de interrogação desse tipo evite intrinsecamente a sensibilidade cruzada à temperatura na LPG [140], e há pesquisa em andamento a fim de demonstrar isso para o sistema proposto aqui.

Pode ser complexo comparar exatidão e precisão entre sistemas de medição de salinidade devido às diferentes unidades usadas por diferentes autores. As unidades utilizadas aqui, gramas por litro (g/L), são equivalentes a partes por milhar, (*ppt - parts per thousand* - ou ‰), mas muitos autores usam a porcentagem (%), unidades de sólidos dissolvidos totais (TDS - *total dissolved solids*), ou unidades de condutância elétrica como o Siemens ou seus submúltiplos (S, μ S). Em porcentagem, por exemplo, o erro absoluto médio desse sistema equivale a 0,05 % na faixa 0–8 %. Além disso, muitos autores reportam apenas o valor da sensibilidade, já que seus sistemas respondem linearmente ao mensurando. No entanto, para comparação, o erro padrão encontrado acima é menor que as resoluções de outros sistemas refratométricos analisados em [148]: 1,53 g/L e 2,46 g/L. A exatidão também é melhor que aquela apresentada em [172], que tem um erro absoluto de até 0,21 %, além de ter um tempo de resposta que chega a centenas de minutos.

Apesar de métodos condutivimétricos poderem alcançar resoluções de duas a três ordens de grandeza melhores, o método proposto aqui tem exatidão e precisão suficientes

para medir a salinidade mesmo em concentrações relativamente baixas (0–80 g/L ou 0–8 %) a longas distâncias com baixo erro. Além disso, para muitas aplicações, as diversas vantagens do sistema baseado em fibra prevalecem sobre a diferença na resolução.

5.6 DISCUSSÃO

Neste capítulo, três variações de um sistema de interrogação baseado em OTDR foram apresentadas e verificadas experimentalmente. Nos três casos, os resultados mostram que os objetivos foram atingidos com sucesso. No primeiro e no último casos, uma análise mais aprofundada utilizando PCA foi necessária. No entanto, no segundo caso, o objetivo foi alcançado com uma abordagem computacional simples. Juntamente com essas contribuições, revelaram-se três possibilidades de investigação futura, discutidas a seguir.

Uma análise mais profunda da influência de cada parâmetro físico no traço da LPG é necessária a fim de determinar, por exemplo, se o sistema é capaz de distinguir meios com índices de refração semelhantes. Espera-se que a combinação de outros parâmetros de cada fluido forme um padrão único no traço que possa ser reconhecido pelo sistema como correspondente ao respectivo fluido. Tal pesquisa poderia contribuir para o desenvolvimento de configurações de interrogação inovadoras e para o aumento do uso de técnicas de ciência de dados em interrogação óptica.

É necessário investigar a relação entre o projeto da LPG e a faixa dinâmica do sistema, a fim de aprimorar a resolução e interrogar, por exemplo, salinidade em concentrações ainda mais baixas, ou ainda permitir a classificação de mais meios, possivelmente com índices mais próximos entre si. Para isso, a localização espectral do vale de ressonância da LPG relativamente ao espectro de emissão da fonte do OTDR é um ponto chave. Outros descritores, além dos que foram discutidos aqui, podem ser considerados num estudo posterior.

Uma análise adicional também é necessária a fim de aumentar a compreensão sobre a relação entre o projeto da LPG e o tamanho da queda induzida no traço de OTDR. Isso teria especial importância em esquemas de sensoriamento multiponto. A Figura 32 mostra que esta LPG, em particular, causa uma queda de 20 dB nos traços. Portanto, mais uma LPG poderia ser interrogada simultaneamente, considerando que o piso de ruído do instrumento é -60 dB. Uma LPG que cause uma queda menor, mantendo a sensibilidade, permitirá a multiplexação de mais sensores.

6 CONCLUSÃO

Neste trabalho, aplicaram-se técnicas computacionais avançadas no problema da interrogação de sensores ópticos a fibra, com foco nas redes de período longo. A interrogação de LPGs vem se apresentando como um desafio na área de instrumentação óptica há anos, apesar dos avanços recentes na utilização das ferramentas computacionais modernas para esse fim, evidenciando a demanda por aprofundamento.

De acordo com o que foi apresentado nos Capítulos 4 e 5, nota-se que as técnicas computacionais utilizadas se mostraram adequadas à análise de sensores a fibra, especialmente considerando que a utilização de tais técnicas pode auxiliar na redução de custos em um sistema de instrumentação óptica. Os resultados apresentados aqui são melhores que os de sistemas similares ou mostram um desempenho comparável e apresentam outras vantagens.

Ressalta-se que as técnicas utilizadas demandam pouco processamento na operação normal, após o treinamento. Isso permite que os sistemas propostos possam ser implementados de forma portátil em microprocessadores, por exemplo. O sistema baseado em RNA, em particular, pode se beneficiar de uma implementação em FPGA, devido à paralelização comum a essas técnicas. Em ambos os sistemas apresentados, existe o potencial de evolução, de inovação e de desenvolvimento de produto, sobretudo no que se refere ao sistema baseado em OTDR apresentado no Capítulo 5. Nesse caso, a implementação de um estimador com boa resposta representa uma inovação importante para o desenvolvimento da área de instrumentação óptica.

Como resultado da apresentação de duas novas técnicas de interrogação de LPG, com componentes comuns e processamentos simples, além do pacote de simulação que será disponibilizado à comunidade, espera-se contribuir para o incentivo à pesquisa e ao desenvolvimento de sistemas de sensoriamento a fibras, idealmente motivando mais grupos a participarem dessa área.

REFERÊNCIAS

- [1] CULSHAW, B.; KERSEY, A. Fiber-optic sensing: A historical perspective. *Journal of Lightwave Technology*, Institute of Electrical and Electronics Engineers (IEEE), v. 26, n. 9, p. 1064–1078, maio 2008.
- [2] HILL, K. O. et al. Photosensitivity in optical fiber waveguides: application to reflection filter fabrication. *Applied Physics Letters*, AIP Publishing, v. 32, n. 10, p. 647–649, maio 1978.
- [3] MELTZ, G.; MOREY, W. W.; GLENN, W. H. Formation of Bragg gratings in optical fibers by a transverse holographic method. *Optics Letters*, The Optical Society, v. 14, n. 15, p. 823, ago. 1989.
- [4] VENGSARKAR, A. M. et al. Long-period fiber gratings as band-rejection filters. *Journal of Lightwave Technology*, Institute of Electrical and Electronics Engineers (IEEE), v. 14, n. 1, p. 58–65, jan. 1996. ISSN 0733-8724.
- [5] DAVIS, D. D. et al. Long-period fibre grating fabrication with focused CO₂ laser pulses. *Electronics Letters*, Institution of Engineering and Technology (IET), v. 34, n. 3, p. 302, 1998.
- [6] DAVIS, D. D. et al. CO₂ laser-induced long-period fibre gratings: spectral characteristics, cladding modes and polarisation independence. *Electronics Letters*, Institution of Engineering and Technology (IET), v. 34, n. 14, p. 1416, 1998.
- [7] KARPOV, V. I. et al. Mode-field converters and long-period gratings fabricated by thermo-diffusion in nitrogen-doped silica-core fibers. In: *OFC '98. Optical Fiber Communication Conference and Exhibit. Technical Digest. Conference Edition. 1998 OSA Technical Digest Series Vol.2 (IEEE Cat. No.98CH36177)*. [S.l.]: Opt. Soc. America, 1998.
- [8] KOSINSKI, S. G.; VENGSARKAR, A. M. Splicer-based long-period fiber gratings. In: *OFC '98. Optical Fiber Communication Conference and Exhibit. Technical Digest. Conference Edition. 1998 OSA Technical Digest Series Vol.2 (IEEE Cat. No.98CH36177)*. [S.l.]: Opt. Soc. America, 1998.
- [9] GODBOUT, N. et al. Long-period fiber grating by electrical discharge. In: *24th European Conference on Optical Communication. ECOC '98 (IEEE Cat. No.98TH8398)*. [S.l.]: Telefonica, 1998.
- [10] HWANG, I. K.; YUN, S. H.; KIM, B. Y. Long-period fiber gratings based on periodic microbends. *Optics Letters*, The Optical Society, v. 24, n. 18, p. 1263, set. 1999.
- [11] RAJAN, G. (Ed.). *Optical Fiber Sensors: Advanced Techniques and Applications*. Boca Raton, FL: CRC Press, 2015. (Devices, Circuits and Systems).
- [12] YIN, S.; RUFFIN, P. B.; YU, F. T. S. (Ed.). *Fiber Optic Sensors*. 2. ed. Boca Raton, FL: CRC Press, 2008. v. 76. (Optical Science and Engineering, v. 76).
- [13] LOPEZ-HIGUERA, J. M. (Ed.). *Handbook of Optical Fibre Sensing Technology*. [S.l.]: Wiley, 2002.

- [14] KEISER, G. *Optical Fiber Communications*. 4. ed. New York, NY: McGraw-Hill, 2008. ISBN 978-0-07-338071-1.
- [15] BINH, L. N. *Optical Fiber Communication Systems with MATLAB and Simulink Models*. 2. ed. Boca Raton, FL: CRC Press, 2015.
- [16] KEISER, G. *Fiber Optic Communications*. Singapore: Springer, 2021. ISBN 978-981-33-4664-2.
- [17] RIBEIRO, J. A. J. *Comunicações Ópticas*. 4. ed. São Paulo: Érica, 2009.
- [18] AGRAWAL, G. P. *Fiber-Optic Communication Systems*. 3. ed. New York: Wiley, 2002.
- [19] GRATTAN, K. T. V.; MEGGITT, B. T. (Ed.). *Optical Fiber Sensor Technology: Advanced Applications - Bragg Gratings and Distributed Sensors*. New York, NY: Springer, 2000.
- [20] KASHYAP, R. *Fiber Bragg Gratings*. Boston, MA: Academic Press, 2010. ISBN 978-0-12-372579-0.
- [21] HICKE, K. et al. Condition monitoring of industrial infrastructures using distributed fibre optic acoustic sensors. In: CHUNG, Y. et al. (Ed.). *SPIE Proceedings*. Jeju: SPIE, 2017. v. 10323, p. 567–573.
- [22] SONG, Y.; XIA, L.; WU, Y. The interrogation of quasi-distributed optical FBG sensing system through adopting a wavelength-tunable fiber chaotic laser. *Journal of Lightwave Technology*, Institute of Electrical and Electronics Engineers (IEEE), v. 37, n. 10, p. 2435–2442, maio 2019. ISSN 0733-8724.
- [23] MARCUSE, D. Gaussian approximation of the fundamental modes of graded-index fibers. *Journal of the Optical Society of America*, The Optical Society, v. 68, n. 1, p. 103, jan. 1978.
- [24] GLOGE, D. The optical fibre as a transmission medium. *Reports on Progress in Physics*, IOP Publishing, v. 42, n. 11, p. 1777–1824, nov. 1979.
- [25] OLSHANSKY, R. Propagation in glass optical waveguides. *Reviews of Modern Physics*, American Physical Society (APS), v. 51, n. 2, p. 341–367, abr. 1979.
- [26] KEISER, G. *Optical Communications Essentials*. New York, NY: McGraw-Hill, 2003. ISBN 0-07-141204-2.
- [27] SNITZER, E. Cylindrical dielectric waveguide modes. *Journal of the Optical Society of America*, The Optical Society, v. 51, n. 5, p. 491, maio 1961.
- [28] SNYDER, A. W. Asymptotic expressions for eigenfunctions and eigenvalues of a dielectric or optical waveguide. *IEEE Transactions on Microwave Theory and Techniques*, Institute of Electrical and Electronics Engineers (IEEE), v. 17, n. 12, p. 1130–1138, dez. 1969.
- [29] UNGER, H.-G. *Planar optical waveguides and fibers*. Oxford: Oxford University Press, 1977. (Oxford Engineering Science Series). ISBN 0198561334.

- [30] ADAMS, M. J. *An introduction to optical waveguides*. Chichester, NY: Wiley, 1981. ISBN 0471279692.
- [31] MARCUSE, D. *Light Transmission Optics*. 2. ed. New York: Van Nostrand-Reinhold, 1982.
- [32] ERDOGAN, T. Cladding-mode resonances in short- and long-period fiber grating filters. *Journal of the Optical Society of America A*, The Optical Society, v. 14, n. 8, p. 1760, ago. 1997.
- [33] ERDOGAN, T. Cladding-mode resonances in short- and long-period fiber grating filters: errata. *Journal of the Optical Society of America A*, The Optical Society, v. 17, n. 11, p. 2113, nov. 2000.
- [34] KAWANO, K.; KITO, T. *Introduction to Optical Waveguide Analysis: Solving Maxwell's Equation and the Schrödinger Equation*. Hoboken, NJ: Wiley, 2001.
- [35] GLOGE, D. Weakly guiding fibers. *Applied Optics*, The Optical Society, v. 10, n. 10, p. 2252, out. 1971.
- [36] MONERIE, M. Propagation in doubly clad single-mode fibers. *IEEE Journal of Quantum Electronics*, Institute of Electrical and Electronics Engineers (IEEE), v. 18, n. 4, p. 535–542, abr. 1982.
- [37] MARCUSE, D. *Theory of Dielectric Optical Waveguides*. 2. ed. New York: Academic, 1991.
- [38] KOGELNIK, H. Guided-wave optoelectronics. In: _____. *Springer Series in Electronics and Photonics*. [S.l.]: Springer Berlin Heidelberg, 1988. cap. Theory of waveguides and devices, p. 7–88.
- [39] ERDOGAN, T. Fiber grating spectra. *Journal of Lightwave Technology*, Institute of Electrical and Electronics Engineers (IEEE), v. 15, n. 8, p. 1277–1294, ago. 1997. ISSN 0733-8724.
- [40] LEE, B. Review of the present status of optical fiber sensors. *Optical Fiber Technology*, Elsevier BV, v. 9, n. 2, p. 57–79, abr. 2003.
- [41] JAMES, S. W.; TATAM, R. P. Optical fibre long-period grating sensors: characteristics and application. *Measurement Science and Technology*, IOP Publishing, v. 14, n. 5, p. R49–R61, mar. 2003.
- [42] SHENG, H.-J. et al. High-sensitivity temperature-independent differential pressure sensor using fiber Bragg gratings. *Optics Express*, The Optical Society, v. 16, n. 20, p. 16013, set. 2008. ISSN 1094-4087.
- [43] ZHANG, W. et al. FBG-type sensor for simultaneous measurement of force (or displacement) and temperature based on bilateral cantilever beam. *IEEE Photonics Technology Letters*, Institute of Electrical and Electronics Engineers (IEEE), v. 13, n. 12, p. 1340–1342, dez. 2001.
- [44] PRASAD, A. G.; ASOKAN, S. Fiber Bragg grating sensor package for submicron level displacement measurements. *Experimental Techniques*, Springer Science and Business Media LLC, v. 39, n. 6, p. 19–24, maio 2013.

- [45] GANGOPADHYAY, T. K. Prospects for fibre Bragg gratings and Fabry-Perot interferometers in fibre-optic vibration sensing. *Sensors and Actuators A: Physical*, Elsevier BV, v. 113, n. 1, p. 20–38, jun. 2004.
- [46] SENGUPTA, D.; KISHORE, P. Continuous liquid level monitoring sensor system using fiber Bragg grating. *Optical Engineering*, SPIE-Intl Soc Optical Eng, v. 53, n. 1, p. 017102, jan. 2014.
- [47] SU, Y. et al. Use of the polarization properties of magneto-optic fiber Bragg gratings for magnetic field sensing purposes. *Optical Fiber Technology*, Elsevier BV, v. 17, n. 3, p. 196–200, maio 2011.
- [48] 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*, Elsevier BV, v. 15, n. 3, p. 233–236, jun. 2009.
- [49] SHAO, M. et al. Humidity sensor based on hybrid fiber Bragg grating/abrupt fiber taper. *IEEE Sensors Journal*, Institute of Electrical and Electronics Engineers (IEEE), v. 17, n. 5, p. 1302–1305, mar. 2017.
- [50] WOYESSA, G. et al. Low loss polycarbonate polymer optical fiber for high temperature FBG humidity sensing. *IEEE Photonics Technology Letters*, Institute of Electrical and Electronics Engineers (IEEE), v. 29, n. 7, p. 575–578, abr. 2017.
- [51] LI, T. et al. Paralleled structure-based string-type fiber Bragg grating acceleration sensor. *IEEE Sensors Journal*, Institute of Electrical and Electronics Engineers (IEEE), v. 17, n. 5, p. 1325–1332, mar. 2017.
- [52] LI, T. et al. Fiber Bragg grating sensing-based online torque detection on coupled bending and torsional vibration of rotating shaft. *IEEE Sensors Journal*, Institute of Electrical and Electronics Engineers (IEEE), v. 17, n. 7, p. 1999–2007, abr. 2017.
- [53] 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*, Institute of Electrical and Electronics Engineers (IEEE), v. 23, n. 2, p. 223–228, mar. 2017.
- [54] VENGSARKAR, A. M. et al. Long-period fiber-grating-based gain equalizers. *Optics Letters*, The Optical Society, v. 21, n. 5, p. 336, mar. 1996.
- [55] BHATIA, V.; VENGSARKAR, A. M. Optical fiber long-period grating sensors. *Optics Letters*, The Optical Society, v. 21, n. 9, p. 692, maio 1996.
- [56] BHATIA, V. et al. Temperature-insensitive and strain-insensitive long-period grating sensors for smart structures. *Optical Engineering*, SPIE-Intl Soc Optical Eng, v. 36, n. 7, p. 1872, jul. 1997. ISSN 0091-3286.
- [57] BHATIA, V. Applications of long-period gratings to single and multi-parameter sensing. *Optics Express*, The Optical Society, v. 4, n. 11, p. 457, maio 1999. ISSN 1094-4087.
- [58] YARIV, A. Coupled-mode theory for guided-wave optics. *IEEE Journal of Quantum Electronics*, Institute of Electrical and Electronics Engineers (IEEE), v. 9, n. 9, p. 919–933, set. 1973.

- [59] TAYLOR, H. F.; YARIV, A. Guided wave optics. *Proceedings of the IEEE*, Institute of Electrical and Electronics Engineers (IEEE), v. 62, n. 8, p. 1044–1060, 1974.
- [60] HILL, K. O.; MELTZ, G. Fiber Bragg grating technology fundamentals and overview. *Journal of Lightwave Technology*, Institute of Electrical and Electronics Engineers (IEEE), v. 15, n. 8, p. 1263–1276, ago. 1997. ISSN 0733-8724.
- [61] VASILIEV, S. A.; MEDVEDKOV, O. I. Long-period refractive index fiber gratings: Properties, applications, and fabrication techniques. In: DIANOV, E. M. (Ed.). *SPIE Proceedings*. [S.l.]: SPIE, 2000. v. 4083, p. 212–223.
- [62] BISWAS, P. et al. Sensitivity enhancement of turnaround-point long period gratings by tuning initial coupling condition. *IEEE Sensors Journal*, Institute of Electrical and Electronics Engineers (IEEE), v. 15, n. 2, p. 1240–1245, fev. 2015.
- [63] 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*, Wiley, v. 37, n. 1, p. 45–49, abr. 2003. ISSN 1098-2760.
- [64] YUAN, Y. Cladding mode resonances in short- and long-fiber grating filters: comment. *Journal of the Optical Society of America A*, The Optical Society, v. 26, n. 10, p. 2199, out. 2009.
- [65] SINGH, A.; ENGLER, D. Calculation of cladding modes using both two layer and three layer geometry in LPFG. *Optik*, Elsevier BV, v. 124, n. 21, p. 5042–5045, nov. 2013.
- [66] SINGH, A. Study of modeling aspects of long period fiber grating using three-layer fiber geometry. *Photonic Sensors*, Springer Science and Business Media LLC, v. 5, n. 1, p. 32–42, mar. 2015.
- [67] DELGADO, F. S. et al. Propagation characteristics of optical long period fiber gratings using graphical solution methods. *Journal of Microwaves, Optoelectronics and Electromagnetic Applications*, FapUNIFESP (SciELO), v. 15, n. 2, p. 135–145, jun. 2016. ISSN 2179-1074.
- [68] ESPOSITO, F. et al. Experimental study of the refractive index sensitivity in arc-induced long period gratings. *IEEE Photonics Journal*, Institute of Electrical and Electronics Engineers (IEEE), v. 9, n. 1, p. 1–10, fev. 2017.
- [69] NIDHI; KALER, R. S.; KAPUR, P. Theoretical and experimental study of long-period grating refractive index sensor. *Fiber and Integrated Optics*, Informa UK Limited, v. 33, n. 1-2, p. 37–46, jan. 2014.
- [70] 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*, Informa UK Limited, v. 33, n. 5-6, p. 347–359, set. 2014.
- [71] ALVARENGA, Í. et al. A novel experimental set-up for turbidity sensing based on plastic optical fibre. *Journal of Modern Optics*, Informa UK Limited, v. 64, n. 3, p. 214–217, ago. 2016.

- [72] ALVARENGA, Í. 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.
- [73] YANG, J. et al. Long-period fiber grating sensor with a styrene-acrylonitrile nano-film incorporating cryptophane a for methane detection. *Optics Express*, The Optical Society, v. 19, n. 15, p. 14696, jul. 2011. ISSN 1094-4087.
- [74] 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.
- [75] DELGADO, F. S. et al. Mathematical modelling for correlation between temperature and mechanical strain in long period gratings. In: *IEEE SENSORS 2014 Proceedings*. Valencia: IEEE, 2014. p. 1900–1903.
- [76] 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*, Informa UK Limited, v. 64, n. 21, p. 2428–2432, ago. 2017.
- [77] LEE, B. H. Temperature sensor using the self-interference of a long-period fiber grating. In: *13th International Conference on Optical Fiber Sensors*. Kyongju: SPIE, 1999. v. 3746, p. 418–421.
- [78] PATRICK, H. J.; KERSEY, A. D.; BUCHOLTZ, F. Analysis of the response of long period gratings to external index of refraction. *Journal of Lightwave Technology*, Institute of Electrical and Electronics Engineers (IEEE), v. 16, n. 9, p. 1606–1612, set. 1998. ISSN 0733-8724.
- [79] SHU, X.; ZHANG, L.; BENNION, I. Sensitivity characteristics of long-period fiber gratings. *Journal of Lightwave Technology*, Institute of Electrical and Electronics Engineers (IEEE), v. 20, n. 2, p. 255–266, fev. 2002. ISSN 0733-8724.
- [80] CHIANG, K. S. et al. Analysis of etched long-period fibre grating and its response to external refractive index. *Electronics Letters*, Institution of Engineering and Technology (IET), v. 36, n. 11, p. 966, 2000.
- [81] ALLSOP, T.; WEBB, D.; BENNION, I. Investigations of the spectral sensitivity of long period gratings fabricated in three-layered optical fiber. *Journal of Lightwave Technology*, Institute of Electrical and Electronics Engineers (IEEE), v. 21, n. 1, p. 264–268, jan. 2003. ISSN 0733-8724.
- [82] ALLSOP, T. et al. Spectral characteristics of tapered LPG device as a sensing element for refractive index and temperature. *Journal of Lightwave Technology*, Institute of Electrical and Electronics Engineers (IEEE), v. 24, n. 2, p. 870–878, fev. 2006. ISSN 0733-8724.
- [83] LALASANGI, A. et al. Highly sensitive cadmium concentration sensor using long period grating. *Sensors & Transducers*, v. 134, n. 11, p. 76–76, 2011. ISSN 1726-5479.

- [84] RAIKAR, U. et al. Cd concentration sensor based on fiber grating technology. *Sensors and Actuators B: Chemical*, Elsevier BV, v. 161, n. 1, p. 818–823, jan. 2012. ISSN 0925-4005.
- [85] PILLAI, A. B.; VARGHESE, B.; MADHUSOODANAN, K. N. Design and development of a high-performance long-period fiber grating chemical sensor for the accurate determination of fluoride. *Journal of Optics*, Springer India, New Delhi, v. 48, n. 3, p. 318–323, jul. 2019. ISSN 0972-8821.
- [86] GARCÍA, I. et al. Optical fiber sensors for aircraft structural health monitoring. *Sensors*, MDPI AG, v. 15, n. 7, p. 15494–15519, jun. 2015.
- [87] KAKLAUSKAS, G. et al. Reinforcement strains in reinforced concrete tensile members recorded by strain gauges and FBG sensors: Experimental and numerical analysis. *Sensors*, MDPI AG, v. 19, n. 1, p. 200, jan. 2019.
- [88] FALLON, R. W. et al. All-fibre optical sensing system: Bragg grating sensor interrogated by a long-period grating. *Measurement Science and Technology*, IOP Publishing, v. 9, n. 12, p. 1969–1973, dez. 1998.
- [89] ALLSOP, T. et al. The interrogation and multiplexing of long period grating curvature sensors using a Bragg grating based, derivative spectroscopy technique. *Measurement Science and Technology*, IOP Publishing, v. 15, n. 1, p. 44–48, out. 2003. ISSN 0957-0233.
- [90] CARVALHO, J. P. et al. Long-period gratings dynamic interrogation with modulated fiber Bragg gratings and optical amplification. *IEEE Sensors Journal*, Institute of Electrical and Electronics Engineers (IEEE), v. 12, n. 1, p. 179–183, jan. 2012.
- [91] PATRICK, H. et al. Hybrid fiber Bragg grating/long period fiber grating sensor for strain/temperature discrimination. *IEEE Photonics Technology Letters*, Institute of Electrical and Electronics Engineers (IEEE), v. 8, n. 9, p. 1223–1225, set. 1996.
- [92] DÍAZ-HERRERA, N. et al. Fibre-optic SPR sensor with a FBG interrogation scheme for readout enhancement. *Sensors and Actuators B: Chemical*, Elsevier BV, v. 144, n. 1, p. 226–231, jan. 2010.
- [93] GIORDANA, A. A.; SICRE, E. E.; DUCHOWICZ, R. Simple wavelength-to-phase mapping FBG's interrogation method. *Optics and Lasers in Engineering*, Elsevier BV, v. 55, p. 221–225, abr. 2014.
- [94] WEI, L. et al. Tunable multimode fiber based filter and its application in cost-effective interrogation of fiber-optic temperature sensors. *IEEE Photonics Journal*, Institute of Electrical and Electronics Engineers (IEEE), v. 9, n. 2, p. 1–8, abr. 2017.
- [95] ZHANG, P. et al. Optical time-domain reflectometry interrogation of multiplexing low-reflectance Bragg-grating-based sensor system. *Optical Engineering*, SPIE-Intl Soc Optical Eng, v. 42, n. 6, p. 1597, jun. 2003.
- [96] HANN, S.; YOO, J. sang; PARK, C.-S. Monitoring technique for a hybrid PS/WDM-PON by using a tunable OTDR and FBGs. *Measurement Science and Technology*, IOP Publishing, v. 17, n. 5, p. 1070–1074, abr. 2006.

- [97] LO, Y.-L.; XU, S.-H. New sensing mechanisms using an optical time domain reflectometry with fiber Bragg gratings. *Sensors and Actuators A: Physical*, Elsevier BV, v. 136, n. 1, p. 238–243, maio 2007.
- [98] BRAVO, M. et al. New interrogation technique for multiplexing LPG-fiber loop mirrors based displacement sensors using an OTDR. In: *2011 IEEE SENSORS Proceedings*. [S.l.]: IEEE, 2011.
- [99] GIRALDI, M. T. M. R. et al. Interrogation and multiplexing system for fiber loop mirror coupled intensity sensors using OTDR. *Microwave and Optical Technology Letters*, Wiley, v. 56, n. 12, p. 2860–2864, set. 2014.
- [100] WANG, X. et al. An OTDR and gratings assisted multifunctional fiber sensing system. *IEEE Sensors Journal*, Institute of Electrical and Electronics Engineers (IEEE), v. 15, n. 8, p. 4660–4666, ago. 2015.
- [101] WANG, X. et al. SNR enhanced distributed vibration fiber sensing system employing polarization OTDR and ultraweak FBGs. *IEEE Photonics Journal*, Institute of Electrical and Electronics Engineers (IEEE), v. 7, n. 1, p. 1–11, fev. 2015.
- [102] DEY, K. et al. Analysis and performance of edge filtering interrogation scheme for FBG sensor using SMS fiber and OTDR. *Results in Optics*, Elsevier BV, v. 2, p. 100039, jan. 2021.
- [103] JUCÁ, M. A.; SANTOS, A. B. dos. Fiber Bragg grating interrogation using FBG filters and artificial neural network. In: *2017 SBMO/IEEE MTT-S International Microwave and Optoelectronics Conference (IMOC)*. Águas de Lindoia: IEEE, 2017.
- [104] BARINO, F. et al. Comparison of regression methods for transverse load sensor based on optical fiber long-period grating. *Measurement*, Elsevier BV, v. 146, p. 728–735, nov. 2019. ISSN 0263-2241.
- [105] BARINO, F. O.; DELGADO, F. S.; SANTOS, A. B. dos. Transverse load discrimination in long-period fiber grating via artificial neural network. *Journal of Microwaves, Optoelectronics and Electromagnetic Applications*, FapUNIFESP (SciELO), v. 19, n. 1, p. 1–10, mar. 2020. ISSN 2179-1074.
- [106] FAUSETT, L. *Fundamentals of Neural Networks: Architectures, Algorithms and Applications*. Upper Saddle River, NJ: Prentice Hall, 1993.
- [107] BRAGA, A. P.; CARVALHO, A. P. L. F. de; LUDERMIR, T. B. *Redes Neurais Artificiais: Teoria e Aplicações*. Rio de Janeiro: LTC, 2000.
- [108] HERTZ, J.; KROGH, A.; PALMER, R. G. *Introduction to the Theory of Neural Computation*. Boca Raton, FL: CRC Press, 2018.
- [109] SILVA, I. N. da et al. *Artificial Neural Networks: A Practical Course*. [S.l.]: Springer, 2017.
- [110] HAYKIN, S. *Neural Networks and Learning Machines*. 3. ed. Upper Saddle River, NJ: Prentice Hall, 2008.

- [111] CYBENKO, G. Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals, and Systems*, Springer Science and Business Media LLC, v. 2, n. 4, p. 303–314, dez. 1989.
- [112] CYBENKO, G. Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals, and Systems*, Springer Science and Business Media LLC, v. 5, n. 4, p. 455–455, dez. 1992.
- [113] HORNIK, K.; STINCHCOMBE, M.; WHITE, H. Multilayer feedforward networks are universal approximators. *Neural Networks*, Elsevier BV, v. 2, n. 5, p. 359–366, jan. 1989.
- [114] HORNIK, K. Approximation capabilities of multilayer feedforward networks. *Neural Networks*, Elsevier BV, v. 4, n. 2, p. 251–257, 1991.
- [115] RIEDMILLER, M.; BRAUN, H. A direct adaptive method for faster backpropagation learning: the RPROP algorithm. In: *IEEE International Conference on Neural Networks*. San Francisco, CA: IEEE, 1993. p. 586–591.
- [116] BONAMENTE, M. *Statistics and Analysis of Scientific Data*. 2. ed. New York, NY: Springer, 2017.
- [117] FREEDMAN, D. A. *Statistical Models: Theory and Practice*. Cambridge: Cambridge University Press, 2009.
- [118] YAN, X.; SU, X. G. *Linear Regression Analysis*. Singapore: World Scientific, 2009.
- [119] DENG, J. D.; SIMMERMACHER, C.; CRANFIELD, S. A study on feature analysis for musical instrument classification. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, Institute of Electrical and Electronics Engineers (IEEE), v. 38, n. 2, p. 429–438, maio 2008. ISSN 1941-0492.
- [120] JOLLIFFE, I. T. *Principal Component Analysis*. 2. ed. New York: Springer-Verlag, 2002. (Springer Series in Statistics). ISBN 9780387954424.
- [121] ERTEL, W. *Introduction to Artificial Intelligence*. 2. ed. Cham, Switzerland: Springer, 2017. (Undergraduate Topics in Computer Science).
- [122] ALPAYDIN, E. *Introduction to Machine Learning*. 4. ed. Cambridge, MA: The MIT Press, 2020. (Adaptive computation and machine learning series).
- [123] AGGARWAL, C. C. *Neural Networks and Deep Learning: a Textbook*. Cham, Switzerland: Springer, 2018.
- [124] JUCÁ, M. A.; HADDAD, D. B.; SANTOS, A. B. dos. Interrogation system for optical sensor using filter bank and artificial neural network. *Microwave and Optical Technology Letters*, Wiley, v. 62, n. 12, p. 4015–4020, ago. 2020. ISSN 1098-2760.
- [125] 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: IEEE, 2015. p. 1–6.

- [126] VIEGAS, D. et al. Long-period grating fiber sensor with in situ optical source for remote sensing. *IEEE Photonics Technology Letters*, Institute of Electrical and Electronics Engineers (IEEE), v. 22, n. 20, p. 1533–1535, out. 2010.
- [127] LEWIS, E. et al. Principal component analysis and artificial neural network based approach to analysing optical fibre sensors signals. *Sensors and Actuators A: Physical*, Elsevier BV, v. 136, n. 1, p. 28–38, maio 2007.
- [128] 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: IEEE, 2015. p. 1487–1490.
- [129] 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 2011)*. Natal: IEEE, 2011. p. 867–871.
- [130] 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: IEEE, 2013. p. 89–94.
- [131] HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. 2. ed. Upper Saddle River, NJ: Prentice Hall, 1999.
- [132] KOYUNCU, I. Implementation of high speed tangent sigmoid transfer function approximations for artificial neural network applications on FPGA. *Advances in Electrical and Computer Engineering*, Universitatea Stefan cel Mare din Suceava, v. 18, n. 3, p. 79–86, 2018.
- [133] AMARI, S. et al. Asymptotic statistical theory of overtraining and cross-validation. *IEEE Transactions on Neural Networks*, Institute of Electrical and Electronics Engineers (IEEE), v. 8, n. 5, p. 985–996, set. 1997.
- [134] HADDAD, D. B. et al. Brazilian soil bulk density prediction based on a committee of neural regressors. In: *2018 International Joint Conference on Neural Networks (IJCNN)*. Rio de Janeiro: IEEE, 2018. p. 1–8.
- [135] JUCÁ, M. A. et al. Weight classifier using optical time domain reflectometry and a long period grating sensor. *Optical Fiber Technology*, Elsevier BV, v. 67, p. 102694, dez. 2021. ISSN 1068-5200.
- [136] JUCÁ, M. A. et al. Identification of external media using a long-period grating and optical time-domain reflectometry. *Applied Optics*, Optica Publishing Group, v. 62, n. 8, p. C43–C48, fev. 2023.
- [137] JUCÁ, M. A. et al. Water salinity measurement using a long-period grating and optical time-domain reflectometry. *Journal of the Optical Society of America B*, Optica Publishing Group, v. 40, n. 4, p. C8–C14, fev. 2023.
- [138] ANRITSU. *Product Brochure: MT9083 Series*. [S.l.], 2018. Series-E-A-1-(17.00).
- [139] CORNING. *Corning SMF-28 Ultra Optical Fiber*. Corning, NY, 2019. Disponível em: <<https://www.corning.com/media/worldwide/coc/documents/Fiber/PI-1424-AEN.pdf>>.

- [140] FRAZÃO, O. et al. Optical bend sensor based on a long-period fiber grating monitored by an optical time-domain reflectometer. *Optical Engineering*, SPIE-Intl Soc Optical Eng, v. 44, n. 11, p. 110502, nov. 2005.
- [141] PIRES FILHO, J. C. *Classificação de Instrumentos Musicais em Configurações Monofônicas e Polifônicas*. Dissertação (Mestrado) — Universidade Federal do Rio de Janeiro, 2009.
- [142] OJALA, M.; GARRIGA, G. C. Permutation tests for studying classifier performance. *Journal of Machine Learning Research*, JMLR.org, v. 11, n. 62, p. 1833–1863, ago. 2010. ISSN 1533-7928.
- [143] FALATE, R. et al. Petroleum hydrocarbon detection with long period gratings. In: *Proceedings of the 2003 SBMO/IEEE MTT-S International Microwave and Optoelectronics Conference - IMOC 2003. (Cat. No.03TH8678)*. [S.l.]: IEEE, 2003.
- [144] FALATE, R. et al. Fiber optic hydrocarbon sensors based on long period gratings. *Journal of Microwaves and Optoelectronics*, SBMO, v. 3, n. 5, p. 47–55, jul. 2004. ISSN 1516-7399.
- [145] FALATE, R. et al. Fiber optic sensors for hydrocarbon detection. *Sensors and Actuators B: Chemical*, Elsevier BV, v. 105, n. 2, p. 430–436, mar. 2005.
- [146] FALATE, R. et al. Refractometric sensor based on a phase-shifted long-period fiber grating. *Applied Optics*, The Optical Society, v. 45, n. 21, p. 5066, jul. 2006.
- [147] FALATE, R. et al. Alternative technique for biodiesel quality control using an optical fiber long-period grating sensor. *Química Nova*, FapUNIFESP (SciELO), v. 30, n. 7, p. 1677–1680, 2007.
- [148] POSSETTI, G. R. C. et al. Salinity measurement in water environment with a long period grating based interferometer. *Measurement Science and Technology*, IOP Publishing, v. 20, n. 3, p. 034003, fev. 2009.
- [149] POSSETTI, G. R. C. et al. Application of a long-period fibre grating-based transducer in the fuel industry. *Measurement Science and Technology*, IOP Publishing, v. 20, n. 3, p. 034012, fev. 2009.
- [150] POSSETTI, G. R. C. et al. Long period grating transducer for measurement of ethanol concentration in water solution. *Journal of Microwaves, Optoelectronics and Electromagnetic Applications*, SBMO, v. 8, n. 1, p. 17S–25S, jun. 2009. ISSN 1516-7399.
- [151] POSSETTI, G. R. C. et al. Sensing ethanol-blended gasoline with long-period fiber grating: a metrological perspective. *Journal of Microwaves, Optoelectronics and Electromagnetic Applications*, SBMO, v. 12, n. SI-1, p. si9–si17, jan. 2013. ISSN 1516-7399.
- [152] TERADA, G. G. et al. Characterization of an encapsulated long period grating transducer applied as a refractometer. In: *2009 SBMO/IEEE MTT-S International Microwave and Optoelectronics Conference (IMOC)*. [S.l.]: IEEE, 2009.
- [153] KAWANO, M. S. et al. Tailoring fiber grating sensors for assessment of highly refractive fuels. *Applied Optics*, The Optical Society, v. 51, n. 12, p. 2015, abr. 2012.

- [154] ENRÍQUEZ, D. A. C.; CRUZ, A. R. da; GIRALDI, M. T. M. R. Hybrid FBG–LPG sensor for surrounding refractive index and temperature simultaneous discrimination. *Optics & Laser Technology*, Elsevier BV, v. 44, n. 4, p. 981–986, jun. 2012.
- [155] HEIDEMANN, B. R. et al. Matching long-period grating modes and localized plasmon resonances: effect on the sensitivity of the grating to the surrounding refractive index. *Applied Optics*, The Optical Society, v. 55, n. 32, p. 8979, nov. 2016.
- [156] HEIDEMANN, B. R. et al. Functionalized long period grating—plasmonic fiber sensor applied to the detection of glyphosate in water. *Journal of Lightwave Technology*, Institute of Electrical and Electronics Engineers (IEEE), v. 36, n. 4, p. 863–870, fev. 2018.
- [157] BERRETTONI, C. et al. Fibre tip sensor with embedded FBG-LPG for temperature and refractive index determination by means of the simple measurement of the FBG characteristics. *Journal of Sensors*, Hindawi Limited, v. 2015, p. 1–8, 2015.
- [158] SUN, A.; WU, Z. A hybrid LPG/CFBG for highly sensitive refractive index measurements. *Sensors*, MDPI AG, v. 12, n. 6, p. 7318–7325, maio 2012. ISSN 1424-8220.
- [159] XUE, P. et al. Investigation of a d-shaped plastic optical fiber assisted by a long period grating for refractive index sensing. *IEEE Sensors Journal*, Institute of Electrical and Electronics Engineers (IEEE), v. 20, n. 2, p. 842–847, jan. 2020.
- [160] JANIK, M. et al. Combined long-period fiber grating and microcavity in-line Mach–Zehnder interferometer for refractive index measurements with limited cross-sensitivity. *Sensors*, MDPI AG, v. 20, n. 8, p. 2431, abr. 2020.
- [161] CALDAS, P.; REGO, G. Optical fiber interferometers based on arc-induced long period gratings at INESC TEC. *Sensors*, MDPI AG, v. 21, n. 21, p. 7400, nov. 2021.
- [162] WANG, J. et al. Line by line inscribed small period long period grating for wide range refractive index sensing. *Optics Communications*, Elsevier BV, v. 508, p. 127821, abr. 2022.
- [163] RANA, S.; KANDADAI, N.; SUBBARAMAN, H. Towards the design of a wideband reflective long period grating distributed sensor. *Journal of Physics Communications*, IOP Publishing, v. 4, n. 6, p. 065015, jun. 2020.
- [164] RANA, S.; KANDADAI, N.; SUBBARAMAN, H. Experimental validation of a reflective long period grating design methodology. *Results in Optics*, Elsevier BV, v. 7, p. 100224, maio 2022.
- [165] JIANG, H. et al. A high sensitivity sensor based on novel CLPFG with wavelength and intensity modulation for simultaneous measurement of SRI and temperature. *Optical Fiber Technology*, Elsevier BV, v. 70, p. 102886, maio 2022.
- [166] HALE, G. M.; QUERRY, M. R. Optical constants of water in the 200-nm to 200- μ m wavelength region. *Applied Optics*, The Optical Society, v. 12, n. 3, p. 555, mar. 1973. ISSN 1539-4522.

- [167] MILLER, W. J. W. et al. Using a handheld refractometer in remote environments to measure the refractive indices of a variety of solutions: Sucrose, coffee, methanol/water, and 2-propanol/water. *Journal of Chemical Education*, American Chemical Society (ACS), v. 98, n. 8, p. 2730–2734, jul. 2021.
- [168] AMLOY, S.; PREECHABURANA, P. Smartphone-based critical angle refractometer for real-time monitoring of brix value. *IEEE Photonics Technology Letters*, Institute of Electrical and Electronics Engineers (IEEE), v. 31, n. 4, p. 307–310, fev. 2019.
- [169] WRIGHT, D. G. An equation of state for use in ocean models: Eckart’s formula revisited. *Journal of Atmospheric and Oceanic Technology*, American Meteorological Society, v. 14, n. 3, p. 735–740, jun. 1997.
- [170] NGUYEN, L. V.; VASILIEV, M.; ALAMEH, K. Three-wave fiber Fabry–Pérot interferometer for simultaneous measurement of temperature and water salinity of seawater. *IEEE Photonics Technology Letters*, Institute of Electrical and Electronics Engineers (IEEE), v. 23, n. 7, p. 450–452, abr. 2011.
- [171] PAUW, P. S. et al. Groundwater salinity monitoring using a new fiber optic sensor. *Groundwater Monitoring & Remediation*, Wiley, v. 42, n. 3, p. 123–124, jun. 2022.
- [172] SUN, M.-Y. et al. Development of FBG salinity sensor coated with lamellar polyimide and experimental study on salinity measurement of gravel aquifer. *Measurement*, Elsevier BV, v. 140, p. 526–537, jul. 2019.
- [173] SONEHARA, M.; TOAI, N. V.; SATO, T. Fundamental study of non-contact water salinity sensor by using electromagnetic means for seawater desalination plants. *IEEE Transactions on Magnetics*, Institute of Electrical and Electronics Engineers (IEEE), v. 52, n. 7, p. 1–4, jul. 2016.
- [174] THORSLUND, J.; VLIET, M. T. H. van. A global dataset of surface water and groundwater salinity measurements from 1980–2019. *Scientific Data*, Springer Science and Business Media LLC, v. 7, n. 1, jul. 2020.
- [175] HEYDARI, M. J. F.; TABATABAEI, N.; REZAI, P. Low-cost resistive microfluidic salinity sensor for high-precision detection of drinking water salt levels. *ACS Omega*, American Chemical Society (ACS), v. 7, n. 18, p. 15529–15539, abr. 2022.
- [176] ROY, S. K.; SHARAN, P. Application of machine learning for real-time evaluation of salinity (or TDS) in drinking water using photonic sensors. *Drinking Water Engineering and Science*, Copernicus GmbH, v. 9, n. 2, p. 37–45, set. 2016.
- [177] AMIRI, M. et al. Remote water salinity sensor using metamaterial perfect absorber. *IEEE Transactions on Antennas and Propagation*, Institute of Electrical and Electronics Engineers (IEEE), v. 70, n. 8, p. 6785–6794, ago. 2022.
- [178] YIN, Y. et al. High-sensitivity salinity sensor based on optical microfiber coil resonator. *Optics Express*, The Optical Society, v. 26, n. 26, p. 34633, dez. 2018.
- [179] ZHANG, H. et al. Water temperature and salinity measurement using frequency comb. *Applied Sciences*, MDPI AG, v. 9, n. 23, p. 5043, nov. 2019.

- [180] TAHA, T. A.; ELSAYED, H. A.; MEHANEY, A. One-dimensional symmetric phononic crystals sensor: towards salinity detection and water treatment. *Optical and Quantum Electronics*, Springer Science and Business Media LLC, v. 54, n. 5, abr. 2022.
- [181] RAHMAN, M. N.; ISLAM, M. T.; SAMSUZZAMAN, M. Development of a microstrip based sensor aimed at salinity and sugar detection in water considering dielectric properties. *Microwave and Optical Technology Letters*, Wiley, v. 60, n. 3, p. 667–672, fev. 2018.
- [182] QIAN, Y. et al. Review of salinity measurement technology based on optical fiber sensor. *Sensors and Actuators B: Chemical*, Elsevier BV, v. 260, p. 86–105, maio 2018.
- [183] QUAN, X.; FRY, E. S. Empirical equation for the index of refraction of seawater. *Applied Optics*, The Optical Society, v. 34, n. 18, p. 3477, jun. 1995.
- [184] DÍAZ-HERRERA, N. et al. In situ salinity measurements in seawater with a fibre-optic probe. *Measurement Science and Technology*, IOP Publishing, v. 17, n. 8, p. 2227–2232, jul. 2006.
- [185] RABELLO, I. G. Y.; JUCÁ, M. A.; HENRIQUES, F. da R. Desenvolvimento de uma interface gráfica para simulador de meios ópticos guiados. In: *Anais do XL Simpósio Brasileiro de Telecomunicações e Processamento de Sinais*. Santa Rita do Sapucaí, MG: Sociedade Brasileira de Telecomunicações, 2022.
- [186] HOCKER, G. B. Fiber-optic sensing of pressure and temperature. *Applied Optics*, The Optical Society, v. 18, n. 9, p. 1445, maio 1979.
- [187] MELTZ, G. Overview of fiber grating-based sensors. In: KERSEY, A. D.; DAKIN, J. P. (Ed.). *SPIE Proceedings*. [S.l.]: SPIE, 1996.
- [188] MACHADO DE ASSIS, J. M. *Memórias Póstumas de Brás Cubas*. Rio de Janeiro: Antofágica, 2019. ISBN 978-65-80210-01-5.

APÊNDICE A – GratingSim

GratingSim é um pacote de simulação de sistemas ópticos com foco em grades de difração desenvolvido em Python com a contribuição de alunos da Universidade Federal de Juiz de Fora (UFJF) e da Universidade de São Paulo (USP), todos ex-alunos do Centro Federal de Educação Tecnológica Celso Suckow da Fonseca (CEFET/RJ). Esse pacote de *software* é capaz de calcular diferentes modos de propagação em fibras, de estimar a perda na fibra incluindo o efeito da dispersão, de simular conjuntos com componentes como conectores, acopladores e emendas, de simular a propagação em grades de difração, tanto de período curto quanto longo, incluindo seu efeito sensor em relação à temperatura, à deformação e ao índice de refração, e de simular diferentes tipos de fonte de luz, incluindo um reflectômetro óptico no domínio do tempo (*Optical Time-Domain Reflectometer* - OTDR), com a estimativa do traço medido por esse instrumento.

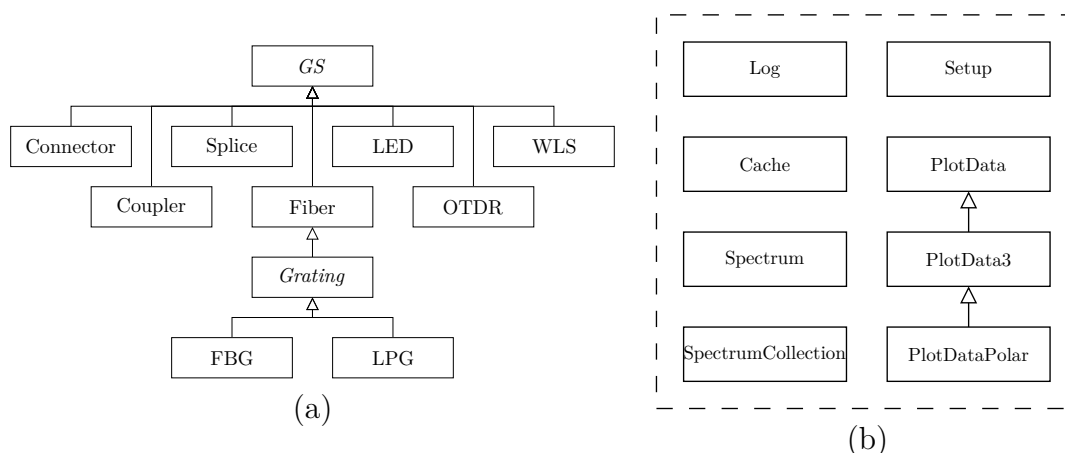
Este apêndice tem o objetivo de apresentar o estado atual da interface pública do GratingSim. O pacote encontra-se no estágio de desenvolvimento ativo inicial e, por isso, mudanças no código são frequentes. A princípio, o pacote oferece uma interface via comandos em Python. Um protótipo de interface gráfica foi desenvolvido também em Python [185], no entanto, devido aos problemas identificados, um novo projeto mais flexível e intuitivo será desenvolvido com orientação à *web*. É importante notar que a interface gráfica não realiza processamento de simulação. Em vez disso, ela usa os métodos disponibilizados pela interface pública em Python e funciona como uma máscara. Isso faz com que a interface gráfica e o simulador possam ser projetos separados, com certa independência. Dessa forma, apenas o simulador será abordado neste texto, com foco nas informações de que o usuário precisa para utilizá-lo.

A Figura 36(a) mostra um diagrama das classes principais do pacote de simulação, as quais se espera que o usuário acesse mais frequentemente, enquanto a Figura 36(b) mostra classes auxiliares que também fazem parte do *software*, mas que raramente serão acessadas diretamente por um usuário comum (não desenvolvedor). O simulador é composto ainda de outras classes e arquivos necessários ao seu funcionamento interno, que fogem ao escopo deste texto. Nos diagramas, cada retângulo representa uma classe e exibe seu nome, e as setas indicam herança. As classes com nomes em itálico são classes abstratas.

Abaixo, os nomes de variáveis, de classes, de métodos e de atributos presentes no código são escritos em fonte monoespaçada. As classes auxiliares podem ser apresentadas resumidamente como:

- a) `Log`, uma classe que implementa funcionalidades de registro, importante principalmente para a depuração do próprio código e para o acompanhamento das simulações em maior detalhe;
- b) `Cache`, implementação de uma memória rápida e conveniente para evitar a

Figura 36 – Diagrama de classes do pacote de simulação GratingSim: (a) classes principais; (b) classes auxiliares.



Fonte: elaborada pelo autor (2023).

repetição de cálculos longos e otimizar o processamento;

- c) **Spectrum**, uma forma conveniente de armazenar duas listas correspondentes às frequências e aos valores do espectro em questão, incluindo funções pertinentes como a conversão de/para decibéis, o cálculo da potência total no espectro e desenho do gráfico do espectro;
- d) **SpectrumCollection**, uma representação coletiva de espectros dispostos ao longo de um eixo longitudinal z , conveniente para representar um sistema óptico de componentes conectados em cascata, especialmente em conjunto com o uso de reflectometria;
- e) **Setup**, uma forma de representar a conexão de componentes utilizando uma estrutura de grafo, que é essencial para a eficiência do simulador, e cujos métodos mais utilizados são mostrados nos exemplos abaixo;
- f) **PlotData**, uma classe que reúne, para conveniência, funcionalidades relacionadas à criação de gráficos em duas dimensões usando coordenadas cartesianas, gerando objetos que podem desenhar esses gráficos prontamente ou podem ser armazenados para ativação posterior;
- g) **PlotData3**, semelhante a **PlotData**, porém, para gráficos em três dimensões usando coordenadas cartesianas; e
- h) **PlotDataPolar**, semelhante a **PlotData3**, porém, para gráficos em três dimensões com coordenadas cilíndricas, sendo a coordenada longitudinal representada por mapa de cores.

A classe **GS**, no topo da hierarquia da Figura 36(a), é uma classe abstrata que define comportamentos e características comuns a todos os componentes do simulador. A maioria

desses comportamentos é trivial, por exemplo, a contagem de instâncias ou a verificação de igualdade entre objetos, e é implementada em métodos privados. Seus atributos públicos são dois: (i) `id`, um número identificador que é único para cada objeto e (ii) `label`, um rótulo que permite a verificação textual da classe do objeto e do seu identificador. Essa classe possui um método virtual puro: `get_params`, que deve ser implementado por todas as classes de componentes. Seu objetivo é retornar os parâmetros de um objeto, de forma que um novo objeto idêntico possa ser instanciado a partir desses parâmetros. Na prática, cada classe implementa esse método retornando uma lista dos parâmetros exigidos pelo respectivo construtor, na mesma ordem.

A classe `Connector` implementa um modelo de conector de fibras ópticas. Um dispositivo desse tipo apresenta uma perda e uma reflexão características. Os atributos públicos dessa classe são: (i) `fiber_1`, que armazena o objeto que representa a fibra acoplada a um dos lados do conector; (ii) `fiber_2`, que armazena o objeto representando a fibra conectada ao outro lado; (iii) `loss`, que representa a perda de inserção do conector e é calculado automaticamente a partir das fibras de cada lado e (iv) `orl`, que representa a perda de retorno óptica causada pela reflexão de Fresnel no conector e também é calculado automaticamente a partir de um valor padrão. Tanto a perda de inserção quanto a de retorno têm um componente aleatório gerado para cada instância, adicionando verossimilhança à simulação. A classe possui apenas um método público: `propagate`, que recebe um objeto `Spectrum` como entrada e simula a propagação desse espectro através do dispositivo. Esse método é implementado em diversas outras classes e é importante para a simulação de sistemas ópticos. No caso desta classe, a implementação apenas insere a consideração da reflexão e da perda uniformemente no espectro, retornando um objeto `SpectrumCollection`.

A classe `Splice` implementa um modelo de emenda em fibra óptica e se assemelha à classe `Connector`, com a diferença de que não há, aqui, a reflexão de Fresnel. Consequentemente, não há o atributo `orl`, e não há a consideração dessa reflexão no método `propagate`. Todo o restante desta classe é similar à implementação contida na classe `Connector`.

A classe `Coupler` implementa um modelo simplificado de acoplador óptico. Os atributos públicos são: (i) `inputs`, uma lista das fibras conectadas à entrada do acoplador; (ii) `outputs`, uma lista das fibras conectadas à saída; (iii) `weights`, uma lista de pesos que indica a razão da potência total que cada saída recebe (opcional); (iv) `number_of_inputs`, a quantidade de entradas conectadas e (v) `number_of_outputs`, a quantidade de saídas conectadas. O único método público é o `propagate`, que, nesse caso, soma as potências de todas as entradas, considerando uma perda mínima em cada emenda, e distribui a potência total para as saídas, de acordo com os pesos respectivos. Nota-se que as conexões são implementadas como emendas. Caso seja necessário modelar o comportamento de um acoplador que se conecta por meio de conectores, estes devem ser inseridos explicitamente

nos caminhos ópticos em questão.

As classes `LED`, `OTDR` e `WLS` modelam fontes de luz: um diodo emissor de luz (*Light Emitting Diode*), a fonte de um OTDR e uma fonte de luz branca (*White Light Source - WLS*), respectivamente. Os espectros de emissão recebem um ruído aditivo específico para cada instância. A classe `LED` tem três atributos públicos: (i) `bandwidth`, que controla a largura de banda do espectro de emissão do LED; (ii) `central_wavelength`, que controla a localização espectral do comprimento de onda central do LED e (iii) `power`, que controla a potência óptica no pico de emissão do LED. A classe `OTDR` também tem o atributo `central_wavelength`, mas não tem os outros dois, visto que o formato do espectro é calculado automaticamente a partir de exemplos experimentais. Além disso, há o atributo `pulse_width`, que controla a largura do pulso do OTDR em simulações de traços. Por outro lado, a classe `WLS` tem apenas o atributo `power`, já que o espectro é constante em todas as frequências, exceto pelo ruído. As três classes têm dois métodos públicos: (i) `get_spectrum`, que retorna o espectro de emissão da fonte como um objeto `Spectrum` e (ii) `plot_spectrum`, que gera o gráfico do espectro da fonte e retorna um objeto `PlotData`.

A classe `Fiber` implementa um modelo de fibra óptica de índice degrau em três camadas: núcleo, casca e ambiente externo. Cada objeto dessa classe tem um objeto `Cache` e um `Log` associados, para agilizar o processamento dos cálculos e facilitar a depuração. Essa classe implementa tanto o modelo de modos vetoriais quanto o modelo de modos linearmente polarizados (LP). Os atributos públicos são: (i) `central_wavelength`, que representa o comprimento de onda de operação nas simulações mais simples, na ausência de um objeto simulando uma fonte; (ii) `cladding_index`, que guarda o valor do índice de refração da casca; (iii) `cladding_radius`, que armazena o raio da casca; (iv) `core_index`, o índice do núcleo; (v) `core_radius`, o raio do núcleo; (vi) `external_index`, o índice de refração do meio externo e (vii) `length`, o comprimento da fibra. Essa classe apresenta os métodos públicos descritos abaixo.

- a) `get_numerical_aperture`: retorna a abertura numérica da fibra, um parâmetro que representa a capacidade de uma fibra óptica de coletar luz [18];
- b) `get_core_effective_index`: retorna o índice efetivo do modo de núcleo, calculado usando a Equação (2.3);
- c) `get_lp_effective_index`: retorna o índice efetivo de um modo LP especificado, calculado usando a Equação (2.7);
- d) `get_lp_effective_indices`: retorna uma lista com os índices efetivos dos modos LP especificados, calculados usando a Equação (2.7);
- e) `get_cladding_effective_index`: retorna o índice efetivo de um modo vetorial especificado, calculado usando o modelo de Erdogan [32];
- f) `get_cladding_effective_indices`: retorna uma lista com os índices efetivos

- dos modos vetoriais especificados, calculados usando o modelo de Erdogan [32];
- g) `get_total_loss`: retorna a perda total na fibra, englobando as perdas por absorção no infravermelho, no ultravioleta, na ressonância da água e a perda por espalhamento, de acordo com os comprimentos de onda especificados, usando o modelo apresentado por Keiser [16];
 - h) `plot_index_profile`: gera um gráfico que mostra o perfil radial do índice de refração nas camadas da fibra;
 - i) `plot_electric_field_radial_component`: gera um gráfico da componente radial do campo elétrico em um modo vetorial;
 - j) `plot_electric_field_azimuthal_component`: gera um gráfico da componente azimutal do campo elétrico em um modo vetorial;
 - k) `plot_electric_field_longitudinal_component`: gera um gráfico da componente longitudinal do campo elétrico em um modo vetorial;
 - l) `plot_magnetic_field_radial_component`: gera um gráfico da componente radial do campo magnético em um modo vetorial;
 - m) `plot_magnetic_field_azimuthal_component`: gera um gráfico da componente azimutal do campo magnético em um modo vetorial;
 - n) `plot_magnetic_field_longitudinal_component`: gera um gráfico da componente longitudinal do campo magnético em um modo vetorial;
 - o) `plot_intensity`: gera um gráfico em mapa de cores da intensidade de campo em um modo vetorial;
 - p) `plot_lp_intensity`: gera um gráfico em mapa de cores da intensidade de campo em um modo LP;
 - q) `plot_lp_field`: gera um gráfico do perfil radial do campo elétrico transversal em um modo LP;
 - r) `propagate`: recebe um espectro inicial, simula a propagação de luz através da fibra e retorna um objeto `SpectrumCollection` representando o espectro da luz em cada ponto ao longo da fibra.

A classe `Grating` é uma classe abstrata que define atributos e métodos comuns aos dois tipos de grades em fibras: as grades de Bragg (*Fiber Bragg Grating* - FBG) e as grades de período longo (*Long-Period Grating* - LPG). Como `Grating` é uma subclasse de `Fiber`, os membros desta classe são herdados por aquela. Além disso, na classe `Grating`, os atributos públicos são: (i) `average_index_change`, a variação média no índice de refração do núcleo promovida pela perturbação; (ii) `grating_apodization`, o tipo de apodização da grade, que pode ser uniforme ou gaussiana e define o envelope da perturbação no índice ao longo do eixo longitudinal; (iii) `grating_period`, o período da perturbação que forma a grade;

(iv) `modulation_index`, o índice de modulação da grade; (v) `poisson_ratio`, o coeficiente de Poisson da fibra que contém a grade [186]; (vi) `strain`, a deformação aplicada à grade; (vii) `strain_optic_coefficient`, o coeficiente fotoelástico [187]; (viii) `temperature`, a temperatura ao redor da grade; (ix) `thermal_expansion_coefficient`, o coeficiente de expansão térmica da fibra [186]; (x) `thermo_optic_coefficient`, o coeficiente termo-óptico da fibra [186] e (xi) P11 e P12, as constantes fotoelásticas, ou coeficientes de Pockels, da fibra [186]. Os métodos públicos da classe `Grating` são descritos abaixo.

- a) `get_resonant_wavelengths`: método virtual puro que deve ser implementado pelas subclasses para retornar os comprimentos de onda ressonantes associados a dados modos vetoriais;
- b) `get_lp_resonant_wavelengths`: método virtual puro que deve ser implementado pelas subclasses para retornar os comprimentos de onda ressonantes associados a dados modos LP;
- c) `plot_index_modulation`: mostra graficamente a modulação do índice de refração do núcleo causada pela grade;
- d) `plot_coupling_constants`: calcula dado número de constantes de acoplamento relativas aos primeiros modos vetoriais e as mostra graficamente;
- e) `plot_lp_coupling_constants`: calcula dado número de constantes de acoplamento relativas aos primeiros modos LP e as mostra graficamente;
- f) `plot_spectrum`: método virtual puro que deve ser implementado pelas subclasses para mostrar os gráficos dos espectros da grade considerando o acoplamento para modos vetoriais;
- g) `plot_lp_spectrum`: método virtual puro que deve ser implementado pelas subclasses para mostrar os gráficos dos espectros da grade considerando o acoplamento para modos LP;
- h) `propagate`: método virtual puro que deve ser implementado pelas subclasses para simular a propagação da luz através da grade a partir de um espectro inicial.

As classes `FBG` e `LPG` implementam efetivamente as grades, sem adicionar novos atributos ou métodos. Elas diferem apenas na implementação dos métodos virtuais puros da classe `Grating`. Enquanto a classe `FBG` simula o acoplamento do modo fundamental de núcleo para o modo de núcleo contrapropagante, usando a Equação (2.21) com os parâmetros das Equações (2.22) e (2.23), a classe `LPG` simula o acoplamento do modo fundamental de núcleo para modos de casca copropagantes, usando a Equação (2.24) com os parâmetros das Equações (2.22) e (2.25). Além disso, os métodos `plot_spectrum`, `plot_lp_spectrum` e `propagate` da classe `FBG` operam tanto com o espectro de transmissão

quanto com o de reflexão, enquanto os da classe `LPG` consideram apenas o espectro de transmissão.

Abaixo, serão apresentados alguns exemplos de utilização do pacote de simulação. Trata-se de códigos em Python que importam o pacote `GratingSim`, abreviado como `gs`, e fazem uso da interface pública do pacote para gerar resultados de simulação. O pacote oferece valores padrão para os atributos requeridos pelos construtores das diversas classes, de forma que é possível instanciar um objeto de forma simples, sem especificar valores para seus parâmetros. Alterações nos valores padrão podem ser feitas fornecendo explicitamente os valores desejados dos parâmetros. O código `LED_spectrum.py` gera o gráfico da Figura 37(a), um modelo simplificado de um LED. Nota-se que o valor padrão dos parâmetros da classe `LED` (comprimento de onda central, largura de banda e potência) foram utilizados.

```

1  """LED_spectrum.py"""
2  import gs
3
4  led = gs.LED()
5  led.plot_spectrum()

```

O código `OTDR_source.py` gera o gráfico da Figura 37(b), o espectro de emissão de um OTDR centrado no comprimento de onda de $1,55 \mu\text{m}$. A potência total e o formato do espectro são definidos internamente pelo código, a partir de exemplos experimentais.

```

1  """OTDR_source.py"""
2  import gs
3
4  central_wavelength = 1.55e-6
5  otdr = gs.OTDR(central_wavelength)
6  otdr.plot_spectrum()

```

O código `index_profile.py` cria uma fibra padrão e exibe o seu perfil de índice. O gráfico gerado é mostrado na Figura 38.


```

1  """index_profile.py"""
2  import gs
3
4  fiber = gs.Fiber()
5  fiber.plot_index_profile()

```

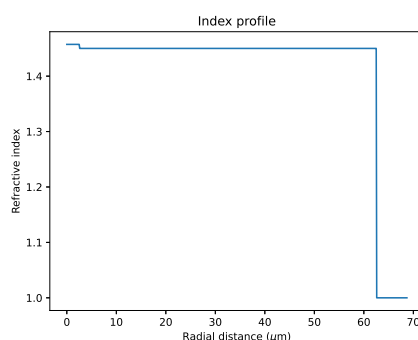
O código `lp_modes.py` cria um objeto `Fiber` padrão, calcula e imprime na tela os índices efetivos de modos LP especificados na linha 6 e gera o gráfico da intensidade de campo na seção reta da fibra para cada modo. Alguns desses gráficos já foram mostrados

Figura 37 – Simulação do espectro de fontes: (a) LED; (b) fonte do OTDR.



Fonte: elaborada pelo autor (2023).

Figura 38 – Perfil de índice de refração em uma fibra de índice degrau.



Fonte: elaborada pelo autor (2023).

nas Figuras 2(b) e 4. Nota-se que o objeto `fiber` é configurado para registrar os erros e os avisos oriundos do processamento interno do componente.

```

1  """lp_modes.py"""
2  import gs
3
4  l = [0, 1, 2, 3]
5  m = [1, 2, 3, 4, 5]
6  lp_modes = [(a, b) for a in l for b in m]
7
8  fiber = gs.LPG(log_level=gs.LogLevels.ERRORS | gs.LogLevels.WARNINGS)
9  lp_neff = fiber.get_lp_effective_indices(lp_modes)
10
11 print('LP modes effective indices:')
12 [print('\t', mode, '\t', f'{lp_neff[i]:.7f}') for i, mode in enumerate(lp_modes)]
13
14 [fiber_1.plot_lp_intensity(mode) for mode in lp_modes]

```


A saída do código `lp_modes.py` é apresentada abaixo.

```
LP modes effective indices:
```

```
(0, 1)      1.4515981
(0, 2)      1.4499456
(0, 3)      1.4497659
(0, 4)      1.4494655
(0, 5)      1.4490482
(1, 1)      1.4499220
(1, 2)      1.4497395
(1, 3)      1.4494541
(1, 4)      1.4490668
(1, 5)      1.4485781
(2, 1)      1.4498594
(2, 2)      1.4496222
(2, 3)      1.4492800
(2, 4)      1.4488325
(2, 5)      1.4482796
(3, 1)      1.4497829
(3, 2)      1.4494919
(3, 3)      1.4490965
(3, 4)      1.4485960
(3, 5)      1.4479899
```

```
Process finished with exit code 0
```

A Figura 8, que mostra os espectros de reflexão e de transmissão de uma FBG, foi criada com base no código `fbg_sim.py`:

```
1  """fbg_sim.py"""
2  import gs
3
4  modes = []
5  w_1 = 1.5485e-6
6  w_2 = 1.5518e-6
7  steps = 500
8
9  fbg = gs.FBG(length=1e-2, grating_apodization='gaussian', average_index_change=8e-4,
10             grating_period=0.53385e-6,
11             log_level=gs.LogLevels.ERRORS | gs.LogLevels.WARNINGS)
12
13  fbg.plot_lp_spectrum(modes, w_1, w_2, steps)
```

Já a Figura 10, que mostra o espectro de transmissão de uma LPG, foi criada com base no código `lpg_sim.py`:

```
1  """lpg_sim.py"""
2  import gs
3
```

```

4 lpg = gs.LPG(log_level=gs.LogLevels.ERRORS | gs.LogLevels.WARNINGS)
5 modes = [(0,2), (0,3), (0,4), (0,5), (0,6)]
6 w1 = 1.3e-6
7 w2 = 2e-6
8 steps = 300
9
10 lpg.plot_lp_spectrum(modes, w1, w2, steps)

```

Ainda em relação à simulação de grades, a Figura 11(a) foi criada com base no código `temperature_sensor.py` e a Figura 11(b), no código `index_sensor.py`.

```

1 """temperature_sensor.py"""
2 import gs
3 import numpy as np
4
5 spectrum_plot_modes = [(0, 5)]
6 start = 1.552e-6
7 stop = 1.56e-6
8 steps = 150
9
10 temperatures = [20, 40, 60, 80, 100]
11
12 source = gs.LED()
13 fiber = gs.Fiber()
14
15 wavelengths = np.linspace(start, stop, steps)
16
17 curves = []
18 for temperature in temperatures:
19     lpg = gs.LPG(temperature=temperature)
20     setup = gs.Setup([source, fiber, lpg])
21     spectrum = setup.get_spectrum_after(lpg, wavelengths, plot=False)
22     curves.append(spectrum.plot(draw=False))
23
24 curves[0].plot_along(curves[1:])

```

```

1 """index_sensor.py"""
2 import gs
3 import numpy as np
4
5 spectrum_plot_modes = [(0, 5)]
6 start = 1.55e-6
7 stop = 1.558e-6
8 steps = 150
9
10 indices = [1, 1.1, 1.2, 1.3, 1.4]
11
12 source = gs.LED()
13 fiber = gs.Fiber()

```

```

14
15 wavelengths = np.linspace(start, stop, steps)
16
17 curves = []
18 for index in indices:
19     lpg = gs.LPG(external_index=index)
20     setup = gs.Setup([source, fiber, lpg])
21     spectrum = setup.get_spectrum_after(lpg, wavelengths, plot=False)
22     curves.append(spectrum.plot(draw=False))
23
24 curves[0].plot_along(curves[1:])

```

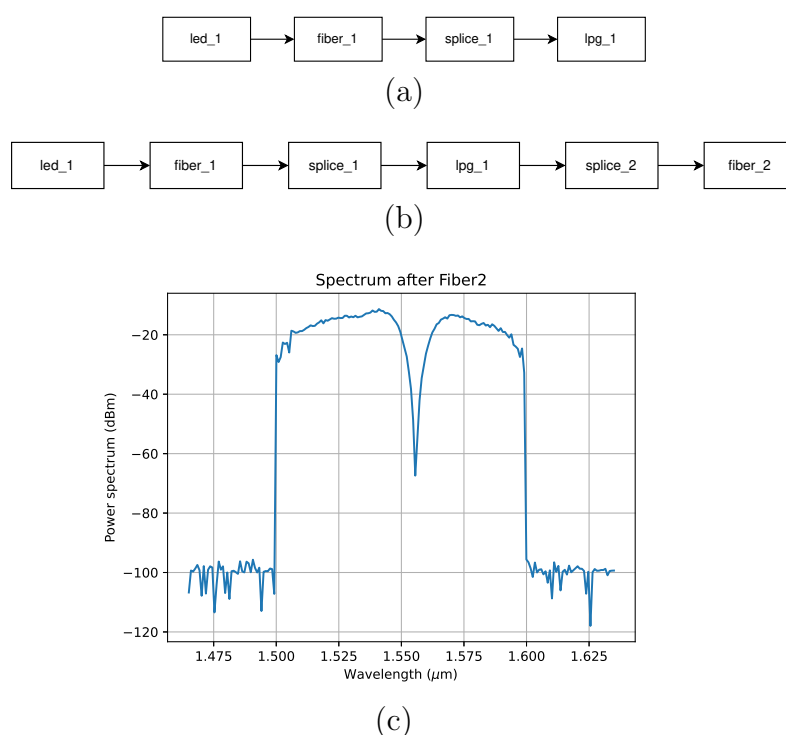
O código `basic_setup.py` simula uma montagem simples de componentes em cascata utilizando a classe `Setup` para fazer proveito da funcionalidade dos grafos. Os componentes são representados pelos nós do grafo, e as arestas representam as conexões entre componentes. Em sentido estrito, os grafos utilizados pelo *software* são grafos direcionados, ou dígrafos, que foram escolhidos porque podem representar convenientemente a direção de propagação da luz. Inicialmente, o código `basic_setup.py` cria quatro componentes e constrói um objeto da classe `Setup` para representar as conexões entre eles. Nota-se que `led_1` é inicializado com um valor de potência ajustado explicitamente. A Figura 39(a) mostra uma representação do diagrama da montagem. Em seguida, o código cria novos objetos e adiciona os novos componentes e as novas conexões ao `setup`. O novo diagrama é exibido na tela, conforme mostra a Figura 39(b). Por fim, o código calcula e mostra o espectro verificado na saída do componente `fiber_2`, após a propagação ao longo de todo o `setup`, conforme a Figura 39(c).

```

1  """basic_setup.py"""
2  import gs
3
4  # Inicializar componentes
5  led_1 = gs.LED(power=-7)
6  fiber_1 = gs.Fiber()
7  lpg_1 = gs.LPG(log_level=gs.LogLevels.ERRORS | gs.LogLevels.WARNINGS)
8  splice_1 = gs.Splice(fiber_1, lpg_1)
9
10 # Criar um setup simples a partir da lista de componentes
11 components = [led_1, fiber_1, splice_1, lpg_1]
12 setup = gs.Setup(components)
13 setup.show()
14
15 # Criar novos componentes, incluí-los no setup e configurar as conexões
16 fiber_2 = gs.Fiber()
17 splice_2 = gs.Splice(lpg_1, fiber_2)
18 setup.add_components([splice_2, fiber_2])
19 setup.add_connections([(lpg_1, splice_2), (splice_2, fiber_2)])
20 setup.show()
21

```

Figura 39 – Simulação de uma montagem simples: (a) diagrama da montagem com 4 componentes; (b) diagrama da montagem com 6 componentes; (c) espectro após `fiber_2`.



Fonte: elaborada pelo autor (2023).

```
22 # Calcular e mostrar o espectro óptico na saída de fiber_2
23 setup.get_spectrum_after(fiber_2, plot=True)
```

O código `coupler_setup.py` simula uma montagem um pouco mais complexa, contendo duas fontes, dois acopladores e duas saídas, além de grades e emendas. As bandas dos LEDs estão justapostas no espectro, com comprimentos de onda centrais em $1,50 \mu\text{m}$ e em $1,59 \mu\text{m}$, e larguras de banda de 50 nm (padrão da classe LED). O comprimento padrão dos objetos da classe `Fiber` é de 10 km . No entanto, o objeto `fiber_2` é instanciado com comprimento de 5 km , e `fiber_4`, com 2 km . O período da grade `lpg_1` é o padrão da classe LPG: $570 \mu\text{m}$. Já `lpg_2` tem um período menor, de $550 \mu\text{m}$, e `lpg_3` tem um período de $590 \mu\text{m}$, de forma que seus vales ressonantes estejam deslocados no espectro, em relação a `lpg_1`. Além disso, a grade `lpg_3` é mais fraca, ou seja, provoca uma alteração média no índice de refração do núcleo de $3,2 \times 10^{-4}$, menor que a das outras grades, que usam o padrão da classe: $3,6 \times 10^{-4}$. O diagrama da Figura 40(a) mostra a disposição geral dos componentes e as conexões entre eles. A Figura 40(b) mostra o espectro na saída do elemento `fiber_4`, em que é possível ver o vale ressonante da `lpg_1` em $1,556 \mu\text{m}$, além do vale ressonante da `lpg_2`, em $1,528 \mu\text{m}$. Ambos os vales se referem ao modo LP_{05} , e a profundidade dos vales é semelhante. A Figura 40(c) mostra o espectro na saída

do elemento `fiber_5`, em que também se pode ver o vale da `lpg_1`, além de dois vales introduzidos pela `lpg_3`: em 1,471 μm , referente ao modo LP_{04} , e em 1,577 μm , referente ao modo LP_{05} . Os vales introduzidos pela `lpg_3` são menos profundos, uma vez que essa grade é relativamente mais fraca.


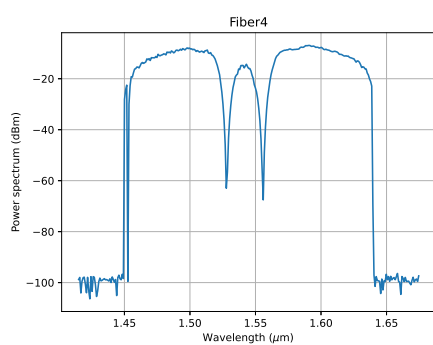

```

1  """coupler_setup.py"""
2  import gs
3
4  # Inicializar componentes
5  led_1 = gs.LED(central_wavelength=1.5e-6)
6  led_2 = gs.LED(central_wavelength=1.59e-6)
7  fiber_1 = gs.Fiber()
8  fiber_2 = gs.Fiber(length=5e3)
9  fiber_3 = gs.Fiber()
10 fiber_4 = gs.Fiber(length=2e3)
11 fiber_5 = gs.Fiber()
12 lpg_1 = gs.LPG()
13 lpg_2 = gs.LPG(grating_period=550e-6)
14 lpg_3 = gs.LPG(grating_period=590e-6, average_index_change=3.2e-4)
15 coupler_1 = gs.Coupler([fiber_1, fiber_2], [lpg_1])
16 coupler_2 = gs.Coupler([fiber_3], [lpg_2, lpg_3])
17 splice_1 = gs.Splice(lpg_1, fiber_3)
18 splice_2 = gs.Splice(lpg_2, fiber_4)
19 splice_3 = gs.Splice(lpg_3, fiber_5)
20
21 # Criar setup e adicionar as conexões
22 setup = gs.Setup()
23 setup.add_connections([(led_1, fiber_1), (fiber_1, coupler_1), (led_2, fiber_2),
24                       (fiber_2, coupler_1), (coupler_1, lpg_1), (lpg_1, splice_1),
25                       (splice_1, fiber_3), (fiber_3, coupler_2), (coupler_2, lpg_2),
26                       (lpg_2, splice_2), (splice_2, fiber_4), (coupler_2, lpg_3),
27                       (lpg_3, splice_3), (splice_3, fiber_5)])
28 setup.show()
29
30 # Propagar o sinal de todas as entradas; plotar todas as saídas
31 setup.propagate(plot=True)

```


O código `simple_trace.py` simula a medição de um traço de OTDR em uma seção de fibra de 5 km. Os componentes são inicializados e adicionados ao `setup`, e o traço é calculado e exibido, conforme mostra a Figura 41. Nota-se a presença de ruído no traço. A inclusão do ruído foi uma opção de projeto para dar verossimilhança à simulação dos traços. O sinal de ruído é gerado a cada execução da função que simula o traço e é projetado para ter a mesma densidade espectral de potência que o ruído encontrado nos traços obtidos experimentalmente durante a pesquisa para o Capítulo 5. Portanto, cada traço gerado pelo *software* tem uma componente aleatória distinta representando o ruído aditivo do traço, mas todos os sinais de ruído têm a mesma densidade espectral de potência, que corresponde àquela verificada experimentalmente.

Figura 40 – Simulação de uma montagem mais elaborada: (a) diagrama do sistema; (b) espectro após `fiber_4`; (c) espectro após `fiber_5`.



Fonte: elaborada pelo autor (2023).

Figura 41 – Simulação do traço de OTDR de uma fibra.




Fonte: elaborada pelo autor (2023).

```

1  """simple_trace.py"""
2  import gs
3
4  otdr = gs.OTDR()
5  fiber = gs.Fiber(length=5000)
6
7  setup = gs.Setup([otdr, fiber])
8  setup.trace(otdr)

```

Figura 42 – Simulação do traço de OTDR em fibra com emenda.



Fonte: elaborada pelo autor (2023).

O código `splice_trace.py` simula o traço de OTDR medido em uma seção de fibra com emenda. Há 5 km de fibra de cada lado da emenda. A Figura 42 mostra o traço simulado, em que é possível notar a queda decorrente da emenda no ponto a 5 km da fonte de luz.

```

1  """splice_trace.py"""
2  import gs
3
4  otdr_1 = gs.OTDR()
5  fiber_1 = gs.Fiber(length=5e3)
6  fiber_2 = gs.Fiber(length=5e3)
7  splice_1 = gs.Splice(fiber_1, fiber_2)
8
9  setup = gs.Setup([otdr_1, fiber_1, splice_1, fiber_2])
10 setup.trace(otdr_1)

```


O código `connector_trace.py` simula o traço de OTDR em uma montagem que consiste em: uma fibra de 5 km, um conector, uma fibra de 50 m, mais um conector e uma última fibra de 5 km. A Figura 43(a) mostra o traço resultante dessa simulação. Devido ao comprimento curto de `fiber_2`, o segundo conector fica sobreposto ao primeiro, devido à *deadzone* do OTDR, similarmente ao que ocorre nas montagens experimentais do Capítulo 5. Em seguida, o comprimento de `fiber_2` é alterado para 500 m. O traço resultante dessa nova simulação é mostrado na Figura 43(b). Nota-se que o segundo conector aparece de forma independente nesse novo traço.

```

1  """connector_trace.py"""
2  import gs
3
4  otdr_1 = gs.OTDR()
5  fiber_1 = gs.Fiber(length=5e3)

```

Figura 43 – Simulação do traço de OTDR em caminho com conectores:
(a) com sobreposição; (b) sem sobreposição.



Fonte: elaborada pelo autor (2023).

```

6 fiber_2 = gs.Fiber(length=50) # alterado em seguida para 500
7 fiber_3 = gs.Fiber(length=5e3)
8 connector_1 = gs.Connector(fiber_1, fiber_2)
9 connector_2 = gs.Connector(fiber_2, fiber_3)
10
11 setup = gs.Setup([otdr_1, fiber_1, connector_1, fiber_2, connector_2, fiber_3])
12 setup.trace(otdr_1)

```



O código `LPG_trace.py` simula a medição de um traço de OTDR em um sistema similar aos apresentados no Capítulo 5. Trata-se de duas fibras de 10 km (valor padrão do componente) intercaladas por uma seção de 2 m contendo uma LPG no ponto médio, utilizando conectores. Os componentes são inicializados e adicionados ao `setup`, cujo diagrama é mostrado na Figura 44(a). O traço é calculado e exibido, conforme mostra a Figura 44(b).

```

1 """LPG_trace.py"""
2 import gs
3
4 otdr_1 = gs.OTDR()
5
6 fiber_1 = gs.Fiber()
7 fiber_2 = gs.Fiber(length=1)
8 fiber_3 = gs.Fiber(length=1)
9 fiber_4 = gs.Fiber()
10
11 lpg_1 = gs.LPG()
12
13 connector_1 = gs.Connector(fiber_1, fiber_2)
14 connector_2 = gs.Connector(fiber_3, fiber_4)
15

```


Figura 44 – Simulação do traço de OTDR em montagem com LPG: (a) diagrama do sistema; (b) traço resultante.



Fonte: elaborada pelo autor (2023).

```

16 setup = gs.Setup([otdr_1, fiber_1, connector_1, fiber_2, lpg_1, fiber_3, connector_2,
17                    fiber_4])
18 setup.show()
19
20 setup.trace(otdr_1)

```

O código `cascade_trace.py` ilustra a simulação de uma montagem com três LPGs em cascata. O diagrama do sistema se encontra na Figura 45(a). Cada seção de fibra utilizada tem 5 km. Na Figura 45(b), que mostra o resultado da simulação, é possível observar o efeito das LPGs nos pontos distantes 5 km, 10 km e 15 km da fonte de luz. Nesta simulação, as LPGs são idênticas, no entanto, as quedas provocadas por elas são progressivamente menores. Isso se deve ao fato de que, como cada LPG insere uma perda na região espectral da sua ressonância, o nível de potência ao redor do comprimento de onda ressonante se aproxima do nível de ruído e sofre saturação, como se pode ver na Figura 45(c), que mostra o espectro calculado na saída de cada LPG.

```

1  """cascade_trace.py"""
2  import gs
3
4  otdr_1 = gs.OTDR()
5  fiber_1 = gs.Fiber(length=5e3)
6  lpg_1 = gs.LPG()
7  connector_1 = gs.Connector(fiber_1, lpg_1)
8  fiber_2 = gs.Fiber(length=5e3)

```

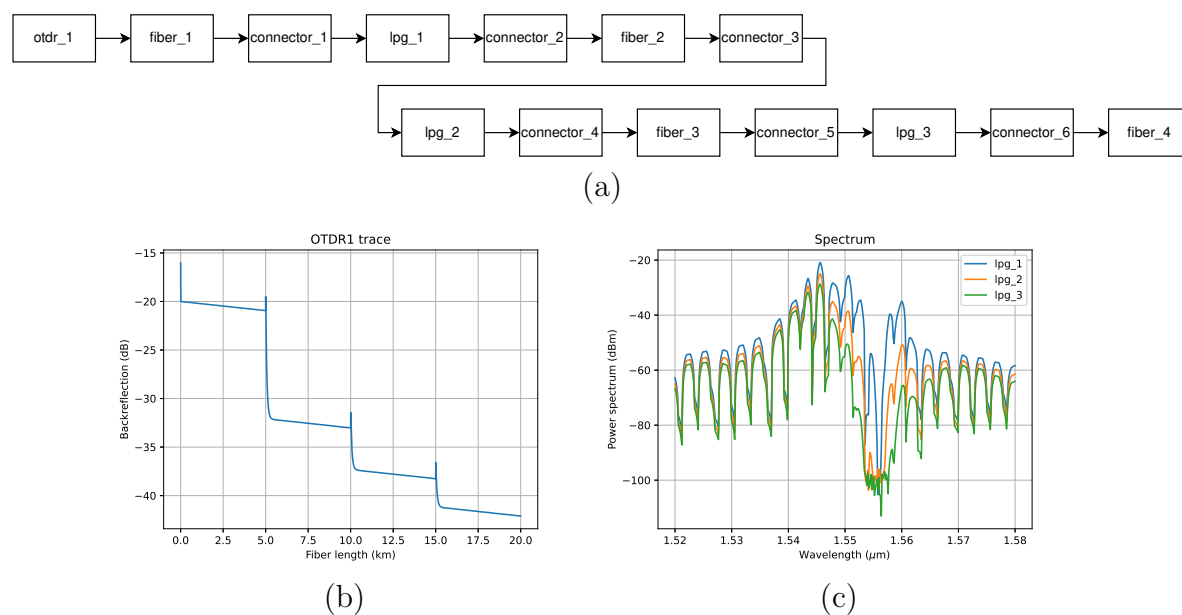
```

9 connector_2 = gs.Connector(lpg_1, fiber_2)
10 lpg_2 = gs.LPG()
11 connector_3 = gs.Connector(fiber_2, lpg_2)
12 fiber_3 = gs.Fiber(length=5e3)
13 connector_4 = gs.Connector(lpg_2, fiber_3)
14 lpg_3 = gs.LPG()
15 connector_5 = gs.Connector(fiber_3, lpg_3)
16 fiber_4 = gs.Fiber(length=5e3)
17 connector_6 = gs.Connector(lpg_3, fiber_4)
18
19 setup = gs.Setup([otdr, fiber_1, connector_1, lpg_1, connector_2, fiber_2,
20                 connector_3, lpg_2, connector_4, fiber_3, connector_5, lpg_3,
21                 connector_6, fiber_4])
22 setup.show()
23
24 setup.trace(otdr_1)
25
26 wl = np.linspace(1.52e-6, 1.58e-6, 400)
27 spectrum_1 = setup.get_spectrum_after(lpg_1, wavelengths=wl)
28 spectrum_2 = setup.get_spectrum_after(lpg_2, wavelengths=wl)
29 spectrum_3 = setup.get_spectrum_after(lpg_3, wavelengths=wl)
30
31 curve_1 = spectrum_1.plot(draw=False)
32 curve_1.legend_entry = 'lpg_1'
33 curve_2 = spectrum_2.plot(draw=False)
34 curve_2.legend_entry = 'lpg_2'
35 curve_3 = spectrum_3.plot(draw=False)
36 curve_3.legend_entry = 'lpg_3'
37
38 curve_1.plot_along([curve_2, curve_3])

```

O código `sensor_trace.py` ilustra a simulação dos traços de OTDR de um sensor de deformação baseado em LPG. O diagrama do sistema é o mesmo encontrado na Figura 44(a). As fibras utilizadas tem 10 km. A LPG encontra-se no ponto médio de uma pequena fibra de 2 m. Na Figura 46(a), que mostra o resultado da simulação, é possível observar o efeito sensor da LPG, por meio das diferenças nos traços nas proximidades do ponto a 10 km da fonte. Os gráficos menores mostram em detalhes duas janelas de interesse nas proximidades do sensor. Devido à aleatoriedade que provoca pequenas diferenças entre execuções diferentes do código, é necessário algum ajuste manual dos eixos nos gráficos. Os quatro descritores apresentados na Seção 5.5 foram calculados para esses traços simulados nas duas janelas evidenciadas. Os resultados estão na Figura 46(b), para a primeira janela, que consiste no intervalo de distâncias entre 9,997 km e 10,096 km, e na Figura 46(c), para a segunda janela, ou seja, para o intervalo entre 10,301 km e 10,499 km. Nota-se que os quatro descritores são bons regressores para a deformação na primeira janela, devido à alta correlação, enquanto apenas o descritor de potência média se mantém como um bom regressor na segunda janela.

Figura 45 – Simulação de um traço de OTDR de LPGs em cascata: (a) diagrama do sistema; (b) traço resultante; (c) espectros nas saídas das LPGs.



Fonte: elaborada pelo autor (2023).

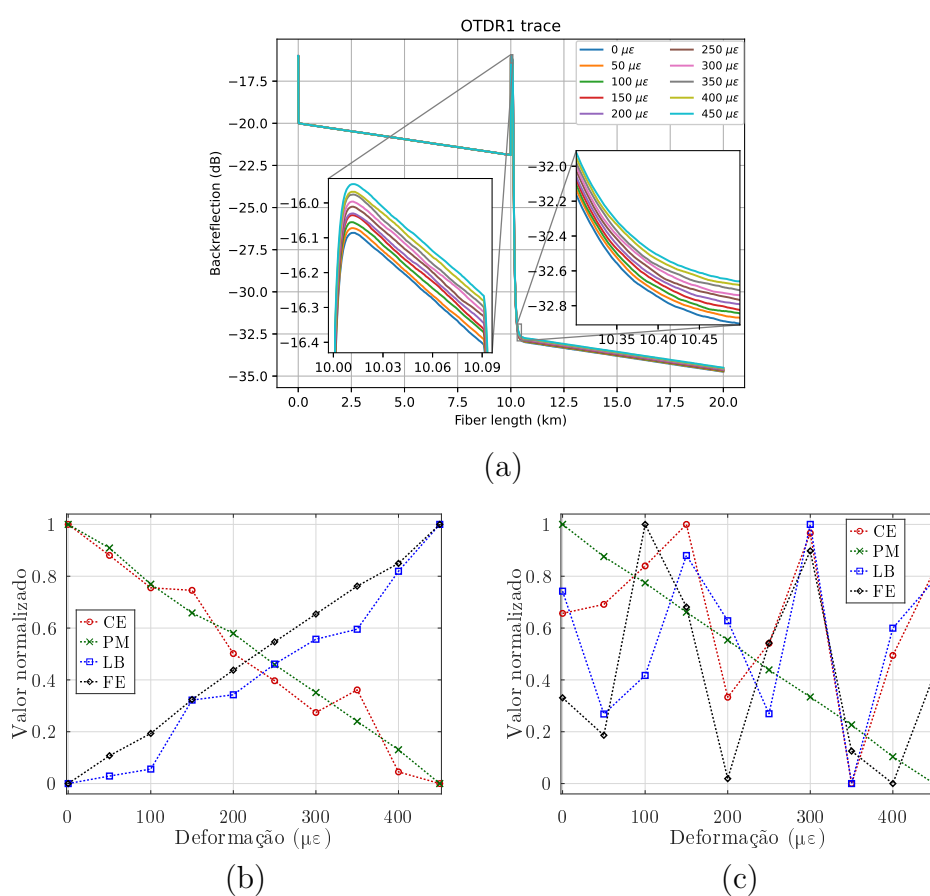
```

1  """sensor_trace.py"""
2  import gs
3  import matplotlib.pyplot as plt
4  import numpy as np
5
6  otdr_1 = gs.OTDR()
7  fiber_1 = gs.Fiber()
8  fiber_2 = gs.Fiber(length=1)
9  connector_1 = gs.Connector(fiber_1, fiber_2)
10 fiber_3 = gs.Fiber(length=1)
11 fiber_4 = gs.Fiber()
12 connector_2 = gs.Connector(fiber_3, fiber_4)
13
14 traces = []
15 for strain in np.arange(0, 500e-6, 50e-6):
16     lpg = gs.LPG(strain=strain)
17     setup = gs.Setup([otdr_1, fiber_1, connector_1, fiber_2, lpg, fiber_3,
18                     connector_2, fiber_4])
19     trace, _ = setup.trace(otdr_1, plot=False)
20     trace.legend_entry = str(round(strain*1e6)) + '  $\mu\epsilon$ '
21     traces.append(trace)
22
23 fig, ax1 = plt.subplots()
24 for i in range(len(traces)):
25     ax1.plot(traces[i].x_values, traces[i].y_values, traces[i].fmt,
26            label=traces[i].legend_entry)
27 ax1.set_xlabel(traces[0].x_label)
28 ax1.set_ylabel(traces[0].y_label)

```

```
29 ax1.set_title(traces[0].title)
30 ax1.grid('minor')
31 ax1.legend()
32
33 ax2 = ax1.inset_axes([0.11, 0.1, 0.35, 0.5])
34 for i in range(len(traces)):
35     ax2.plot(traces[i].x_values, traces[i].y_values, traces[i].fmt,
36             label=traces[i].legend_entry)
37 ax2.set_xlim(9.997, 10.096)
38 ax2.set_ylim(-16.43, -15.93)
39
40 ax3 = ax1.inset_axes([0.64, 0.18, 0.35, 0.5])
41 for i in range(len(traces)):
42     ax3.plot(traces[i].x_values, traces[i].y_values, traces[i].fmt,
43            label=traces[i].legend_entry)
44 ax3.set_xlim(10.301, 10.499)
45 ax3.set_ylim(-32.91, -31.91)
46
47 plt.legend(bbox_to_anchor=(1.01, 1.01), ncol=2, fontsize='small')
48
49 ax1.indicate_inset_zoom(ax2)
50 ax1.indicate_inset_zoom(ax3)
51
52 plt.show()
```

Figura 46 – Simulação dos traços de OTDR de um sensor LPG: (a) traços simulados; (b) descritores calculados na primeira janela; (c) descritores calculados na segunda janela.



Fonte: elaborada pelo autor (2023).