

Universidade Federal do Espírito Santo
Centro Tecnológico
Programa de Pós-Graduação em Engenharia Elétrica

Ingrid Andrade Reis

Extração de Características do Padrão *Speckle* para
Classificação de Perturbações em Fibra Óptica

Vitória

2021

Ingrid Andrade Reis

**Extração de Características do Padrão *Speckle* para
Classificação de Perturbações em Fibra Óptica**

Universidade Federal do Espírito Santo

Centro Tecnológico

Programa de Pós-Graduação em Engenharia Elétrica

Orientador: Prof. Dr. Evandro Ottoni Teatini Salles

Vitória

2021

Ingrid Andrade Reis

Extração de Características do Padrão *Speckle* para Classificação de Perturbações em Fibra Óptica/ Ingrid Andrade Reis. – Vitória, 2021-

70 p. : il. (algumas color.) ; 30 cm.

Orientador: Prof. Dr. Evandro Ottoni Teatini Salles

Dissertação de Mestrado – Universidade Federal do Espírito Santo
Centro Tecnológico
Programa de Pós-Graduação em Engenharia Elétrica, 2021.

1.

Ingrid Andrade Reis

Extração de Características do Padrão *Speckle* para Classificação de Perturbações em Fibra Óptica

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do Grau de Mestre em Engenharia Elétrica.

Trabalho aprovado. Vitória, 22 de outubro de 2021:

Prof. Dr. Evandro Ottoni Teatini Salles
Orientador

Profa. Dra. Maria José Pontes
Membro Interno

Profa. Dra. Shirley Peroni Neves Cani
Membro Externo

Vitória
2021

Dedico este trabalho a meus pais

Agradecimentos

Aos meus pais, Santa e José Agostinho, pelo amor incondicional todos esses anos, exemplificado no suporte emocional e material e nos exemplos que me proporcionaram. A minha irmã Andrezza, por ser desde que nasceu a companhia que eu precisava quando sequer sabia.

Ao Bruno, por me mostrar a cada dia uma vida a dois leve, regada de respeito, companheirismo, compreensão e muito carinho. Você sempre me inspira e me faz sentir mais forte. À família Lima Zattoni, por todo acolhimento e torcida.

A minhas amigas e meus amigos, pelo apoio em tantos momentos difíceis e por dividir tantas alegrias, de perto ou de longe. Em especial, Amanda Lima e Marcus Vinícius Lyra, que neste período me presentearam com ideias, desabafos e conversas tão significantes.

Às minhas amigas do Ifes, por serem meu porto seguro muitas vezes e continuarem presentes. A Cristina, Thais, Marcello e Lucas por todas as trocas e me inspirarem a ser sempre questionadora e lutar pelo que acredito.

A tantos outros amigos cujos nomes não cito aqui mas que fazem parte de mim, pelos encontros, risadas e aprendizados. Aos colegas de laboratório e de pós-graduação que mesmo com pouca proximidade foram muito importantes nessa caminhada.

Ao Prof. Evandro, por ter sido um mentor tão presente, por sua paciência e por acreditar em meu trabalho. Aos Professores Anselmo, Camilo e Arnaldo, pelo suporte durante a pesquisa.

Por fim, a todas as pessoas, instituições e iniciativas que possibilitaram que essa pesquisa se tornasse realidade e que acreditam numa Educação Pública gratuita e de qualidade para todos.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

"Grande coisa é haver recebido do céu uma partícula da sabedoria, o dom de achar as relações das coisas, a faculdade de as comparar e o talento de concluir!"

Machado de Assis

Resumo

Em fibras óticas multimodo, um padrão de manchas, ou specklegrama, aparece na saída das fibras quando iluminadas por uma luz coerente. Neste caso, o fenômeno responsável pela geração do specklegrama é a interferência entre os diferentes modos propagados na fibra. Tendo em vista a sensibilidade desse padrão a mudanças na fibra óptica, são desenvolvidos sensores capazes de detectar diferentes tipos de perturbações, como vibrações, deformações e deslocamentos. Trabalhos anteriores mostram que há correlação entre a distância em que uma perturbação é gerada em uma fibra óptica e as mudanças que ocorrem em seu padrão *speckle*. Devido a sua aparência granular, é proposto neste trabalho um sistema de classificação de imagens do padrão *speckle* utilizando redes neurais baseado em características extraídas por descritores de textura, de forma a avaliar se tais aspectos também conseguem representar o specklegrama. Para isso, utilizou-se dois bancos de imagens obtidos em experimentos com fibras óticas poliméricas e, para cada um deles, comparou-se os resultados de acurácia para diferentes conjuntos de características. Elas foram extraídas por dois extratores de textura, o *Local Binary Pattern* (LBP) e a *Gray Level Co-occurrence Matrix* (GLCM). Os resultados mostraram que foi possível classificar a localização das perturbações, especialmente ao utilizar o operador LBP uniforme e invariante a rotação aplicado às imagens quando divididas em 25 blocos.

Palavras-chave: Extração de características, Análise de Textura, *Speckle*, LBP, GLCM, Redes Neurais

Abstract

In multimode optical fibers, a speckle pattern, or specklegram, appears at the output of the fiber when illuminated by coherent light. In this case, the phenomenon responsible for generating the specklegram is the interference between the different modes propagating in the fiber. Considering the sensitivity of this pattern to changes in the optical fiber, sensors capable of detecting different types of disturbances, such as vibrations, deformations and displacements, have been developed. Previous works show that there is a correlation between the distance at which a disturbance is generated in an optical fiber and the changes that occur in its *speckle* pattern. Due to its granular appearance, it is proposed in this work a speckle pattern image classification system using neural networks based on features extracted by texture descriptors, in order to assess whether such aspects can also represent the specklegram. For this, two datasets containing images obtained by experiments with polymeric optical fibers were used and, for each one, the results of accuracy for different sets of characteristics were compared. They were extracted by two texture extractors, the *Local Binary Pattern* (LBP) and the *Gray Level Co-occurrence Matrix* (GLCM). The results showed that it was possible to classify the location of the perturbations, especially when using the uniform and rotation-invariant LBP operator applied to the images when divided into 25 blocks.

Keywords: Feature Extraction, Texture Analysis, Speckle, LBP, GLCM, Neural Network

Lista de ilustrações

Figura 1 – Esquemático do sensor a fibra óptica baseado em specklegrama.	27
Figura 2 – Padrão <i>speckle</i>	28
Figura 3 – Comparação do padrão <i>speckle</i> antes e depois de uma perturbação.	28
Figura 4 – Ilustração do processo de extração do LBP para um pixel.	34
Figura 5 – Exemplos de combinações (P, R) para cálculo do LBP.	35
Figura 6 – Padrões uniformes e representações de texturas primitivas.	35
Figura 7 – Mapeamento do padrões uniformes invariantes a rotação referentes a 8 pontos de amostragem.	37
Figura 8 – Extração de características de textura artificial original e rotacionada utilizando LBP^{u2} e LBP^{riu2}	37
Figura 9 – Orientações referentes aos ângulos para a geração da Matriz de Coocorrência.	38
Figura 10 – Matrizes de coocorrência geradas para a imagem exemplo.	40
Figura 11 – Exemplos de descritores estatísticos extraídos da matriz de coocorrência.	42
Figura 12 – Modelo de Neurônio de McCulloch e Pitts.	43
Figura 13 – Funções de Ativação.	43
Figura 14 – Ilustração de Rede Neural Perceptron Multi-Camada.	44
Figura 15 – Fluxograma do pré-processamento das imagens.	53
Figura 16 – Exemplos de amostras do padrão <i>speckle</i> do banco de imagens cedido.	54
Figura 17 – Acurácia das classificações de padrões <i>speckle</i> do banco de imagens cedido com extração de características.	56
Figura 18 – Matriz de confusão resultante da classificação das imagens do grupo G1 com 250 características extraídas pelo operador LBP.	57
Figura 19 – Exemplos de amostras do padrão <i>speckle</i> em RGB (esquerda) e em tons de cinza (direita) do banco de imagens inédito.	59
Figura 20 – Acurácia das classificações de padrões <i>speckle</i> do banco de imagens inédito.	60
Figura 21 – Exemplo de recorte realizado.	61

Lista de quadros

Quadro 1 – Parâmetros da rede neural artificial para classificação.	52
---	----

Lista de tabelas

Tabela 1 – Detalhamento dos descritores avaliados	51
Tabela 2 – Quantidade e dimensão das amostras do banco de imagens cedido. . . .	54
Tabela 3 – Acurácia das classificações de padrões <i>speckle</i> do banco de imagens cedido sem extração de características.	55
Tabela 4 – Quantidade e dimensão das amostras do banco de imagens inédito. . .	58
Tabela 5 – Matriz de Confusão resultante da classificação com características extraídas pelo descritor G.	61
Tabela 6 – Comparação em relação a acurácia entre imagens integrais e recortadas.	62
Tabela 7 – Comparação em relação a tempo para treinamento e teste da rede neural entre imagens integrais e recortadas, em segundos.	62
Tabela 8 – Comparação em relação a tempo de leitura e extração de características entre imagens integrais e recortadas, em segundos.	62

Lista de abreviaturas e siglas

CCD	(<i>Charge Couple Device</i>) Dispositivo de Carga Acoplada
CG	(<i>Conjugate Gradient</i>) Gradiente Conjugado
FSS	(<i>Fiber Specklegram Sensors</i>) Sensores de fibra óptica baseado em specklegrama
GLCM	(<i>Gray Level Coocurrence Matrix</i>) Matriz de Coocorrência de Níveis de Cinza
LABTEL	Laboratório de Telecomunicações da UFES
Laser	(<i>Light Amplification by Stimulated Emission of Radiation</i>) Amplificação de Luz por Emissão Estimulada de Radiação
LBP	(<i>Local Binary Pattern</i>) Padrão Binário Local
MATLAB	<i>MATrix LABoratory</i>
MLP	(<i>Multi-layer Perceptron</i>) Perceptron Multi-Camada
MMF	(<i>Multimode Fiber</i>) Fibra Multimodo
MSE	(<i>Mean Squared Error</i>) Erro quadrático médio
NIPC	(<i>Normalized Inner Product Coefficient</i>) Coeficiente de Produto Interno Normalizado
POF	(<i>Polymer Optical Fiber</i>) Fibra Óptica Plástica
RNA	Redes Neurais Artificiais
SCG	(<i>Scaled Conjugate Gradient</i>) Gradiente Conjugado Escalonado
SVM	(<i>Support Vector Machine</i>) Máquina Vetor de Suporte
UFES	Universidade Federal do Espírito Santo

Sumário

1	INTRODUÇÃO	25
1.1	O Fenômeno <i>Speckle</i>	25
1.2	Padrão <i>Speckle</i> em Sensores a Fibra Óptica	27
1.3	Hipótese e Objetivos do Trabalho	30
1.4	Estrutura da Dissertação	31
2	REFERENCIAIS TEÓRICOS	33
2.1	Extração de Características baseada em Textura	33
2.1.1	LBP	34
2.1.2	GLCM	36
2.2	Redes Neurais Artificiais	42
2.2.1	Algoritmos de Treinamento	45
2.2.1.1	<i>Backpropagation</i>	45
2.2.1.2	Gradiente Conjugado Escalonado	46
2.2.2	Capacidade de Generalização	49
3	TESTES EXPERIMENTAIS	51
3.1	Banco de Imagens Cedido	53
3.2	Banco de Imagens Inédito	57
4	CONCLUSÕES E TRABALHOS FUTUROS	65
	REFERÊNCIAS	67

1 Introdução

O uso de métodos que utilizam textura tem sido crescente para soluções de desafios em diversas áreas. Problemas como identificação e reconhecimento facial, controle de qualidade, sensoriamento remoto, diagnóstico médico por imagem e microscopia são alguns exemplos nos quais técnicas de classificação de textura podem ser aplicadas. Em cada uma delas, um sistema de visão computacional obtém informações relevantes de uma imagem capazes de diferenciar entre objetos de interesse distintos.

A classificação de imagens depende dos atributos utilizados para a representação e é buscado estabelecer quais deles potencializam o processo de análise. Dentre esses atributos estão, além da forma do objeto e a sua cor, a textura (SCHIEZARO, 2014). Aplicações de classificação que utilizam aspectos texturais encontram potencial proveito no desenvolvimento de novos sistemas de sensoriamento por fibra óptica baseados no padrão *speckle*.

O padrão *speckle* é caracterizado por sua aparência granular e é presente em diversas áreas, do desenvolvimento de técnicas de amostragem compressiva (LIU et al., 2020) a análise de imagens médicas (BASAK; MANJUNATHA; DUTTA, 2012). O emprego de algoritmos de aprendizado de máquina para classificação de imagens do padrão *speckle* é presente em diversos estudos (EFENDIOGLU; YILDIRIM; TOKER, 2011), (EFENDIOGLU et al., 2012), (FUJIWARA; WU; SUZUKI, 2012), (BORHANI et al., 2018), (RAZMYAR; MOSTAFAVI, 2021). No contexto de sensores a fibra óptica, Fontana (2018) apresenta uma prova de conceito na qual é mostrado que um sistema que utiliza todos os pixels de uma imagem é capaz de reconhecer onde uma perturbação ocorre em uma fibra.

Nesse contexto, o desenvolvimento de outros sistemas baseados em tal conceito torna-se promissor. Neste trabalho é proposto avaliar a efetividade da análise com base na textura do padrão *speckle* para sensoriamento de perturbações em fibra óptica.

1.1 O Fenômeno *Speckle*

Em 1960, a primeira operação utilizando um laser HeNe revelou que, ao incidir tal luz coerente sobre um objeto com rugosidade da ordem do comprimento de onda da fonte, era possível observar um padrão irregular de aparência granular. A este fenômeno deu-se o nome de *laser speckle*. O laser (*Light Amplification by Stimulated Emission of Radiation*) é um dispositivo capaz de produzir radiação eletromagnética monocromática e coerente, ou seja, o comprimento da onda é bem definido e as frentes de onda não são defasadas

(GOULD, 1959).

A maioria dos materiais possuem superfícies com rugosidade na escala de um comprimento de onda óptico ($\lambda = 5 \times 10^{-7}\text{m}$) e quando uma luz monocromática é refletida por uma superfície, a onda óptica resultante consiste em várias componentes coerentes, denominados *wavelets*, cada uma derivada de um elemento microscópico diferente. Ao padrão granular gerado pela interferência das *wavelets* é dado o nome de *speckle* (GOODMAN, 1975).

Considerado um ruído óptico indesejado durante os primeiros anos do uso do laser como ferramenta instrumental, o *speckle* tornou-se, anos mais tarde, um fenômeno importante para determinação de ampla variedade de parâmetros físicos por meio de medidas interferométricas (ENNOS, 1975). O padrão *speckle* possibilitou caracterizar o meio sem a necessidade de perturbá-lo para realizar essas medições.

Os padrões *speckle* (ou specklegramas), também são obtidos na saída de uma fibra óptica multimodo (*multimode fiber* - MMF), como proposto para fibras de sílica (SPILLMAN et al., 1989) e, posteriormente, para fibras ópticas plásticas (*Polymer Optical Fiber* - POF) (RODRIGUEZ-COBO et al., 2012). Quando uma luz emitida por uma fonte coerente é guiada através de uma MMF, um padrão surge na face da extremidade da fibra. Esse specklegrama é produzido em decorrência da interferência entre os diversos modos de propagação, correspondentes aos diferentes caminhos ópticos pelos quais passam os feixes de luz. De fato, este é um efeito indesejável em sistemas de comunicação óptica, porém ele contém informações do estado espacial da fibra óptica, que podem ser utilizadas em aplicações metrológicas.

Sendo o specklegrama um padrão de interferências dos diversos modos que se propagam numa fibra óptica, a quantidade de *speckles* é aproximadamente igual ao número de modos M , e por isso é importante estimar a quantidade deles. O número de modos propagados em uma fibra depende da Frequência Normalizada (V), expressa por:

$$V = \frac{2\pi a}{\lambda} (n_1^2 - n_2^2)^{\frac{1}{2}} \quad (1.1)$$

em que n_1 e n_2 são, respectivamente, os índices de refração do núcleo e do revestimento da fibra óptica, λ é o comprimento de onda da luz incidente e a é o diâmetro do núcleo.

Levando em conta a forma como o índice varia de acordo com o aumento da distância radial no eixo óptico da fibra, pode-se classificá-la como “perfil de índice degrau” (do inglês, *Step Index Fiber*) e “perfil de índice gradual” (do inglês, *Graded Index Fiber*). Para fibras de índice degrau, o número de modos (M) é calculado por:

$$M = \frac{V^2}{2} \quad (1.2)$$

e para fibras de perfil de índice gradual:

$$M = \frac{V^2}{4}. \quad (1.3)$$

Pelas relações apresentadas nas Equações 1.1, 1.2 e 1.3, nota-se que uma fibra óptica cujo diâmetro é grande ou que é incidida por uma luz com menor comprimento de onda, maior é o número de modos nela propagados e, conseqüentemente, maior o número de *speckles*. Ademais, uma fibra de índice degrau exibe mais *speckles* porque suporta o dobro de modos em relação a fibra de índice gradual.

1.2 Padrão Speckle em Sensores a Fibra Óptica

O desenvolvimento de sensores baseados em fibra óptica é um importante aspecto para o avanço em diversas tecnologias. Por isso, em sensores com interrogação por padrões *speckle*, a criação de técnicas de processamento desses padrões que possibilitem melhor caracterização do estado da fibra é de interesse científico.

Sensores ópticos baseados em specklegramas de fibra óptica (*Fiber Specklegram Sensors* - FSSs) são sensores que podem ser implementados com um sistema de interrogação simples e de baixo custo, utilizando apenas um laser e uma câmera (RODRIGUEZ-COBO; LOMER; LOPEZ-HIGUERA, 2014), como representado na Figura 1. No esquemático, uma luz coerente é propagada através da fibra óptica e depois projetada em um anteparo e capturada pela câmera.

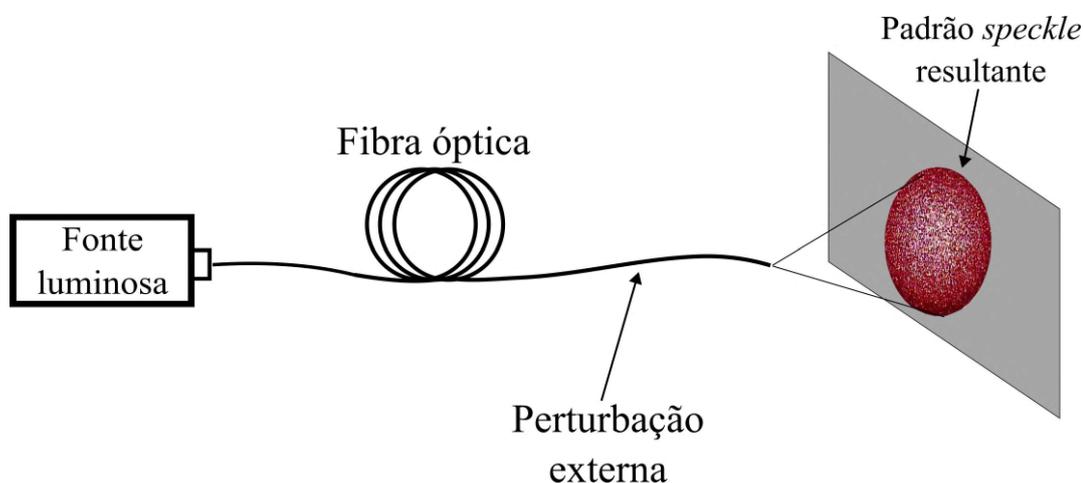


Figura 1 – Esquemático do sensor a fibra óptica baseado em specklegrama.

As fotografias, ou *frames* de um vídeo, capturadas pela câmera que compõe o sensor representam o padrão *speckle* e com base nele o FSS é capaz de caracterizar uma mudança no conteúdo espacial do specklegrama após a aplicação de uma perturbação externa na fibra.

Na Figura 2 é mostrada o aspecto total de uma fotografia do padrão *speckle* e na Figura 3 é exemplificada essa mudança no padrão antes, em (a), e depois, em (b), de se aplicar uma curvatura sobre a fibra.

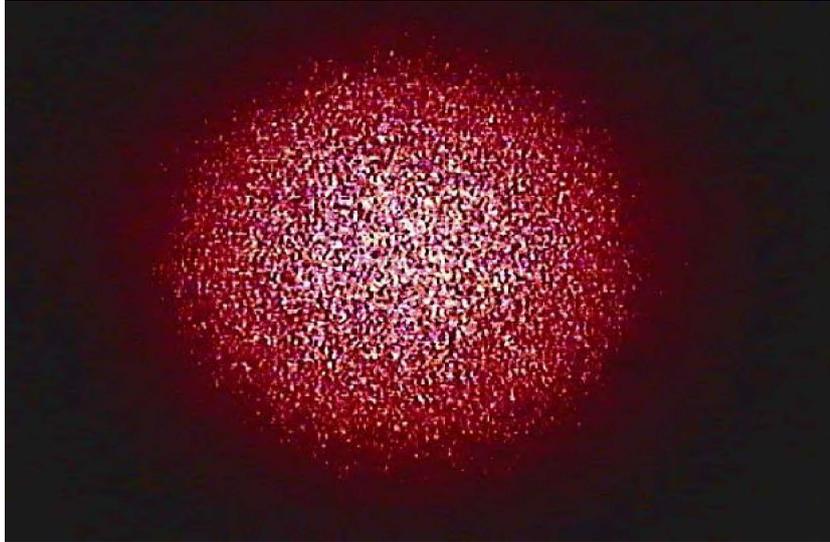


Figura 2 – Padrão *speckle*.

Fonte: (EFENDIOGLU, 2017).

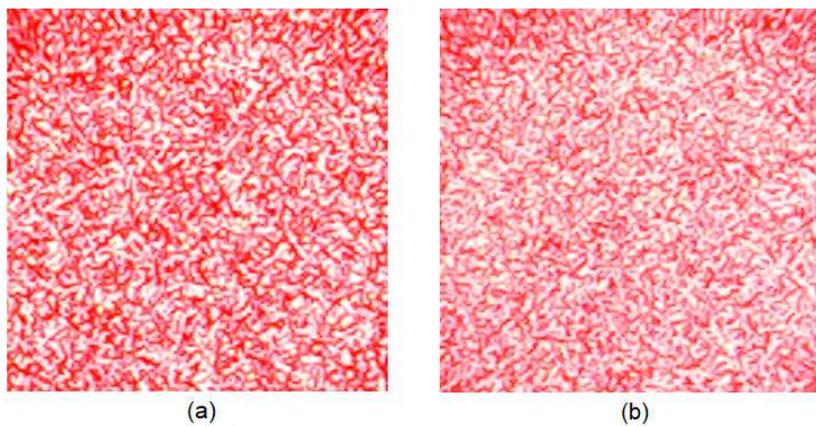


Figura 3 – Comparação do padrão *speckle* antes e depois de uma perturbação.

Tal modificação do padrão *speckle* é justificada pelo fato de a perturbação aplicada na fibra provocar uma redistribuição nos modos, podendo assim apresentar um rico caso de textura para o processamento de imagem (HAVLICEK; HARDING; BOVIK, 2000). É sabido que, diferentemente da noção comum, a propagação da luz em fibras ópticas multimodo tem comportamento determinístico (PLÖSCHNER; TYC; ČIŽMÁR, 2015). Dessa forma, o estudo dos sinais de luz coerentes representados na forma de padrões manchados (*speckle*) aparentemente aleatórios, se faz significativo.

Assumindo que uma luz coerente é usada em uma fibra óptica multimodo, inicialmente não perturbada, a teoria do princípio de operação dos sensores de specklegrama de fibra óptica pode ser obtida a partir da mudança de intensidade espacial (YU, 1993).

O campo iluminado na saída da fibra em uma posição (x, y) do padrão *speckle* pode ser considerado um campo complexo expresso por:

$$u_{0m}(x, y) = a_{0m}(x, y) \exp [j\phi_{0m}(x, y)], \quad (1.4)$$

no qual a_{0m} e ϕ_{0m} são as distribuições de amplitude e fase relacionadas ao m -ésimo modo e $j = \sqrt{-1}$. Assim, a distribuição total da saída é:

$$U_0(x, y) = \sum_{m=1}^M u_{0m}(x, y) = \sum_{m=1}^M a_{0m}(x, y) \exp [j\phi_{0m}(x, y)]. \quad (1.5)$$

Dessa forma, a intensidade do specklegrama medido por uma câmera CCD (*Charge Couple Device*) é calculada como:

$$\begin{aligned} I_0(x, y) &= \left| \sum_{m=1}^M u_{0m}(x, y) \right|^2 \\ &= \sum_{n=1}^M \sum_{m=1}^M a_{0m}(x, y) a_{0n}(x, y) \times \exp \{j [\phi_{0m}(x, y) - \phi_{0n}(x, y)]\}. \end{aligned} \quad (1.6)$$

Se uma fibra óptica é sujeita a perturbações físicas, as mudanças na propagação dos modos são refletidas no padrão *speckle* e o campo na saída se torna:

$$\begin{aligned} U(x, y) &= \sum_{m=1}^M u_m(x, y) \\ &= \sum_{m=1}^M [a_{0m}(x, y) + \Delta a_m(x, y)] \\ &\quad \times \exp \{j [\phi_{0m}(x, y) + \Delta \phi_m(x, y)]\}, \end{aligned} \quad (1.7)$$

e a distribuição de intensidade se torna:

$$\begin{aligned} I(x, y) &= \left| \sum_{m=1}^M u_m(x, y) \right|^2 = \sum_{n=1}^M \sum_{m=1}^M [a_{0m}(x, y) + \Delta a_m(x, y)] \\ &\quad \times [a_{0n}(x, y) + \Delta a_n(x, y)] \\ &\quad \times \exp \{j [\phi_{0m}(x, y) - \phi_{0n}(x, y) + \Delta \phi_m - \Delta \phi_n]\}, \end{aligned} \quad (1.8)$$

em que Δa_n e $\Delta \phi_m$ são as variações de amplitude e fase correspondentes, respectivamente, causadas pelas mudanças no estado da fibra.

Uma abordagem para o processamento de specklegrama é a apresentada por (YU et al., 1993), baseada no produto interno das intensidades dos padrões *speckle*. Nela, toma-se os padrões de intensidade de manchas antes e durante a perturbação da fibra e calcula-se o produto interno entre os dois padrões. Tendo em vista que o padrão *speckle* é causado pela mudança dos modos da fibra, a intensidade do produto interno é sensível às alterações na situação da fibra (deformações, vibrações, temperatura, por exemplo) (FONTANA, 2018). O valor normalizado desse parâmetro (NIPC - *Normalized Inner Product Coefficient*) é calculado por:

$$NIPC = \frac{\iint g_0(x, y)g(x, y)dxdy}{[\iint g_0^2dxdy \iint g^2dxdy]^{1/2}} \quad (1.9)$$

para

$$\begin{aligned} g_0(x, y) &= G [I_0(x, y)], \\ g(x, y) &= G [I(x, y)], \end{aligned} \quad (1.10)$$

em que

$$G[f(x, y)] = \left\{ [df(x, y)/dx]^2 + [df(x, y)/dy]^2 \right\}^{1/2} \quad (1.11)$$

e $I_0(x, y)$ e $I(x, y)$ são as intensidades das saídas do padrão *speckle* antes e depois da perturbação, respectivamente.

Assim, pode-se afirmar que o NIPC varia à medida que o padrão *speckle* se desvia do padrão de referência (I_0), possibilitando quantificar as variações relativas no status da fibra. No entanto, deve-se ressaltar que se a perturbação da fibra de detecção torna-se extremamente brusca, o NIPC tende a um valor constante (YU et al., 1993). Portanto, a avaliação do specklegrama apenas pela variação na intensidade apresenta limitações em relação à faixa dinâmica.

Isso posto, são buscadas outras alternativas que utilizem de forma integral as complexidades do padrão *speckle*. As características não-lineares relacionadas ao processo de formação e captura dos specklegramas possibilitam um desenvolvimento à luz do Aprendizado de Máquina, conforme sugerido por (EFENDIOGLU, 2017). Trabalhos correlatos, como em (RODRÍGUEZ-CUEVAS et al., 2018), mostram que algoritmos de aprendizado de máquina podem ser treinados de forma a classificar onde uma perturbação ocorreu ao longo da fibra óptica.

Aspectos ainda não explorados na literatura como a avaliação das texturas presentes nas imagens decorrentes do sensoriamento usando o specklegrama em fibra óptica são abordados neste projeto. Uma técnica utilizada é o *Local Binary Partition* (LBP), uma poderosa técnica para classificação de texturas em virtude de possuir poucas operações e, ainda assim, possibilitar um bom poder discriminativo (DAS; JENA, 2017). Outra técnica é o *Gray Level Cooccurrence Matrix* (GLCM), já aplicado na literatura para analisar a rugosidade do papel por meio da textura do padrão *speckle* (PINO; PLADELLORENS; COLOM, 2010).

Os resultados provenientes de ambos extratores de características são utilizados como parâmetros (*features*) para uso em técnicas de aprendizado de máquina, como as Redes Neurais Artificiais (RNAs). As RNAs podem ser úteis para extrair características significativas presentes nos specklegramas na saída da fibra óptica (EFENDIOGLU, 2017). Sua capacidade de construir modelos não lineares por meio de algoritmos de aprendizado com base na análise de grandes conjuntos de treinamento se configura particularmente útil nesse contexto (RODRÍGUEZ-CUEVAS et al., 2018).

1.3 Hipótese e Objetivos do Trabalho

Esse trabalho assume como hipótese que o padrão *speckle* possui aspectos texturais relevantes que retratam as mudanças sofridas pelo padrão de interferência entre os modos em uma fibra óptica. Sendo assim, tem-se como objetivo geral avaliar se o uso de características

extraídas por descritores de textura em algoritmo de aprendizado de máquina possibilita a classificação da posição onde ocorre uma perturbação ao longo de uma fibra óptica. Os objetivos específicos desta pesquisa são:

- Utilizar os descritores de texturas LBP e GLCM para caracterizar o specklegrama;
- Utilizar uma rede neural *feedforward* como classificador e contrastar seus resultados a um modelo sem extração de características já presente na literatura;
- Avaliar diferentes combinações de parâmetros que definem os descritores, gerando sete diferentes conjuntos de dados de entrada para classificação a partir de diferentes bancos de imagens;
- Testar a abordagem em 2 tipos de banco de dados: o primeiro banco deles cedido pelos autores de (RODRÍGUEZ-CUEVAS et al., 2018) e o segundo, obtido experimentalmente.

1.4 Estrutura da Dissertação

No Capítulo 2, apresentam-se conceitos essenciais para a compreensão da proposta, relacionados a análise de imagem por textura e classificação de padrões. No Capítulo 3, são apresentadas as metodologias de desenvolvimento e resultados referentes a duas análises: na Seção 3.1, utilizando um banco de imagens já utilizado na literatura cedido para este trabalho; e na Seção 3.2, um banco de imagens inédito na literatura obtido experimentalmente. Por fim, no Capítulo 4, as conclusões gerais do trabalho e os próximos passos para o desenvolvimento de trabalhos futuros.

2 Referenciais Teóricos

No presente capítulo são apresentadas as teorias de base aplicadas a este trabalho, a fim de discorrer a respeito dos extratores de características baseados em textura utilizados na pesquisa, bem como do classificador adotado.

2.1 Extração de Características baseada em Textura

No processo de classificação de um padrão, geralmente é utilizada uma representação mais compacta da imagem, chamada de vetor de características, cujo tamanho é determinado pelo número de atributos ou características, e depende dos atributos da imagem a serem utilizados para a classificação (GONZALEZ; WOODS, 2010). Normalmente, busca-se estabelecer quais atributos podem destacar melhor as propriedades dos componentes da imagem. As principais características usadas para representar uma imagem, de forma a ajudar no processo de análise, são a forma do objeto, sua cor e textura.

Texturas fornecem informações sobre a distribuição das mudanças de tonalidade de um objeto ao longo do espaço, de forma que torna possível uma dada superfície tenha um aspecto visual mais rugoso ou suave, por exemplo (SCHWARTZ; SIQUEIRA; PEDRINI, 2012).

Segundo (GONZALEZ; WOODS, 2010), existem três principais abordagens para descrever uma textura: espectral, estrutural e estatística. Cada uma delas possui uma variedade de descritores que podem representar a textura (VENTURA, 2009).

A abordagem espectral leva em consideração as características do espectro de Fourier, a partir do qual padrões periódicos globais podem ser detectados por meio de seus picos de alta energia. Os descritores da energia espectral mais comuns são dados pela soma das funções espectrais em cada coordenada (GONZALEZ; WOODS, 2010).

Em contrapartida, a abordagem estrutural utiliza elementos mais básicos que compõem uma imagem inteira, dispostas de forma aproximadamente repetitiva e regular seguindo regras bem definidas. Esses elementos primitivos de textura são chamadas *textons* (JULESZ, 1981), (JULESZ, 1984), que são descritores usados para agrupar e formar um vocabulário para descrever todas as texturas de um conjunto.

Já a terceira abordagem, a estatística, busca descrever as texturas estimando-se a distribuição espacial local do nível de cinza dos pixels. Dentre os descritores dessa abordagem estão o *Local Binary Pattern* (LBP) e a *Gray Level Co-occurrence Matrix* (GLCM).

2.1.1 LBP

Proposto por [Ojala, Pietikäinen e Harwood \(1996\)](#) o LBP é um método que resume a estrutura local de uma imagem de maneira não-paramétrica. Tal característica advém da sua construção: nesta técnica, são avaliados se pixels circundantes são maiores ou não que um pixel central, não importando qual a magnitude dessa diferença. Deste modo, uma mesma variação na intensidade de todos os pixels não altera o valor obtido pelo método, tornando-o invariante a transformações na escala de cinza e, conseqüentemente, menos sensível a variações na iluminação. Outro aspecto importante do LBP é o seu número reduzido de operações, o que possibilita um baixo custo computacional, mantendo um alto poder discriminativo ([MARCEL; RODRIGUEZ; HEUSCH, 2007](#)). Por essas razões, o LBP apresenta uma vasta gama de aplicações, nas quais a representação da textura de uma imagem é importante, desde detecção de objetos ([HEIKKILÄ; PIETIKÄINEN; HEIKKILÄ, 2004](#)) a reconhecimento de expressão facial ([MARCEL; RODRIGUEZ; HEUSCH, 2007](#)).

Originalmente, o LBP é calculado para uma janela 3x3, comparando as intensidades entre 8 pixels vizinhos circundantes e um pixel central. Atribui-se um número binário a depender dessa comparação - valor 1 quando maior ou igual ao pixel central e 0 caso contrário. Cada um dos números obtidos é ponderado pela posição do pixel referente a ele e o valor do LBP para essa unidade de textura é a soma destes números ponderados. Esse processo é exemplificado na Figura 4.

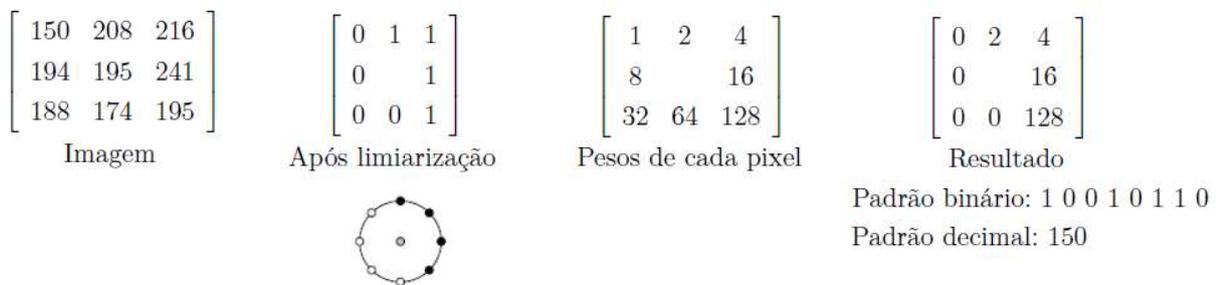


Figura 4 – Ilustração do processo de extração do LBP para um pixel.

Após aplicar o LBP para todos os pixels da imagem original, a distribuição de frequência dos valores resultantes é calculada, formando o histograma H_{LBP} , com 2^P possíveis valores. A partir dele, é possível formar um vetor de características a ser utilizado como a entrada de um classificador baseado em textura.

Matematicamente, o operador LBP, aplicada a um pixel (x_c, y_c) pode ser definido da seguinte forma:

$$LBP_{P,R}(x_c, y_c) = \sum_{n=0}^{P-1} s(g_n - g_c) 2^n, \quad (2.1)$$

sendo

$$s(x) = \begin{cases} 1 & \text{se } x \geq 0 \\ 0 & \text{x} < 0, \end{cases} \quad (2.2)$$

e g_n e g_c , os níveis de cinza do pixel da vizinhança e o nível de cinza do pixel central, respectivamente.

Ojala, Pietikäinen e Mäenpää (2002) propõem uma variação do LBP para vizinhanças circulares aplicável a qualquer quantização de espaço angular e resolução espacial, possibilitando uma aplicação multiescalar. Isso é realizado tomando as intensidades do nível de cinza de uma vizinhança (P, R) de um dado pixel central g_c , com coordenadas x_c e y_c e P pontos de amostragem em um círculo de raio R , conforme ilustrado na Figura 5.

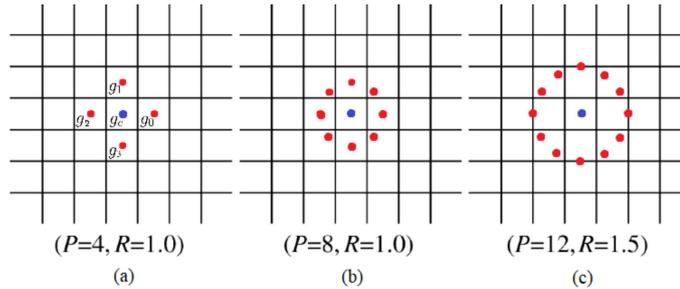


Figura 5 – Exemplos de combinações (P, R) para cálculo do LBP.

Também em (OJALA; PIETIKÄINEN; MÄENPÄÄ, 2002), foi constatado que um pequeno conjunto de padrões LBP chegam a representar mais de 90% das informações de textura. Esses padrões, chamados de uniformes, são aqueles nos quais a medida de uniformidade U é menor ou igual a 2, dada pela Equação 2.3. Essa medida calcula a quantidade de transições de 0 para 1 ou de 1 para 0 entre pixels vizinhos, conforme

$$U(LBP_{P,R}) = |s(g_{P-1} - g_c) - s(g_0 - g_c)| + \sum_{p=1}^{P-1} |s(g_p - g_c) - s(g_{P-1} - g_c)|, \quad (2.3)$$

no qual s é definido segundo a Equação 2.2.

Os padrões uniformes representam texturas primitivas de uma imagem, como pontos, fins de linhas, bordas e cantos, como apresentado na Figura 6. Nela, 1's são representados por círculos preenchidos e 0's por círculos vazados.

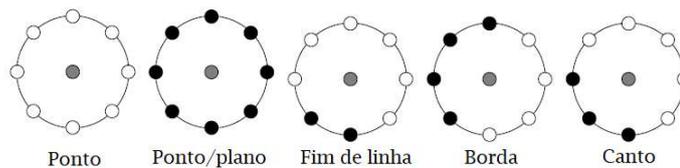


Figura 6 – Padrões uniformes e representações de texturas primitivas.

Fonte: Adaptado de Pietikäinen et al. (2011).

Denomina-se LBP^{u2} o operador LBP que leva em consideração os diferentes padrões uniformes ($U \leq 2$) e agrupa todos os padrões não-uniformes em um dos grupos de intervalos

idênticos nos quais são agregados as frequências, denominados *bins*, de um histograma gerado ao final da operação em todos os pixels. Para análise com 8 pontos de amostragem ($P=8$), são formados 58 padrões uniformes distintos entre si. Eles variam de acordo com a quantidade de bits iguais a 1 e suas rotações, sendo um deles com todos os pixels iguais a 0 e outro, com todos iguais a 1. Cada um dos 7 padrões possuem 8 combinações diferentes de acordo com as variações nas posições dos bits iguais a 1, conforme mostrado no lado esquerdo da Figura 7.

Assim, o histograma produzido tem 59 bins, ou seja, o vetor de características extraído por este descritor é constituído de 59 posições. De maneira geral, o resultado da aplicação do LBP^{u2} em uma imagem representa a frequência de $P(P-1)+3$ possíveis padrões. Tal fato possibilita reduzir a dimensionalidade do LBP, anteriormente de 2^P . Ao considerar apenas padrões uniformes, o número de rótulos possíveis diminui significativamente tornando menos sensíveis a ruídos ao compor o conjunto de bins (PIETIKÄINEN et al., 2011).

A fim de obter invariância a rotação, utilizando os padrões uniformes, foi proposto o operador $LBP_{P,R}^{riu2}$ (*rotation invariant* com $U \leq 2$), dado por

$$LBP_{P,R}^{riu2} = \begin{cases} \sum_{p=0}^{P-1} s(g_p - g_c) & \text{se } U(LBP_{P,R}) \leq 2, \\ P + 1 & \text{caso contrário.} \end{cases} \quad (2.4)$$

Nele, todos os padrões uniformes com a mesma quantidade de 1's (n) que, portanto, se diferenciam apenas pela rotação em relação ao pixel central, são rotulados da mesma forma. Assim, é feito um mapeamento entre padrões de mesmo n , conforme ilustrado na Figura 7. Ao todo são formados $P+1$ padrões uniformes e invariantes a rotação e os padrões não-uniformes são agrupados em único rótulo, totalizando $P+2$ padrões.

Para efeitos de comparação, são ilustrados na Figura 8 os histogramas normalizados resultantes da extração das características texturais de duas imagens utilizando LBP^{u2} (com 59 bins) e LBP^{riu2} (com 10 bins). Ela são texturas artificiais que só se diferenciam pela rotação de 90° . Deve-se observar que os histogramas gerados pelo operador LBP^{u2} se diferenciam apenas em relação a certa defasagem entre alguns picos de frequência. Mais especificamente, na imagem original os picos se referem às posições 36 e 40 e na imagem rotacionada, 34 e 38. Tal fato resulta da presença de padrões uniformes que o operador é capaz de distinguir, o que não ocorre ao utilizar o operador LBP^{riu2} . Nota-se que este representa ambas imagens com o mesmo histograma, denotando a sua capacidade de invariância a rotação e boa capacidade de representação com poucos bins.

2.1.2 GLCM

A Matriz de Coocorrência de Tons de Cinza é um método estatístico utilizado para descrever texturas, proposto em (HARALICK; SHANMUGAN; DINSTEIN, 1973). Nessa

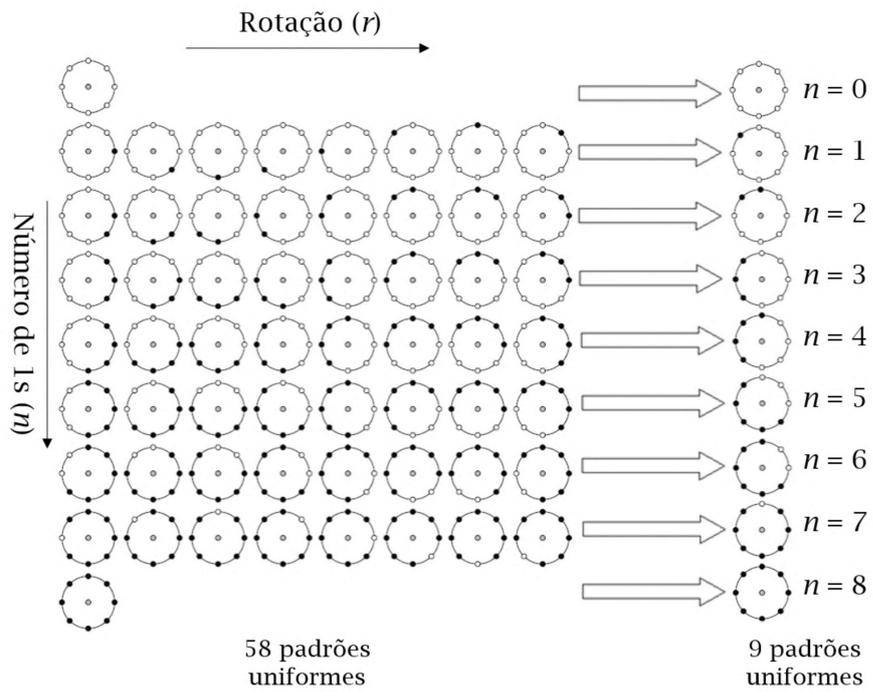


Figura 7 – Mapeamento do padrões uniformes invariantes a rotação referentes a 8 pontos de amostragem.

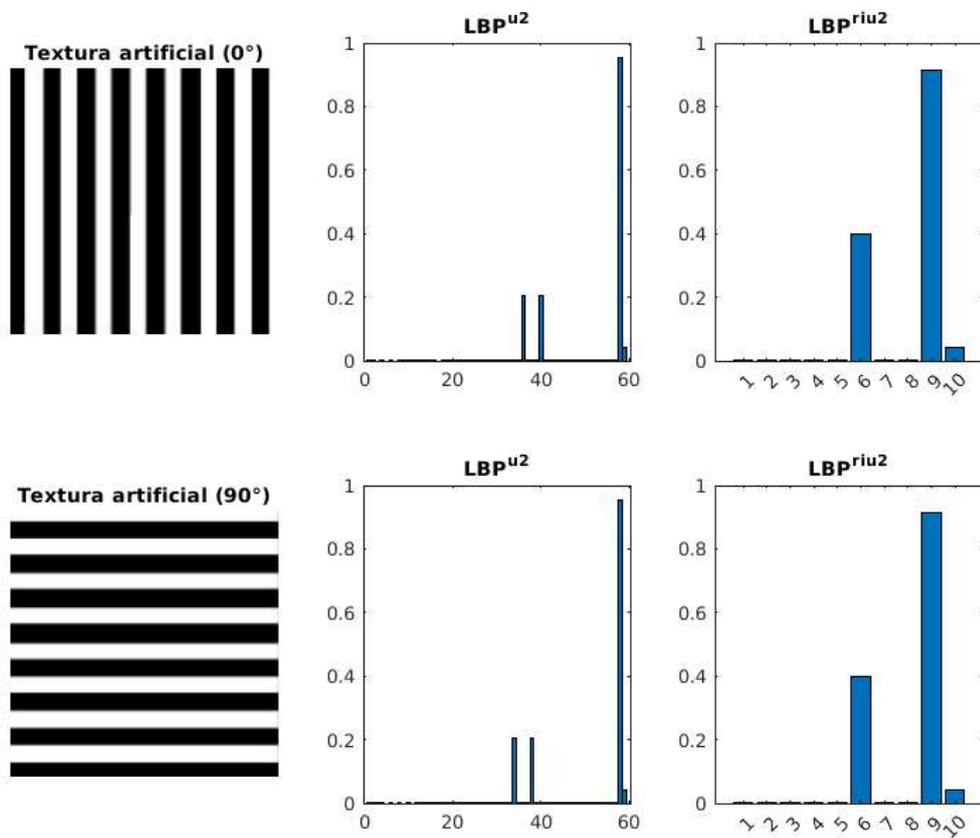


Figura 8 – Extração de características de textura artificial original e rotacionada utilizando LBP^{u2} e LBP^{riu2} .

matriz são armazenadas probabilidades de que dois valores de intensidade de cinza estejam envolvidos por uma relação espacial.

Uma GLCM corresponde a uma matriz que não depende do tamanho da imagem, mas apenas dos níveis de cinza na textura. De fato, ela é uma matriz quadrada de dimensão $M_c \times M_c$, em que M_c é a maior intensidade do nível de cinza na imagem. Antes de ser calculada, deve-se definir o arranjo de pixels a partir dos quais as transições serão consideradas e pelo conjunto S . Cada elemento de S é um par de coordenadas envolvidas no arranjo.

A partir disso, define-se $F(m, n)$ todo elemento da Matriz de Coocorrência responsável por armazenar a frequência de transições entre cada par de níveis de cinza m -ésima linha e n -ésima coluna da matriz. Cada elemento registra a quantidade de vezes em que há transição de um pixel com nível de cinza m para um pixel com nível de cinza n , sendo $0 \leq m, n \leq M_c - 1$ (PEDRINI; SCHWARTZ, 2007). Assim sendo, define-se $F(m, n)$ conforme

$$F(m, n) = \#\{[(i, j), (k, l)] \in S | g(i, j) = m, g(k, l) = n\}, \quad (2.5)$$

em que $g(x, y)$ representa o nível de cinza no pixel localizado em (x, y) na imagem e $\#$ denota o número de elementos no conjunto.

As características de textura são obtidas através da matriz de coocorrência normalizada, definida por

$$f(m, n) = \frac{F(m, n)}{\sum_{i=0}^{M_c-1} \sum_{j=0}^{M_c-1} F(i, j)} \quad \text{para } m, n = 0, \dots, M_c - 1. \quad (2.6)$$

Nela, cada elemento da matriz calculada pela Equação 2.5 é dividido pela soma de seus elementos.

O conjunto S é definido por dois parâmetros: distância d e ângulo θ entre os pixels vizinhos, que formarão o par a ser analisado.

Cada pixel possui 8 vizinhos, restringindo a escolha de θ aos ângulos de 0° , 45° , 90° , 135° , 180° , 225° , 270° ou 315° . No entanto, os pares coocorrentes obtidos pela escolha de um ângulo seriam semelhantes aos obtidos pela escolha de seu suplementar. Portanto, tem-se quatro opções para θ , ilustrados na Figura 9.

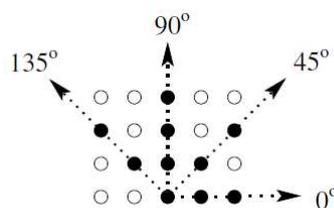


Figura 9 – Orientações referentes aos ângulos para a geração da Matriz de Coocorrência.

Formalmente, as frequências não normalizadas para cada um dos ângulos são definidas pelas equações:

$$F(m, n, d, 0^\circ) = \{[(i, j), (k, l)] \in S \mid i - k = 0, |j - l| = d, g(i, j) = m, g(k, l) = n\} \quad (2.7)$$

$$F(m, n, d, 45^\circ) = \{[(i, j), (k, l)] \in S \mid (i - k = d, j - l = -d) \vee (i - k = -d, j - l = d), \\ g(i, j) = m, g(k, l) = n\} \quad (2.8)$$

$$F(m, n, d, 90^\circ) = \{[(i, j), (k, l)] \in S \mid |i - k| = d, j - l = 0, g(i, j) = m, g(k, l) = n\} \quad (2.9)$$

$$F(m, n, d, 135^\circ) = \{[(i, j), (k, l)] \in S \mid (i - k = d, j - l = d) \vee (i - k = -d, j - l = -d), \\ g(i, j) = m, g(k, l) = n\} \quad (2.10)$$

A distância d pode variar entre valores inteiros de acordo com a relação deseja-se se avaliar entre dois pixels. Para uma textura fina, utilizar um valor de d grande resultaria em uma GLCM que não é capaz de capturar informações texturais detalhadas. Precisoões de classificação geral com d iguais a 1, 2, 4 e 8 são aceitáveis, obtendo melhores resultados com $d = 1$ e 2, salientando o fato de que é mais provável que um pixel seja mais correlacionado a outro mais próximo que a outro distante (GADKARI, 2004).

A Figura 10 traz a ilustração de um exemplo da geração das matrizes de coocorrência de uma imagem I com 3 níveis de cinza representada em uma matriz 4×5 , para cada ângulo definido anteriormente com $d=1$.

Cada elemento (m, n) dessas matrizes representam a probabilidade de que o valor de cinza m esteja espacialmente relacionado, conforme d e θ , com o valor de cinza n . Dessa forma, é possível afirmar que a GLCM caracteriza uma distribuição conjunta de pares de pixels vizinhos, e é a partir dela que são extraídos os descritores.

Diversas estatísticas podem ser originadas da matriz de coocorrência. Em (HALICK; SHANMUGAN; DINSTEIN, 1973) são propostas 14 medidas cujos médias e intervalos de cada uma compõem um conjunto de 28 atributos que podem ser utilizados como entradas de um classificador. No entanto, muitos deles possuem pouca capacidade de discriminação tendo em vista as correlações entre si. Portanto, em aplicações práticas, utiliza-se um subconjunto desses atributos, dentre os quais estão Homogeneidade, Contraste, Correlação e Energia.

$$\begin{aligned}
 I &= \begin{bmatrix} 1 & 1 & 1 & 0 & 1 \\ 2 & 1 & 0 & 2 & 0 \\ 1 & 0 & 1 & 2 & 1 \\ 2 & 0 & 0 & 1 & 0 \end{bmatrix} & F(m, n, d = 1, \theta = 0^\circ) &= \begin{bmatrix} 1 & 3 & 1 \\ 4 & 2 & 1 \\ 2 & 2 & 0 \end{bmatrix} \\
 & & F(m, n, d = 1, \theta = 45^\circ) &= \begin{bmatrix} 2 & 1 & 1 \\ 0 & 3 & 1 \\ 2 & 2 & 0 \end{bmatrix} \\
 & & F(m, n, d = 1, \theta = 90^\circ) &= \begin{bmatrix} 1 & 5 & 0 \\ 2 & 1 & 2 \\ 1 & 2 & 1 \end{bmatrix} \\
 & & F(m, n, d = 1, \theta = 135^\circ) &= \begin{bmatrix} 2 & 2 & 2 \\ 0 & 3 & 1 \\ 1 & 1 & 0 \end{bmatrix}
 \end{aligned}$$

Figura 10 – Matrizes de coocorrência geradas para a imagem exemplo.

A Homogeneidade (*Hom*) mede a proximidade da distribuição dos elementos à diagonal da matriz de coocorrência, calculada como:

$$Hom = \sum_{i=0}^{M_c-1} \sum_{j=0}^{M_c-1} \frac{f(i, j)}{1 + (i - j)^2}. \quad (2.11)$$

Variando de 0 a 1, o valor encontrado para esse atributo representa que, quanto maior for frequência de ocorrência de um determinado nível de cinza, maior será a uniformidade local e mais próximo de 1 é a homogeneidade.

O Contraste (*Con*) mede as variações locais da intensidade do pixel em relação a sua vizinhança e é calculada por:

$$Con = \sum_{i=0}^{M_c-1} \sum_{j=0}^{M_c-1} f(i, j)(i - j)^2. \quad (2.12)$$

Uma imagem com contraste igual a zero representa que a imagem possui o mesmo tom de cinza em toda sua extensão. Seu valor máximo é de $(M_c - 1)^2$

A Correlação (*Cor*) mede, para todos os pixels da imagem, quão correlacionado ao seu vizinho ele está e é dada pela equação:

$$Cor = \sum_{i=0}^{M_c-1} \sum_{j=0}^{M_c-1} f(i, j) \frac{(i - \mu_i)(j - \mu_j)}{\sigma_i \sigma_j}, \quad (2.13)$$

em que μ e σ representam a média e o desvio padrão. Eles são calculados para cada linha e coluna da matriz de coocorrência conforme as equações:

$$\mu_i = \sum_{i, j=0}^{M_c-1} i \cdot (f(i, j)) \quad (2.14)$$

$$\mu_j = \sum_{i,j=0}^{M_c-1} j \cdot (f(i, j)) \quad (2.15)$$

$$\sigma_i^2 = \sum_{i,j=0}^{M_c-1} (i - \mu_i)^2 \cdot (f(i, j)) \quad (2.16)$$

$$\sigma_j^2 = \sum_{i,j=0}^{M_c-1} (j - \mu_j)^2 \cdot (f(i, j)) \quad (2.17)$$

A correlação entre dois pixels representa se existe uma relação de dependência linear, ou seja, se há uma alta previsibilidade, através de uma regressão linear. Para uma região da imagem onde há pixels vizinhos que podem ser representados por uma combinação linear entre si, a correlação será de -1 ou 1, a depender do nível de cinza. Para regiões onde não há essa combinação, o valor varia entre -1 e 1. Além disso, para regiões uniformes, o desvio padrão será zero e, portanto, a correlação terá valor indefinido.

A Energia (*Ene*), também chamada de segundo momento angular ou uniformidade, mede o nível total da intensidade, dada segundo a equação:

$$Ene = \sum_{i=1}^{M_c} \sum_{j=1}^{M_c} f(i, j)^2. \quad (2.18)$$

Seu valor varia entre 0 e 1. Em uma imagem que possui o mesmo tom de cinza em toda sua extensão, a sua energia será 1.

Os descritores de Homogeneidade e Contraste baseados na GLCM foram utilizados em (LIU et al., 2018) para sensoriamento de deslocamento lateral utilizando o specklegrama, que apresentou resultados melhores que uma abordagem baseada em variação de intensidade.

As relações entre imagem e medidas estatísticas extraídas da matriz de coocorrência gerada a partir dela são exemplificadas em 4 casos da Figura 11.

No primeiro caso, percebe-se que a correlação é 1, tendo em vista que as linhas que compõem a matriz são linearmente dependentes, o que aumenta a previsibilidade do próximo pixel. Essa dependência linear é dada por um coeficiente positivo, o que não acontece no terceiro caso. Nele, há colunas linearmente dependentes, que relacionam por um coeficiente negativo. O segundo caso representa uma imagem uniforme que, portanto, possui desvio padrão igual a zero, fazendo com que a correlação tenha um valor que tende ao infinito. Por fim, o quarto caso mostra uma imagem com pixels diversos, sem relação direta entre eles.

Caso 1	$I_1 = \begin{bmatrix} 0 & 0 & 0 \\ 1 & 1 & 1 \\ 2 & 2 & 2 \end{bmatrix}$	$F_1 = \begin{bmatrix} 2 & 0 & 0 \\ 0 & 2 & 0 \\ 0 & 0 & 2 \end{bmatrix}$	$Con_1 = 0$ $Cor_1 = 1$ $Ene_1 = 0,33$ $Hom_1 = 1$
Caso 2	$I_2 = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}$	$F_2 = \begin{bmatrix} 0 & 0 \\ 0 & 6 \end{bmatrix}$	$Con_2 = 0$ $Cor_2 = NaN$ $Ene_2 = 1$ $Hom_2 = 1$
Caso 3	$I_3 = \begin{bmatrix} 0 & 1 & 0 \\ 0 & 1 & 0 \\ 0 & 1 & 0 \end{bmatrix}$	$F_3 = \begin{bmatrix} 0 & 3 \\ 3 & 0 \end{bmatrix}$	$Con_3 = 0$ $Cor_3 = -1$ $Ene_3 = 0,5$ $Hom_3 = 0,5$
Caso 4	$I_4 = \begin{bmatrix} 1 & 2 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 2 \end{bmatrix}$	$F_4 = \begin{bmatrix} 2 & 0 & 1 \\ 1 & 0 & 1 \\ 1 & 0 & 0 \end{bmatrix}$	$Con_4 = 1,67$ $Cor_4 = -0,16$ $Ene_4 = 0,22$ $Hom_4 = 0,61$

Figura 11 – Exemplos de descritores estatísticos extraídos da matriz de coocorrência.

2.2 Redes Neurais Artificiais

Uma Rede Neural Artificial (RNA), usualmente denominada “rede neural” é um sistema inspirado no funcionamento não linear, complexo e paralelo que ocorre no sistema nervoso humano. Ela é constituída de unidades básicas de processamento (neurônios) que são interligados e propensos a acumular conhecimento experimental, a partir de um processo de aprendizagem, e a torná-lo disponível para uso (HAYKIN, 2009).

Tal processo de aprendizagem se baseia na comunicação entre neurônios de uma rede neural biológica, na qual os seus terminais de recepção recebem ativações de outros neurônios conectados e, a depender do limiar da combinação entre as ativações, produzem um impulso elétrico que é propagado pela rede. O primeiro modelo matemático que busca representar um neurônio biológico foi proposto por McCulloch e Pitts (1943) e é ilustrado na Figura 12. Nela, é apresentado um conjunto de n valores de entrada, representados pelo vetor $\mathbf{x} = [x_1, x_2, \dots, x_n]^T$ e seus respectivos pesos sinápticos, dados pelo vetor $\mathbf{w} = [w_1, w_2, \dots, w_n]$, em que φ é a função de ativação e y é o sinal de saída.

O neurônio matemático realiza a soma ponderada dos sinais de entrada, acrescida de um *bias* (viés) b , formando a saída v . O *bias* possui a função de aumentar o grau de liberdade dos ajustes de pesos. O sinal de saída é enfim dado pela transformação do sinal v aplicada pela função de ativação. Este processo é matematicamente descrito por:

$$v = \sum_{j=1}^n x_j \cdot w_j = \mathbf{x}^T \mathbf{w} + b, \quad (2.19)$$

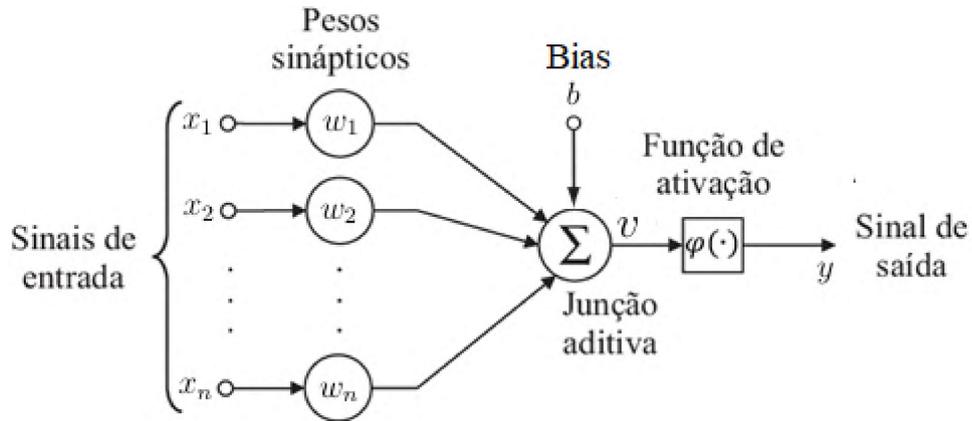


Figura 12 – Modelo de Neurônio de McCulloch e Pitts.

Fonte: Adaptado de (HAYKIN, 2009).

$$y = \varphi(v). \quad (2.20)$$

A função de ativação tem papel importante visto que a sua saída é o sinal de saída do neurônio, apresentando um valor que seja relevante para efeitos práticos.

São apresentadas na Figura 13 as principais funções de ativação. Em 13d e 13e, estão representadas aquelas mais frequentemente usadas considerando a sua capacidade em modelar equações e encontrar limites de classificação não-lineares (GRAVES, 2012).

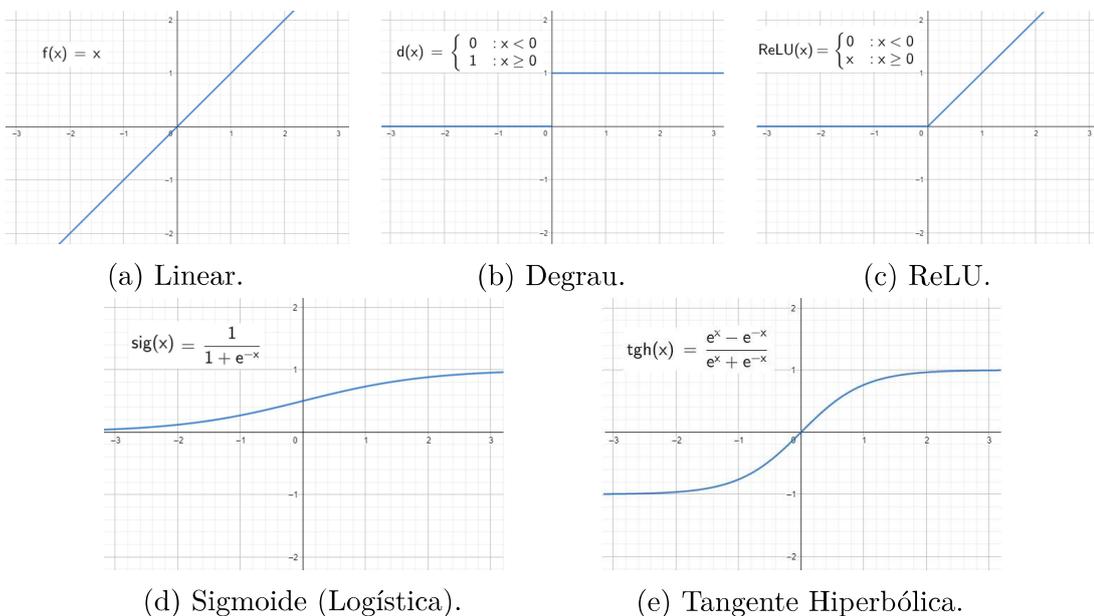


Figura 13 – Funções de Ativação.

Uma importante função de ativação para problemas de classificação é a função *SoftMax*. Ela possibilita uma interpretação probabilística dos valores de saída dos neurônios, ao os normalizar entre 0 e 1. Para um conjunto de K neurônios, que formam uma camada de saída, no qual cada neurônio k está um relacionado a uma classe diferente, tem-se que

a probabilidade p_i de uma entrada x ser pertencente a classe C_k é dada por

$$p_i = \frac{e^{v_k}}{\sum_{j=1}^K e^{v_j}}, \quad (2.21)$$

em que cada v_j é calculado conforme a Equação 2.20.

As interconexões entre neurônios matemáticos estruturados em camadas possibilitam a formação de uma rede neural artificial e, quando essas interconexões são acíclicas, tem-se redes neurais *feedforward*. Sendo os neurônios que recebem os sinais de entrada diretamente conectados aos neurônios da saída, essas redes neurais são classificadas como de Camada Única. Ao utilizar outro conjunto de neurônios entre as camadas de entrada e saída, formando uma camada oculta, constitui-se a classe de Redes Neurais Perceptron Multi-Camada (*Multi-layer Perceptron* – MLP). Um exemplo de MLP com 1 camada oculta é ilustrada na Figura 14.

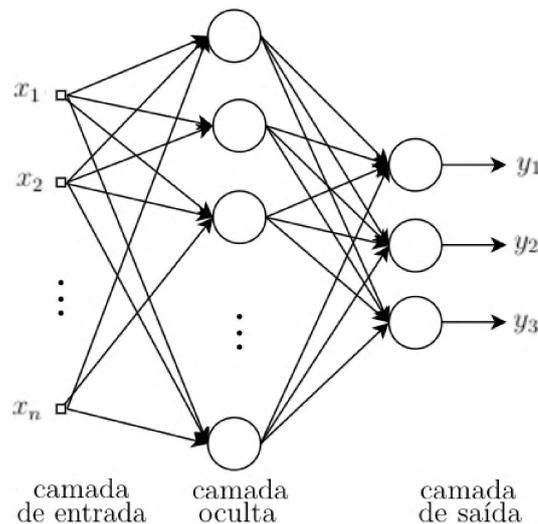


Figura 14 – Ilustração de Rede Neural Perceptron Multi-Camada.

Redes neurais *feedforward* são considerados aproximadores universais de função, visto que um conjunto de valores de pesos define um mapeamento de vetores de entrada para vetores de saída e, alterando-se tais pesos é possível representar distintas funções (GRAVES, 2012). Segundo Bishop (2006), redes neurais podem ser vistas como uma classe geral de funções não-lineares paramétricas de uma entrada x para uma saída y . Assim, o algoritmo de aprendizado consiste em decidir como usar as camadas para melhor implementar uma aproximação de dessas funções (GOODFELLOW; YOSHUA; COURVILLE, 2016).

O treinamento de uma rede neural baseado no aprendizado supervisionado utiliza dados conhecidos e previamente rotulados para auxiliar na atualização dos pesos das camadas a fim de atingir a classificação desejada. As informações da entrada x são passadas por todas as camadas através dos cálculos realizados em cada neurônio da rede e a saída y é formada pelo conjunto das saídas relativas às funções de ativação dos neurônios

da camada de saída. A partir dessa informação da saída, uma função perda (também chamada de função erro) é calculada, comparando o valor obtido com o valor esperado (*target*). As principais funções para realização do cálculo são o erro quadrático médio (*Mean Squared Error* – MSE), calculado como

$$E(\mathbf{w}) = \frac{1}{2} \sum_{n=1}^N \|\mathbf{y}(\mathbf{x}_n, \mathbf{w}) - \mathbf{t}_n\|^2, \quad (2.22)$$

e a entropia cruzada, descrita por

$$E(\mathbf{w}) = - \sum_{n=1}^N \sum_{k=1}^K t_{kn} \ln \mathbf{y}(\mathbf{x}_n, \mathbf{w}). \quad (2.23)$$

Nelas, \mathbf{w} representa o conjunto de pesos da rede, \mathbf{x}_n , o vetor de entrada, \mathbf{t}_n , o vetor de *targets* e $\mathbf{y}(\mathbf{x}_n, \mathbf{w})$ a saída, sendo N a quantidade de vetores de entrada e K o número de classes para a classificação (BISHOP, 2006).

Sobre a distinção na utilização de cada uma das diferentes funções custo e suas relações com as funções de ativação, Bishop (2006) afirma que

"[...] há uma escolha natural da função de ativação da unidade de saída e da correspondente função de erro, de acordo com o tipo de problema a ser resolvido. Para a regressão, usamos saídas lineares e um erro de soma de quadrados, para classificações binárias (independentes múltiplas) usamos saídas sigmóides logísticas e uma função de erro de entropia cruzada, e para classificação multiclasse usamos saídas *softmax* com os correspondentes função de erro de entropia cruzada multiclasse" (BISHOP, 2006, p.236, tradução nossa).

2.2.1 Algoritmos de Treinamento

Para que haja aprendizado da rede neural, é necessário ajustar os pesos de forma que o valor encontrado pela função custo seja minimizado durante o treinamento supervisionado. Muitos são os algoritmos de treinamento de redes MLPs, porém são abordados neste trabalho dois deles: o algoritmo *backpropagation* e o Gradiente Conjugado Escalonado.

2.2.1.1 *Backpropagation*

O algoritmo *backpropagation* foi pioneiro em resolver eficientemente o problema da estimativa do erro total da rede em função de cada um dos neurônios das diferentes camadas de uma MLP, ao ser baseado no método do gradiente descendente. Ele é realizado em duas etapas: uma para frente (*forward*) e uma para trás (*backward*). A primeira consiste em apresentar os dados de entrada à rede, gerar os sinais de saída e calcular o valor da função custo. Já na segunda etapa são ajustados os pesos.

Esse ajuste é feito de forma iterativa de acordo com o método do gradiente descendente, no qual as derivadas parciais da função custo em relação a cada peso do

vetor \mathbf{w} é calculado em uma iteração k e os pesos são atualizados de forma a minimizar o erro na iteração seguinte ($k + 1$). Em outras palavras, os pesos são atualizados na direção do gradiente negativo do erro a uma taxa de aprendizado fixa η , conforme

$$\mathbf{w}_{k+1} = \mathbf{w}_k - \eta \nabla E(\mathbf{w}_k). \quad (2.24)$$

Pode-se avaliar que, se o gradiente da função custo for negativo significa que ele está indo em direção a um mínimo estável e que um aumento nos pesos irá diminuir o erro, portanto, na iteração seguinte o peso será maior. Por outro lado, se o gradiente for positivo, os pesos devem ser diminuídos de forma a diminuir o erro.

O controle do tamanho do passo na correção dos pesos é feito pela taxa de aprendizado. Ela não pode ser nem tão pequena que faça com que sejam necessárias muitas iterações para que se chegue a um mínimo estável da função custo, nem tão grande que induza a um aprendizado instável (HAYKIN, 2009). Portanto, a escolha adequada deste parâmetro é decisivo para um bom desempenho do algoritmo, oferecendo respostas não adequadas, principalmente em problemas de grande escala.

2.2.1.2 Gradiente Conjugado Escalonado

O algoritmo do Gradiente Conjugado Escalonado (*Scaled Conjugate Gradient - SCG*) proposto por Møller (1993) é um algoritmo pertencente a classe dos métodos de gradiente conjugado (CG). Eles são caracterizados por minimizar funções objetivo com uso das suas derivadas secundárias e, portanto, serem métodos de segunda ordem. Comparados aos de primeira ordem, apresentam maior rapidez para convergir.

Sendo o SCG um algoritmo resultado de melhorias no método GC, é importante apresentar o funcionamento deste e posteriormente as modificações realizadas para criação daquele. Enquanto o algoritmo de *backpropagation* possui uma taxa de aprendizado fixa, no GC é realizado o procedimento de busca em linha (*line search*) para definir uma taxa η_k a cada iteração. A busca em linha é um procedimento feito ao longo da direção do gradiente conjugado a fim de determinar o tamanho do passo que minimize a função custo ao longo da linha e é finalizado ao encontrar o valor mínimo de erro ou ao após executar um número de passos.

As buscas iniciam-se na direção de descida mais íngreme, na primeira iteração ($k = 1$) do algoritmo GC, dada por

$$\mathbf{P}_1 = -\mathbf{g}_1 = -\nabla E(\mathbf{w}_1), \quad (2.25)$$

em que \mathbf{g} representa o vetor do gradiente local da função custo em relação a \mathbf{w} .

Posteriormente, realiza-se a busca em linha para determinar a distância η que será percorrida no sentido da direção atual e então, os pesos são atualizados, de acordo com a

expressão

$$\mathbf{w}_{k+1} = \mathbf{w}_k + \eta_k \mathbf{P}_k. \quad (2.26)$$

Enquanto o algoritmo de *backpropagation* avança de acordo com o gradiente da função de erro, o CG procede em uma direção que é conjugada às direções das etapas anteriores. Assim, a minimização do erro realizada em uma etapa não é descartada pela próxima. Tal direção de busca é dada por

$$\mathbf{P}_{k+1} = -\mathbf{g}_0 + \beta_k \mathbf{P}_k. \quad (2.27)$$

A constante β_k é utilizada com a finalidade de determinar \mathbf{P}_k sem que haja conhecimento explícito da matriz Hessiana $E''(\mathbf{w}_k)$, que é de difícil manipulação. Os passos descritos são repetidos até que o critério de parada do algoritmo seja atendido.

A busca em linha exige que, para cada iteração, a resposta da MLP a todas as entradas de treinamento seja computada várias vezes, tornando-se, assim, muito custosa computacionalmente, ainda que consiga convergir mais rapidamente que o algoritmo *backpropagation*.

Com o intuito de evitar a busca em linha, Møller (1993), portanto, propõe o algoritmo SCG, baseado na ideia de estimar o tamanho do passo com a aproximação do cálculo da matriz Hessiana. Para que o algoritmo seja bem sucedido, é imperativo que ele convirja para um ponto estacionário. De acordo com testes apresentados por Møller (1993), isso só é possível tal aproximação seja definida positiva, e isso é conseguido por meio da inclusão do escalar λ_k .

A aproximação é expressa por

$$\mathbf{s}_k = \frac{E'(\mathbf{w}_k + \eta_k \mathbf{P}_k) - E'(\mathbf{w}_k)}{\eta_k} + \lambda_k \mathbf{P}_k, \quad (2.28)$$

em que E é dado pela Equação 2.23 quando utiliza-se a entropia cruzada para cálculo do erro.

O escalar λ_k é ajustado a cada iteração de acordo com a informação de $\delta_k = \mathbf{P}_k^T \mathbf{s}_k$, que revela se a matriz hessiana é definida positiva ou não. Caso o $\delta_k \leq 0$ então o λ_k é elevado e o \mathbf{s}_k é estimado novamente. Outro parâmetro importante no algoritmo SCG é σ , que possui a função de regular a aproximação da segunda derivada.

O algoritmo SCG completo é detalhado a seguir, conforme descrito em (MØLLER, 1993).

1. Escolher o vetor de pesos \mathbf{w}_1 e os escalares $\sigma > 0$, $\lambda_1 > 0$ e $\lambda_1 = 0$.
2. Atribuir $\mathbf{P}_1 = \mathbf{r}_1 = E'(\mathbf{w}_1)$, $k = 1$ e sucesso = verdadeiro, em que \mathbf{r} é a direção da descida mais íngreme.

3. Se sucesso = verdadeiro, então calcular a informação de segunda ordem:

$$\sigma_k = \frac{\sigma}{|\mathbf{P}_k|} \quad (2.29)$$

$$\mathbf{s}_k = \frac{E'(\mathbf{w}_k + \sigma_k \mathbf{P}_k) - E'(\mathbf{w}_k)}{\sigma_k} \quad (2.30)$$

$$\delta_k = \mathbf{P}_k^T \mathbf{s}_k \quad (2.31)$$

4. Escalonar \mathbf{s}_k :

$$\mathbf{s}_k = \mathbf{s}_k + (\lambda_k - \bar{\lambda}_k) \mathbf{P}_k, \quad (2.32)$$

$$\delta_k = \delta_k + (\lambda_k - \bar{\lambda}_k) |\mathbf{P}_k|^2 \quad (2.33)$$

5. Se o escalar $\delta \leq 0$, fazer a matriz Hessiana ser definida positiva:

$$\mathbf{s}_k = \mathbf{s}_k + \left(\lambda_k - 2 \frac{\delta_k}{|\mathbf{P}_k|^2} \right) \mathbf{P}_k, \quad (2.34)$$

$$\bar{\lambda}_k = 2 \left(\lambda_k \frac{\delta_k}{|\mathbf{P}_k|^2} \right), \quad (2.35)$$

$$\delta_k = -\delta_k + \lambda_k |\mathbf{P}_k|^2, \lambda_k = \bar{\lambda}_k. \quad (2.36)$$

6. Calcular o tamanho do passo:

$$\mu_k = \mathbf{p}_k^T \mathbf{r}_k \quad (2.37)$$

$$\eta_k = \frac{\mu_k}{\delta_k} \quad (2.38)$$

7. Calcular o parâmetro de comparação Δ_k , que auxilia numa estimação mais precisa do aumento de λ_k , para obter uma melhor aproximação \mathbf{s}_k :

$$\Delta_k = \frac{2\delta_k [E(\mathbf{w}_k) - E(\mathbf{w}_k - \eta_k \mathbf{P}_k)]}{\mu_k^2} \quad (2.39)$$

8. Se $\Delta_k \geq 0$ então, uma redução no erro pode ser feita:

$$\mathbf{w}_{k+1} = \mathbf{w}_k + \eta_k \mathbf{P}_k \quad (2.40)$$

$$\mathbf{r}_{k+1} = -E'(\mathbf{w}_{k+1}) \quad (2.41)$$

$$\bar{\lambda}_k = 0, \text{ sucesso} = \text{verdadeiro} \quad (2.42)$$

- a) Se $k \bmod N = 0$ então, reiniciar o algoritmo: $\mathbf{P}_{k+1} = \mathbf{r}_{k+1}$. Se não, criar uma nova direção conjugada \mathbf{P}_{k+1} :

$$\beta_k = \frac{|\mathbf{r}_{k+1}|^2 - \mathbf{r}_{k+1}^T \mathbf{r}_k}{\mu_k}, \quad (2.43)$$

$$\mathbf{P}_{k+1} = \mathbf{r}_{k+1} + \beta_k \mathbf{P}_k \quad (2.44)$$

- b) Se $\Delta_k \geq 0,75$ então, reduzir a escala do parâmetro: $\bar{\lambda}_k = \frac{1}{4} \lambda_k$.

9. Se $\Delta_k < 0$ então, uma redução no erro não é possível: $\lambda_k = \lambda_k$, sucesso = falso .
10. Se $\Delta_k < 0,25$ então, aumentar a escala do parâmetro:

$$\lambda_k = \lambda_k + \frac{\delta_k (1 - \Delta_k)}{|\mathbf{P}_k|^2} \quad (2.45)$$

11. Se $\mathbf{r}_k \neq 0$, então definir $k = k + 1$ e voltar para o passo 3, senão encerrar e retornar \mathbf{w}_{k+1} como o mínimo desejado.

Mesmo em vista do seu grande número de etapas e cálculos, o algoritmo SCG converge rapidamente e possui uma melhor desempenho que o algoritmo *backpropagation*. Estudos mostram que o SCG apresenta bom desempenho tanto em relação ao erro de treinamento quanto ao tempo de processamento (MATAR; LINA; KADDOUM, 2020; KHADSE; CHAUDHARI; BORGHATE, 2017).

2.2.2 Capacidade de Generalização

No aprendizado de máquina, o principal desafio é ter a capacidade de produzir, a partir de entradas novas e não conhecidas anteriormente, saídas com erro mínimo. A generalização, nesse sentido, consiste nessa habilidade e diz-se que uma rede neural é capaz de generalizar bem quando ela é capaz de mapear entrada-saída corretamente (ou quase) para dados nunca usados na sua criação ou treinamento (HAYKIN, 2009). A esse grupamento de dados dá-se o nome de conjunto de teste.

Uma forma de avaliar a qualidade da aprendizagem consiste em analisar o erro obtido pela rede com o conjunto de treinamento e o erro do conjunto de teste (erro de generalização), e compará-los. Quando ambos apresentam valores altos, ocorre o que se chama *underfitting*, no qual a rede não foi capaz de se ajustar de forma adequada aos dados. Porém, quando a rede neural se apresenta sensível de forma significativa a ruídos no conjunto de amostras de treinamento e acaba se sobre-ajustando a elas, o erro de treinamento apresentado é baixo, porém o erro de teste é alto, indicando a ocorrência de *overfitting*.

Nesse sentido, a fim de projetar uma rede neural que tem uma boa generalização como objetivo, é possível lançar mão de uma ferramenta estatística conhecida como validação cruzada (*cross-validation*). O método *holdout*, baseado nessa ferramenta, consiste em particionar aleatoriamente os dados de treinamento em dois subconjuntos separados: o primeiro, de estimativa, é usado para selecionar o modelo e o segundo, de validação, é usado para testar ou avaliar o modelo. O objetivo de realizar esse procedimento é validar o modelo em um conjunto de dados diferente daquele usado para estimativa de parâmetros da rede neural. Assim, é possível comparar diferentes modelos e escolher aquele que apresenta melhor desempenho. Para evitar a possibilidade de que este "melhor modelo" possua sobre-ajuste ao subconjunto de validação, a generalização da rede neural é medida no conjunto de teste, distinto do subconjunto de validação.

Em casos nos quais há escassez de amostras para realizar o método descrito, a validação cruzada pode ser feita utilizando o método *multifold*, ou *K-fold*. Ele se baseia na ideia de repetir o treinamento e testar em diferentes subconjuntos ou divisões escolhidos aleatoriamente do conjunto de dados original. Nele, todo o conjunto disponível de treinamento é particionado em K subconjuntos distintos de mesmo tamanho e destes, 1 subconjunto é utilizado para validação e $K - 1$ subconjuntos são utilizados para treinamento. Este procedimento é repetido para um total de K tentativas, cada vez usando um subconjunto diferente para validação. O desempenho do modelo é avaliado pela média do erro sob validação em todas as tentativas.

3 Testes Experimentais

Este trabalho propõe avaliar a eficácia da utilização da textura do padrão *speckle* para aprimorar as classificações de perturbações realizadas por sensores a fibra óptica. Mais especificamente, devido ao aspecto visual granular das imagens do specklegrama, são analisadas as microtexturas por meio de diferentes descritores. Foram escolhidos 7 deles, sendo 2 referentes ao GLCM e 5 referentes ao LBP, relacionados de acordo com a quantidade de características em ordem crescente conforme se observa na Tabela 1.

Tabela 1 – Detalhamento dos descritores avaliados.

Descritor	Operador	Variação	Quantidade de Características
A	GLCM	1 orientação	4
B	LBP^{riu2}	1 bloco	10
C	GLCM	4 orientações	16
D	LBP^{riu2}	4 blocos	40
E	LBP^{u2}	1 bloco	59
F	LBP^{u2}	4 blocos	236
G	LBP^{riu2}	25 blocos	250

Fonte: Próprio Autor

Uma vez que busca-se representar os pequenos grânulos que formam o specklegrama, todos os 5 descritores baseados no LBP possuem 8 pontos de amostragem em um círculo de raio 1 ($LBP_{8,1}$). Desses, 3 deles são invariantes a rotação e 2 são variantes a rotação. A utilização de ambos tipos permite comparar se resultados melhores podem ser obtidos por meio de informações rotacionais do padrão *speckle*, mantidas quando utiliza-se o operador LBP^{u2} .

Com o intuito de captar mais informações de cada imagem, utiliza-se da divisão da imagem em blocos não sobrepostos do mesmo tamanho, semelhante ao desenvolvido por [Chen et al. \(2009\)](#). Nesse sentido, a extração de características de cada um dos blocos gera um histograma e a imagem é representada pela concatenação desses histogramas. Esse particionamento possibilita que, ao diminuir o tamanho do bloco, seja possível obter maior detalhamento local. Tal procedimento foi realizado para os descritores F, relativo ao operador LBP^{u2} , e para os descritores D e G, relativo ao operador LBP^{riu2} . A divisão em 25 blocos realizada no descritor G é justificada pela necessidade em compará-lo ao descritor F, a fim de possuírem quantidades de características similares.

Dentre os descritores baseados na GLCM, o aspecto que varia é a quantidade de orientações entre pixels vizinhos analisados em uma imagem. Em ambos descritores A e C, a distância entre esses pixels é de 1 ($d = 1$). Para o primeiro descritor, apenas

o ângulo $\theta = 0^\circ$ é considerado e, assim, são extraídas 4 propriedades estatísticas da GLCM: homogeneidade, correlação, contraste e energia. Já para o segundo descritor, são considerados, além do ângulo $\theta = 0^\circ$, outras 3 orientações, com ângulos $\theta = 45^\circ, 90^\circ$ e 135° . Para cada uma delas também são extraídas as 4 propriedades estatísticas relacionadas, totalizando as 16 características que representam uma imagem.

Para obtenção dos resultados, os algoritmos de aprendizado de máquina foram implementados computacionalmente em MATLAB e executados em uma máquina com processador Intel Core i5 de 2ª geração operando a 3,3 GHz e memória RAM de 8 GB. Uma rede neural artificial rasa, cujos parâmetros estão apresentados no Quadro 1, é utilizada para realização da classificação das diferentes perturbações. Ela tem 3 camadas, sendo que a camada de entrada possui tantos neurônios quantas características forem apresentadas à rede e a de saída, tantos neurônios quantas classes serão necessárias para a classificação.

Quadro 1 – Parâmetros da rede neural artificial para classificação.

PARÂMETRO	DESCRIÇÃO
Arquitetura	<i>Feedforward</i> (multi-layer perceptron)
Algoritmo de treinamento	Gradiente escalado conjugado
Neurônios na camada intermediária	10
Medida de desempenho	Entropia cruzada
Função de ativação - camada intermediária	Tangente hiperbólica
Função de ativação - camada de saída	Softmax
Taxa de aprendizagem	0,01
Número máximo de épocas	1000
Gradiente mínimo de erro	10^{-6}
Critério de parada	6 aumentos consecutivos no erro

Fonte: Próprio autor.

Para treinar e testar o algoritmo de classificação usando os diferentes conjuntos de dados, empregou-se o método de validação cruzada *K-Fold* com $K=10$. Para cada uma das 10 repetições foi obtida a o valor de acurácia do sub-conjunto e, ao final, a partir da média entre esses valores, é dada a acurácia de todo o conjunto.

A conjectura de que o speckograma possui característica de microtextura suficiente para possibilitar uma classificação da região onde ocorre uma perturbação, de acordo com as características extraídas pelos descritores selecionados, é testada em dois bancos de imagens: o primeiro, cedido por Alberto Rodríguez-Cuevas e o segundo, inédito na literatura, obtido experimentalmente no Laboratório de Telecomunicações - LABTEL - UFES. Informações específicas de cada banco, como dimensão das imagens, número de amostras e detalhes sobre o procedimento de captura, e os resultados obtidos estão presentes nas Seções 3.1 e 3.2.

3.1 Banco de Imagens Cedido

O conjunto utilizado nesta Seção é constituído de imagens já pré-processadas utilizadas anteriormente em (RODRÍGUEZ-CUEVAS et al., 2018). Elas são capturadas a partir de 4 diferentes experimentos. Para todos eles, a configuração utilizada consiste em uma série de suportes serpenteada por uma POF, a qual é acoplada a um laser ($\lambda = 638\text{nm}$) em uma extremidade e a uma câmera CCD em outra. O que os diferencia é o modo como é executada a perturbação e o tipo de POF em que ela é aplicada, podendo ser manuais ou automáticas. Quando automáticas, um batedor conectado a um motor de passo linear, acionado a uma velocidade constante e prefixada, perturba diferentes pontos da fibra. Dois tipos de fibras ópticas foram utilizadas: uma com núcleo de $50\mu\text{m}$ (tipo 1) e outra de $240\mu\text{m}$ (tipo 2).

Para fins de simplificação de análise neste trabalho, os dados foram divididos em grupos (G1, G2, G3, G4), de acordo com a tipo de fibra (50 ou $240\mu\text{m}$) e com o tipo de perturbação (com motor de passo linear ou de forma manual).

A porção da fibra a ser perturbada é de 6 metros e as perturbações podem ocorrer em 2 metros, 4 metros e 6 metros distantes do laser. Assim, são classificados 3 diferentes regiões (classes). O sistema de captura das imagens é projetado de maneira que toda perturbação durasse um pouco menos de $0,33\text{s}$. A câmera empregada opera a 30 quadros por segundos com resolução de 60 por 80 pixels. Assim, a partir de cada perturbação mecânica na fibra, um vídeo colorido de 9 *frames* pode ser gravado. O pré-processamento realizado pelos autores de (RODRÍGUEZ-CUEVAS et al., 2018) foi feito com o intuito de assegurar que as classificações realizadas são decorrentes da mudança do padrão *speckle*. O pré-processamento realizado é representado na Figura 15, cujos detalhes de cada etapa apresentada podem ser aprofundados naquele trabalho.

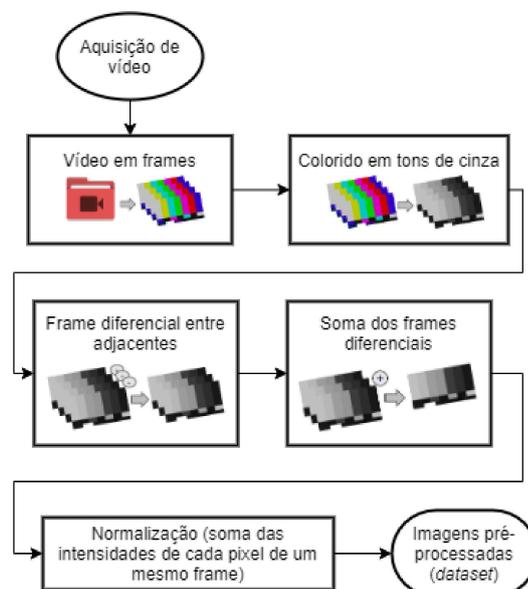


Figura 15 – Fluxograma do pré-processamento das imagens.

Para a fibra tipo 2, as imagens tem a mesma dimensão da captura (60x80), enquanto que para a tipo 1, as imagens cedidas foram recortadas para dimensão 55x58. Tal redução não compromete as análises posteriores, visto que é na porção disponibilizada onde a imagem possui maior detalhe do padrão *speckle*. Assim, é possível verificar nessa região as mudanças microtexturais no padrão de interferência dos modos decorrentes da perturbação mecânica aplicada na fibra.

A Tabela 2 sumariza as informações mencionadas sobre cada grupo e relaciona a quantidade de amostras para cada um deles. São apresentadas na Figura 16 alguns exemplos de cada classe dos diferentes grupos.

Tabela 2 – Quantidade e dimensão das amostras do banco de imagens cedido.

Grupo	Fibra	Perturbação	Dimensão	Amostras	Classes
G1	50 μm	Automática	55x58	149.940	3
G2	50 μm	Manual	55x58	22.728	3
G3	240 μm	Automática	60x80	57.360	3
G4	240 μm	Manual	60x80	19.392	3

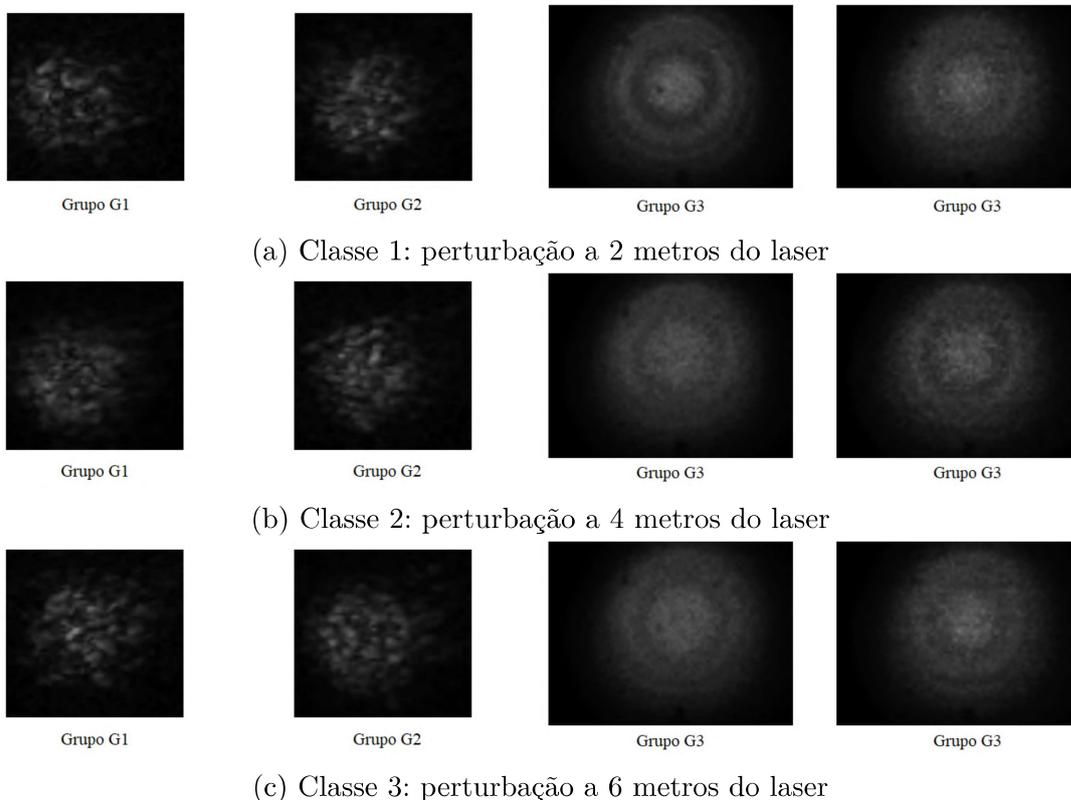


Figura 16 – Exemplos de amostras do padrão *speckle* do banco de imagens cedido.

A fim de avaliar a reprodutibilidade dos resultados obtidos em (RODRÍGUEZ-CUEVAS et al., 2018), é realizado um teste de classificação da perturbação utilizando todos os pixels como entrada da rede neural, ou seja, sem extração de características. Visto

que não se utiliza a mesma semente aleatória para o teste, uma comparação ilustrativa é apresentada na Tabela 3.

Tabela 3 – Acurácia das classificações de padrões *speckle* do banco de imagens cedido sem extração de características.

Grupo	Acurácia Experimental	Acurácia Literatura	Quantidade de Características
G1	99,9%	99,8%	3190
G2	95,5%	79,1%	3190
G3	89,5%	79,1%	4800
G4	93,1%	78,7%	4800

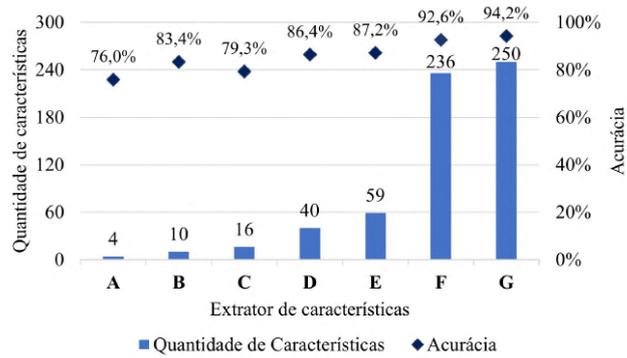
Importante notar que no trabalho utilizado para comparação não foi realizado procedimento de validação cruzada, fazendo com que pudesse ocorrer um sobre-ajuste no conjunto de teste. A diferença nos valores apresentados pode ser decorrente do uso deste procedimento e de uma semente aleatória distinta.

A acurácia obtida para cada um dos grupos é similar ou superior ao apresentado na literatura, denotando que os pixels constituintes das imagens do padrão *speckle* possibilitam, com alta taxa de acerto, a classificação dentre 3 regiões perturbadas em uma fibra óptica. Dessa forma, para responder se características extraídas com base nas texturas das imagens também promovem tais resultados, a rede neural é utilizada para a mesma tarefa de classificação, porém com menos dados de entrada, obtidos por cada um dos 7 descritores avaliados. Na Figura 17 são apresentadas as acurácias resultantes da classificação para cada um dos grupos de imagens.

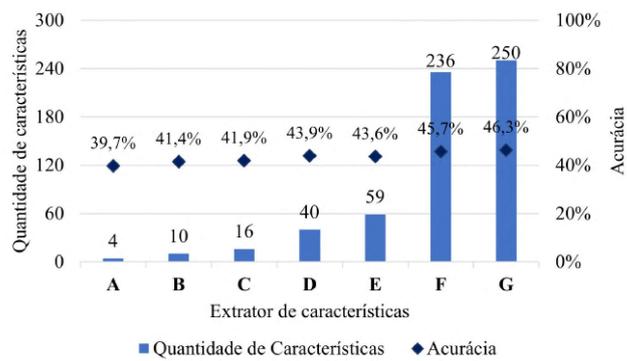
Observa-se que o grupo G1, cujas imagens foram obtidas com perturbação automática na fibra óptica tipo 1 ($50 \mu\text{m}$), foi o único que apresentou classificação dentre as 3 classes de perturbação com acurácia maior que 60%. Para o descritor LBP, essa métrica chegou a 94,15% quando a rede neural utilizou 250 características. Tais características foram extraídas de cada imagem a partir da aplicação do operador LBP invariante a rotação em 25 blocos e a matriz de confusão com o detalhamento das frequências de classificação para cada uma das 3 classes para este grupo está representada na Figura 18.

Nota-se que a Categoria 2 foi aquela que apresentou maior taxa de acerto, ou seja, uma quantidade menor de suas amostras foram classificadas erroneamente como sendo Categoria 1 ou 3. Isso indica que perturbações ocorridas na porção intermediária da fibra são melhores representadas pelas características extraídas do *speckle*.

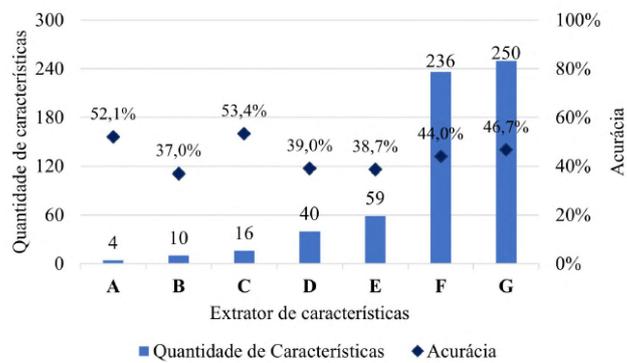
O resultado diferenciado apresentado pelo conjunto de imagens do grupo G1 pode ter diversas razões. A principal delas é a quantidade de amostras utilizadas para treinamento e teste da rede neural. O grupo G1 possui quase 3 vezes mais imagens que o grupo G3, segundo com maior número de amostras, conforme apresentado na Tabela 2. Além disso, são imagens com menor dimensão visto que a região de interesse foi recortada



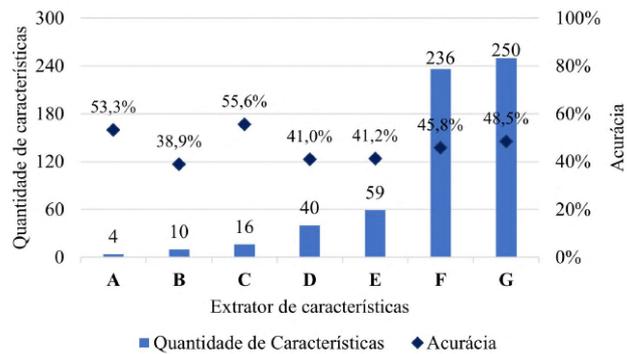
(a) Grupo G1.



(b) Grupo G2.



(c) Grupo G3.



(d) Grupo G4.

Figura 17 – Acurácia das classificações de padrões *speckle* do banco de imagens cedido com extração de características.

Classe Predita	1	46088 30.7%	62 0.0%	3834 2.6%	92.2% 7.8%
	2	75 0.1%	49458 33.0%	519 0.3%	98.8% 1.2%
	3	3817 2.5%	460 0.3%	45627 30.4%	91.4% 8.6%
		92.2% 7.8%	99.0% 1.0%	91.3% 8.7%	94.2% 5.8%
		1	2	3	
		Classe Verdadeira			

Figura 18 – Matriz de confusão resultante da classificação das imagens do grupo G1 com 250 características extraídas pelo operador LBP.

previamente, o que pode auxiliar no processo de extração das características. Pode-se especular também que a perturbação automática possibilita que as mudanças na textura do padrão *speckle* sejam melhor descritas pelos operadores utilizados. Não se deve deixar de levar em consideração os possíveis efeitos causados pelas características ópticas de cada tipo de fibra e pelas configurações da câmera utilizada para captura das imagens. Em comparação com o LBP, o descritor GLCM apresentou menor acurácia: 76,0% para 4 características e 79,3% para 16 características. Além disso, é importante salientar que para a fibra de 240 μm (subgrupos C e D), o uso do descritor GLCM resultou numa acurácia superior ao LBP.

É percebida certa tendência no aumento da acurácia conforme são disponibilizadas a rede neural mais características. Em (RODRÍGUEZ-CUEVAS et al., 2018), foi obtido 96,9% de acurácia para imagens do grupo G1, quando são apresentados 3190 características, que representam todos os pixels de imagens 55×58 , a uma rede neural rasa, sem realização de validação cruzada. Entretanto, isso pode acarretar grande custo computacional, considerando que além do aumento no número de características, uma maior quantidade de amostras também é desejado para melhor taxa de acerto. Nesse sentido, a extração de características se torna uma etapa relevante, tendo em vista as possíveis aplicações deste tipo de sensoriamento.

3.2 Banco de Imagens Inédito

Um novo banco de imagens é gerado a partir de um experimento similar ao apresentado na Seção 3.1. O sistema construído possibilita perturbar uma fibra óptica e

registrar o comportamento do padrão *speckle* para cada uma de 5 perturbações realizadas. Para isso, foram aplicadas deformações com um peso de 100 g em 5 pontos espaçados de 1 m ao longo de uma fibra óptica plástica (POF - *Plastic Optical Fiber*) de 6 m de comprimento. Essa POF caracteriza-se por possuir 980 μm de núcleo e espessura de casca é de 10 μm . Além da fibra e do peso, o sistema desenvolvido conta com um computador de baixo custo do tipo Raspberry Pi 3 Modelo B+ com módulo de câmera de 5MP, baseada em sensor de imagem CMOS e uma fonte de luz coerente. Para a emissão da luz coerente utiliza-se um diodo laser cujo comprimento de onda é 637 nm, que é acoplado a um controlador com intervalo de controle de corrente de 0 a 20 mA.

Foram gravados 5 minutos de vídeo em cada um dos 5 pontos de perturbação distantes 1 metro entre si, a uma taxa de 90 *frames* por segundo e resolução de 640 por 480 pixels. Todos os vídeos foram salvos no formato H.264 e depois convertidos para MP4 no Raspberry Pi. Posteriormente, foram transferidos ao computador onde foi realizado o processamento, que consistiu em realizar a leitura dos vídeos, que compõem um total de 45.015 *frames* e convertê-los em matrizes de tons de cinza. Amostras de cada perturbação/classe antes e depois da conversão são apresentadas na Figura 19. Importante ressaltar que não foi realizado o pré-processamento apresentado na Seção anterior para este banco de imagens, a fim de manter as informações de cada um dos padrões *speckle*.

Observou-se que a inspeção visual da mudança entre diferentes specklegramas é menos dificultosa quando a imagem não é colorida. A partir dos padrões *speckle* em nível de cinza é que são extraídas as características para cada um dos descritores de textura e que ocorre a classificação.

Tabela 4 – Quantidade e dimensão das amostras do banco de imagens inédito.

Fibra	Perturbação	Dimensão	Amostras	Classes
980 μm	Manual	480x640	45.025	5

Após a extração dos vetores de características que representam as amostras do padrão *speckle*, é testado o algoritmo de aprendizado de máquina para cada um dos 7 descritores avaliados (A até G). Na Figura 20 são apresentados os resultados da acurácia obtida após 10 execuções de treinamento e teste da rede neural, segundo o *K-Fold*.

Ao relacionar, neste gráfico, descritores, quantidade de características e acurácia, é possível notar as diferenças entre as distintas abordagens utilizando o LBP e a GLCM. Os descritores baseados na GLCM (A e C) possibilitaram acurácia de 74,8% com 4 características e 81,81% com 16 características, respectivamente. Isso demonstra que os descritores GLCM foram capazes de descrever o padrão *speckle* com uma quantidade de dados de entrada para a rede neural inferior a 4 dos 5 descritores do LBP.

Também entre os descritores baseados no LBP, nota-se que quanto maior a quanti-

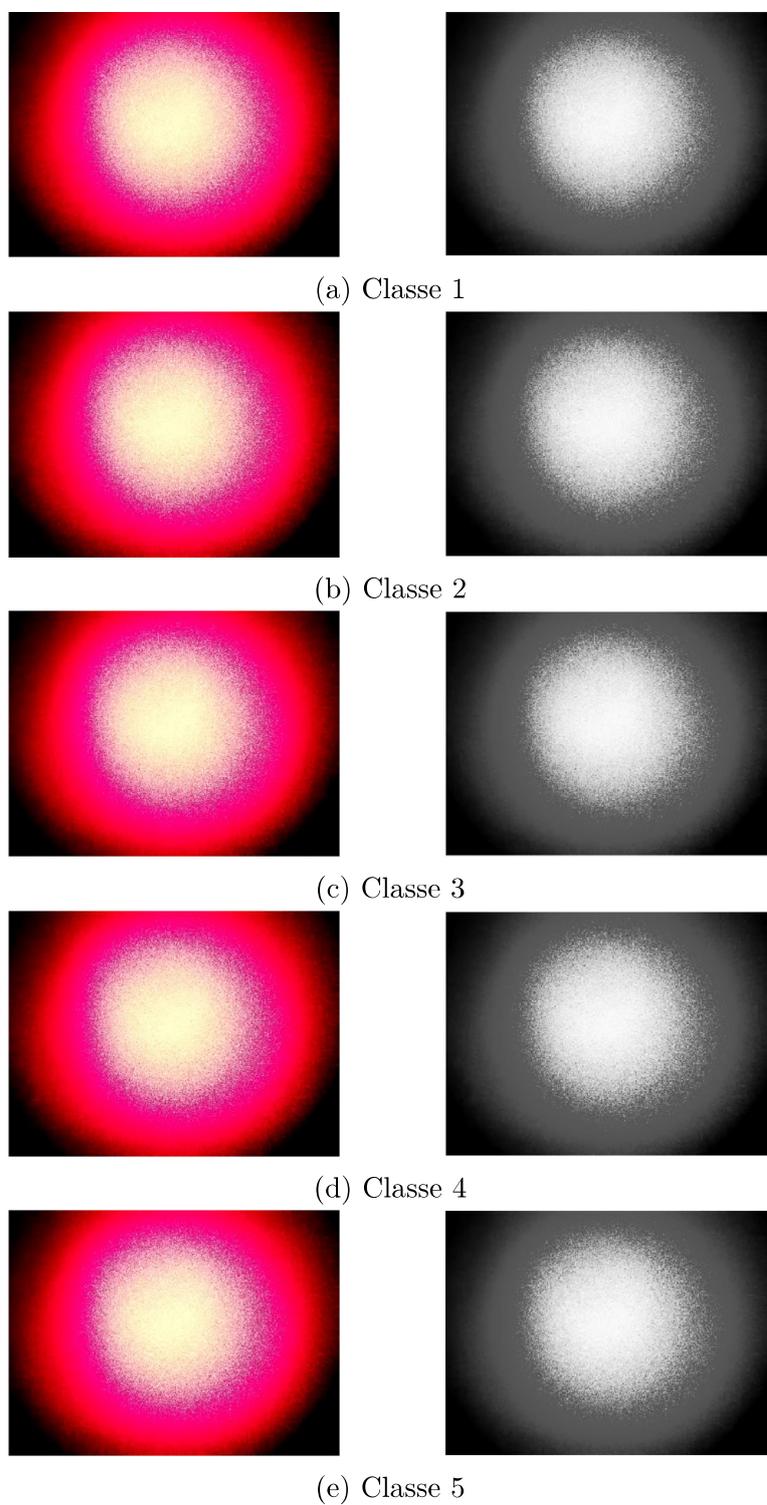


Figura 19 – Exemplos de amostras do padrão *speckle* em RGB (esquerda) e em tons de cinza (direita) do banco de imagens inédito.

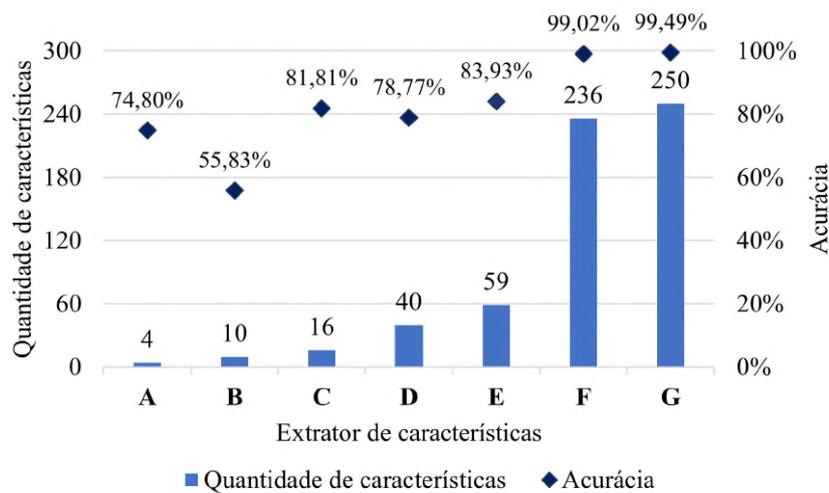


Figura 20 – Acurácia das classificações de padrões *speckle* do banco de imagens inédito.

dade de características, maior a acurácia. Tal fato já era esperado conforme visto ao utilizar todos os pixels do banco de imagens cedido. No entanto, para este experimento, a utilização de todos os 307.200 pixels de cada imagem do banco como entrada da rede neural rasa não se apresenta como uma boa alternativa, considerando a complexidade computacional que isso pode demandar. Por meio do algoritmo de extração de características, é alcançada uma acurácia maior que 99% com até 1.300 vezes menos entradas na rede neural, como no caso do descritor F.

Ao analisar a diferença de desempenho entre os operadores LBP^{riu2} (invariante a rotação) e LBP^{u2} (variante a rotação), é relevante notar que os descritores que não foram divididos em blocos (B para o primeiro tipo e E para o segundo), o conjunto de características extraídas pelo operador variante a rotação possibilitou uma classificação com acurácia 28,1% maior. Entretanto, não se pode afirmar categoricamente que o uso de padrões uniformes variantes a rotação para extração foi a principal causa deste resultado. O próprio aumento do número de características pode ter colaborado para tal, visto que houve um aumento de 22,94% na acurácia com o uso de padrões uniformes invariantes a rotação, como é o caso do descritor D, com 40 características.

De maneira geral, o LBP conseguiu ser eficaz em descrever a textura do padrão *speckle* e possibilitar alta acurácia nas classificações de perturbações realizadas por sensores a fibra óptica. Isso é demonstrado na Matriz de Confusão, apresentada na Tabela 5, obtida a partir da classificação com características extraídas por 25 blocos nos quais foram aplicados o LBP^{riu2} .

Por fim, foi analisado se há benefício em utilizar apenas recortes centralizados no padrão *speckle* das imagens capturadas. Além do impacto na acurácia, foram levantados dados sobre o tempo necessário tanto para leitura dos vídeos e extração de características e como também para treinamento e teste da rede neural. As imagens sofreram redução de

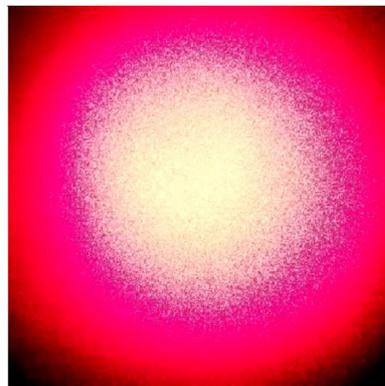
Tabela 5 – Matriz de Confusão resultante da classificação com características extraídas pelo descritor G.

		Predição				
		Classe 1	Classe 2	Classe 3	Classe 4	Classe 5
Real	Classe 1	8975	0	25	2	3
	Classe 2	5	8958	8	29	5
	Classe 3	30	7	8958	5	5
	Classe 4	7	34	7	8938	19
	Classe 5	4	10	7	19	8965

640x480 (integrais) para 480x480 (recortadas), retirando-se as faixas laterais, conforme ilustrado na Figura 21 e os resultados são apresentados nas Tabela 6, 7 e 8.



(a) Antes



(b) Depois

Figura 21 – Exemplo de recorte realizado.

Para leitura e processamento dos vídeos e extração de características, observa-se que a retirada das faixas laterais diminui em todos os casos analisados o tempo para essa tarefa, uma redução de 23,9% em média. Visto que todos os descritores são obtidos a partir de leituras pixel a pixel, o menor tamanho da imagem justifica essa diminuição que pode ser benéfica para se obter mais rapidamente conjuntos de dados para uso no treinamento e teste da rede neural.

Em 6 dos 7 descritores, o emprego de imagens recortadas também facilitou a redução no tempo gasto para treinamento e teste da RNA. Ainda que o tamanho do vetor

Tabela 6 – Comparação em relação a acurácia entre imagens integrais e recortadas.

DESCRITOR	INTEGRAL	RECORTE	Δ
A	74,8%	69,4%	-7,3%
B	55,8%	54,2%	-3,0%
C	81,8%	83,5%	2,0%
D	78,8%	72,1%	-8,5%
E	83,9%	78,4%	-6,6%
F	99,0%	98,3%	-0,7%
G	99,5%	99,3%	-0,2%

Tabela 7 – Comparação em relação a tempo para treinamento e teste da rede neural entre imagens integrais e recortadas, em segundos.

DESCRITOR	INTEGRAL	RECORTE	Δ
A	26,31	18,15	-31,0%
B	19,84	13,25	-33,2%
C	29,41	35,53	20,8%
D	38,57	12,41	-67,8%
E	25,47	14,91	-41,5%
F	20,64	17,07	-17,3%
G	25,32	23,40	-7,6%

Tabela 8 – Comparação em relação a tempo de leitura e extração de características entre imagens integrais e recortadas, em segundos.

DESCRITOR	INTEGRAL	RECORTE	Δ
A	1.293,15	978,88	-24,3%
B	1.439,38	1.091,28	-24,2%
C	4.155,01	3.086,67	-25,7%
D	1.387,87	1.089,12	-21,5%
E	1.415,17	1.091,96	-22,8%
F	1.460,71	1.102,51	-24,5%
G	1.457,84	1.106,73	-24,1%

de características de cada um não seja diminuído na etapa de extração, as diferenças obtidas em relação às imagens sem recorte indicam que as novas características extraídas representam de forma similar as informações texturais do *speckle*.

Por fim, verifica-se que a acurácia não é grandemente afetada pelo recorte das imagens, principalmente quando considera-se os descritores que mantiveram acurácias maiores que 80%, como é o caso de C, F e G, que obtiveram 2,0% ou menos de variação. Isso denota que esses conseguem bem representar o padrão *speckle* mesmo com menor quantidade de pixels na imagem.

Em média, a variação na acurácia foi de -3,5% e o único descritor que apresentou aumento na acurácia foi o C, referente ao GLCM com 4 orientações (16 características). Tal acréscimo está relacionado com aumento no tempo de treinamento e teste para

esse descritor e pode ser decorrente de diversos fatores. Entre eles, estão o aumento na sensibilidade, devido a análise de 4 orientações e não somente 1 como no descritor A, e aliado a isso um aumento na representatividade das frequências de coocorrências de mais altos níveis de cinza. O recorte realizado pode ter feito com que as estatísticas extraídas fossem menos dominada por coocorrências entre baixas níveis de cinza (região mais escura) e pudesse representar melhor a parte central da imagem.

Vale ressaltar que as regiões escuras recortadas da imagem apresentam intensidade maior que zero. Isso pode fazer com que informações além do centro da imagem sejam importantes para a descrição em textura dos outros descritores e, conseqüentemente, para a classificação que os utiliza.

Portanto, tais comparações ilustrativas exemplificam o compromisso entre a quantidade de informações disponibilizadas aos extratores e as métricas de tempo e acurácia obtidas na classificação. Ele se apresenta como um fator importante para o desenvolvimento de aplicações práticas de sensoriamento utilizando um sistema a fibra óptica baseado na textura do specklegrama.

4 Conclusões e Trabalhos Futuros

Este trabalho teve como principal objetivo a exploração de características texturais do padrão *speckle* para desenvolvimento de sensores a fibra óptica. A classificação automática desses padrões de acordo com a posição onde uma perturbação ocorre é um importante caso a ser analisado. Tendo em vista o aspecto granular do specklegrama, conjecturou-se que imagens obtidas a partir de um sistema sensível a essa perturbação teriam um comportamento de microtextura. Dessa forma, foi proposta a utilização de variações do LBP e do GLCM como extratores de características baseados em texturas, constituindo sete diferentes descritores do padrão *speckle*. As informações obtidas foram então utilizadas em uma rede neural artificial para realização da classificação de diferentes perturbações.

Empregou-se tal metodologia a dois bancos de imagens, obtidos a partir da gravação de vídeos do specklegrama quando provocado por diferentes perturbações, sendo um já utilizado na literatura e outro inédito. Avaliou-se a acurácia do sistema em cada um dos bancos e para os diferentes descritores. Foi investigado também o uso de apenas parte da imagem obtida experimentalmente.

O GLCM foi capaz de gerar conjuntos de 4 ou 16 características e possibilitou uma acurácia máxima de 81,8% para o banco de imagens inédito. Tanto para o operador LBP uniforme, LBP^{u2} aplicado em imagens divididas em 4 blocos, quanto o operador LBP uniforme e invariante a rotação, LBP^{riu2} aplicado em imagens divididas em 25 blocos, apresentaram acurácias superiores a 90% quando aplicados a imagens do banco de imagens cedido e ao banco de imagens inédito. Estes geraram 236 e 250 características, respectivamente, que foram capazes de representar specklegrama de forma a possibilitar a classificação adequada pela rede neural da localização onde houve uma perturbação.

A divisão da imagem em diferentes regiões indica que o aspecto textural do padrão *speckle* é melhor quando analisado em detalhe, devido a sua pequena granulosidade. Indica também que quanto maior número de características extraídas pelo LBP, mais satisfatoriamente o padrão *speckle* é descrito. O compromisso entre o tamanho das imagens do specklegrama capturadas, o tamanho do vetor de características e complexidade do algoritmo de aprendizado de máquina é relevante principalmente no que concerne à aplicações práticas reais nas quais há limitações de processamento. A realização de um pré-processamento que consistia no recorte das áreas laterais das imagens do banco de imagens inédito reduziu tanto o tempo de treinamento e teste da rede neural como o tempo para a extração das características, sem grande impacto na acurácia final, na maioria dos casos.

Como sugestão de trabalhos de continuidade desta pesquisa, pode-se indicar outras análises e melhorias que poderiam ser realizadas:

- Aplicação do sistema de classificação em situações dinâmicas, a partir de vídeos contínuos que apresentem a fibra também sem perturbações.
- Utilização de outros descritores de textura, incluindo aqueles que combinem características obtidas diferentes extratores em um mesmo vetor de entrada para o classificador;
- Análise da acurácia da classificação com outros algoritmos de aprendizado de máquina além das redes neurais, como máquinas SVM e *random forest*;
- Avaliação sistematizada da complexidade computacional dos algoritmos propostos.

Referências

- BASAK, K.; MANJUNATHA, M.; DUTTA, P. K. Review of laser speckle-based analysis in medical imaging. *Medical and Biological Engineering and Computing*, v. 50, n. 6, p. 547–558, 2012. ISSN 01400118. Citado na página 25.
- BISHOP, C. M. *Pattern Recognition and Machine Learning*. New York: [s.n.], 2006. ISSN 25228609. ISBN 9780387310732. Citado 2 vezes nas páginas 44 e 45.
- BORHANI, N.; KAKKAVA, E.; MOSER, C.; PSALTIS, D. Learning to see through multimode fibers. *Optica*, v. 5, n. 8, 2018. ISSN 23318422. Citado na página 25.
- CHEN, L.; WANG, Y. H.; WANG, Y. D.; HUANG, D. Face recognition with statistical local binary patterns. *Proceedings of the 2009 International Conference on Machine Learning and Cybernetics*, v. 4, n. February, p. 2433–2439, 2009. Citado na página 51.
- DAS, S.; JENA, U. R. Texture classification using combination of LBP and GLRLM features along with KNN and multiclass SVM classification. *2nd International Conference on Communication, Control and Intelligent Systems, CCIS 2016*, p. 115–119, 2017. Citado na página 30.
- EFENDIOGLU, H. S. A Review of Fiber-Optic Modal Modulated Sensors: Specklegram and Modal Power Distribution Sensing. *IEEE Sensors Journal*, IEEE, v. 17, n. 7, p. 2055–2064, 2017. Citado 2 vezes nas páginas 28 e 30.
- EFENDIOGLU, H. S.; YILDIRIM, T.; TOKER, O. Advanced image processing and artificial intelligence based approaches to fiber optic statistical mode sensor design. *Smart Sensor Phenomena, Technology, Networks, and Systems 2011*, v. 7982, p. 79820T, 2011. ISSN 0277786X. Citado na página 25.
- EFENDIOGLU, H. S.; YILDIRIM, T.; TOKER, O.; FIDANBOYLU, K. Design of intelligent fiber optic statistical mode sensors using novel features and artificial neural networks. *INISTA 2012 - International Symposium on INnovations in Intelligent Systems and Applications*, 2012. Citado na página 25.
- ENNOS, A. E. Speckle Interferometry. In: DAINTY, J. (Ed.). *Laser Speckle and Related Phenomena*. Berlin, Heidelberg: Springer-Verlag Berlin Heidelberg, 1975. cap. 6, p. 203–253. ISBN 978-3-662-43205-1. Citado na página 26.
- FONTANA, M. *Using Machine Learning to Turn Optical Fiber Specklegram Sensor into a Spatially Resolved Sensing System*. Tese (Doutorado) — Università degli Studi di Padova, 2018. Citado 2 vezes nas páginas 25 e 29.
- FUJIWARA, E.; WU, Y. T.; SUZUKI, C. K. Vibration-based specklegram fiber sensor for measurement of properties of liquids. *Optics and Lasers in Engineering*, Elsevier, v. 50, n. 12, p. 1726–1730, 2012. ISSN 01438166. Disponível em: <<http://dx.doi.org/10.1016/j.optlaseng.2012.06.018>>. Citado na página 25.
- GADKARI, D. *Image Quality Analysis Using GLCM*. 1–120 p. Tese (Doutorado) — University of Central Florida, 2004. Citado na página 39.

GONZALEZ, R. C.; WOODS, R. E. *Processamento Digital de Imagens*. 3ª edição. ed. São Paulo: Pearson Prentice Hall, 2010. v. 53. 644 p. ISSN 1098-6596. ISBN 978-85-8143-586-2. Citado na página 33.

GOODFELLOW, I.; YOSHUA, B.; COURVILLE, A. *Deep Learning*. [S.l.]: MIT Press, 2016. Citado na página 44.

GOODMAN, J. Statistical Properties of Laser Speckle Patterns. In: DAINTY, J. C. (Ed.). *Laser Speckle and Related Phenomena*. Berlin, Heidelberg: Springer-Verlag Berlin Heidelberg, 1975. cap. 2, p. 9–75. ISBN 978-3-662-43205-1. Citado na página 26.

GOULD, G. The LASER, light amplification by stimulated emission of radiation. In: FRANKEN, P. A.; SANDS, R. H. (Ed.). *Ann Arbor Conference on Optical Pumping*. [S.l.: s.n.], 1959. p. 128. Citado na página 26.

GRAVES, A. *Supervised Sequence Labelling with Recurrent Neural Networks*. Berlin: Springer-Verlag Berlin Heidelberg, 2012. Citado 2 vezes nas páginas 43 e 44.

HARALICK, R. M.; SHANMUGAN, K.; DINSTEN, I. Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3, n. 3, p. 610–621, 1973. ISSN 19494645. Citado 2 vezes nas páginas 36 e 39.

HAVLICEK, J. P.; HARDING, D. S.; BOVIK, A. C. Multidimensional quasi-eigenfunction approximations and multicomponent AM-FM models. *IEEE Transactions on Image Processing*, v. 9, n. 2, p. 227–242, 2000. ISSN 10577149. Citado na página 28.

HAYKIN, S. *Neural networks and learning machines*. 3rd. ed. New Jersey: Pearson Prentice Hall, 2009. ISBN 978-0-13-147139-9. Citado 4 vezes nas páginas 42, 43, 46 e 49.

HEIKKILÄ, M.; PIETIKÄINEN, M.; HEIKKILÄ, J. A Texture-based Method for Detecting Moving Objects. In: *BMVC*. [S.l.: s.n.], 2004. p. 1–10. Citado na página 34.

JULESZ, B. Textons, the elements of texture perception, and their interactions. *Nature*, v. 290, n. 5802, p. 91–97, 1981. ISSN 00280836. Citado na página 33.

JULESZ, B. A brief outline of the texton theory of human vision. *Trends in Neurosciences*, v. 7, n. 2, p. 41–45, 1984. Citado na página 33.

KHADSE, C. B.; CHAUDHARI, M. A.; BORGHATE, V. B. Electromagnetic Compatibility Estimator Using Scaled Conjugate Gradient Backpropagation Based Artificial Neural Network. *IEEE Transactions on Industrial Informatics*, v. 13, n. 3, p. 1036–1045, 2017. ISSN 15513203. Citado na página 49.

LIU, Y.; HU, Y.; LI, Y.; QIN, Q.; LI, G.; TAN, Z. W.; WANG, M.; YAN, F. P. Image Compression-Encryption Scheme via Fiber Specklegram-Based Compressive Sensing and Double Random Phase Encoding. *IEEE Photonics Journal*, v. 12, n. 4, 2020. ISSN 19430655. Citado na página 25.

LIU, Y.; QIN, Q.; LIU, H. huan; TAN, Z. wei; WANG, M. guang. Investigation of an image processing method of step-index multimode fiber specklegram and its application on lateral displacement sensing. *Optical Fiber Technology*, v. 46, n. June, p. 48–53, 2018. ISSN 10685200. Citado na página 41.

- MARCEL, S.; RODRIGUEZ, Y.; HEUSCH, G. On the Recent Use of Local Binary Patterns for Face Authentication. *International Journal on Image and Video Processing Special Issue on Facial Image Processing*, p. 1–9, 2007. Citado na página 34.
- MATAR, G.; LINA, J. M.; KADDOUM, G. Artificial Neural Network for in-Bed Posture Classification Using Bed-Sheet Pressure Sensors. *IEEE Journal of Biomedical and Health Informatics*, IEEE, v. 24, n. 1, p. 101–110, 2020. ISSN 21682208. Citado na página 49.
- MCCULLOCH, W.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, v. 5, p. 115–133, 1943. ISSN 21945357. Citado na página 42.
- MØLLER, M. F. A scaled conjugate gradient algorithm for fast supervised learning. *Neural Networks*, v. 6, n. 4, p. 525–533, 1993. ISSN 08936080. Citado 2 vezes nas páginas 46 e 47.
- OJALA, T.; PIETIKÄINEN, M.; HARWOOD, D. A comparative study of texture measures with classification based on feature distributions. *Pattern Recognition*, v. 29, n. 1, p. 51–59, 1996. ISSN 00313203. Citado na página 34.
- OJALA, T.; PIETIKÄINEN, M.; MÄENPÄÄ, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 24, n. 7, p. 971–987, 2002. ISSN 01628828. Citado na página 35.
- PEDRINI, H.; SCHWARTZ, W. R. *Análise de imagens digitais: princípios, algoritmos e aplicações*. [S.l.]: Thomson Learning Edições Ltda., 2007. 528 p. ISBN 978-85-221-0595-3. Citado na página 38.
- PIETIKÄINEN, M.; HADID, A.; ZHAO, G.; AHONEN, T. Local Binary Patterns for Still Images. In: *Computer Vision Using Local Binary Patterns*. 1. ed. Springer-Verlag London, 2011. cap. 2, p. 13–47. ISBN 9780857297488. Disponível em: <<https://www.springer.com/br/book/9780857297471>>. Citado 2 vezes nas páginas 35 e 36.
- PINO, A. O.; PLADELLORENS, J.; COLOM, J. F. Method of measure of roughness of paper based in the analysis of the texture of speckle pattern. *Speckle 2010: Optical Metrology*, v. 7387, n. Figure 1, p. 73871W, 2010. ISSN 0277786X. Citado na página 30.
- PLÖSCHNER, M.; TYC, T.; ČIŽMÁR, T. Seeing through chaos in multimode fibres. *Nature Photonics*, v. 9, n. 8, p. 529–535, 2015. ISSN 17494893. Citado na página 28.
- RAZMYAR, S.; MOSTAFAVI, M. T. Deep Learning for Estimating Deflection Direction of a Multimode Fiber from Specklegram. *Journal of Lightwave Technology*, v. 39, n. 6, p. 1850–1857, 2021. ISSN 15582213. Citado na página 25.
- RODRIGUEZ-COBO, L.; LOMER, M.; GALINDEZ, C.; LOPEZ-HIGUERA, J. M. POF vibration sensor based on speckle pattern changes. *OFS2012 22nd International Conference on Optical Fiber Sensors*, v. 8421, p. 84212Y–84212Y–4, 2012. ISSN 0277786X. Citado na página 26.
- RODRIGUEZ-COBO, L.; LOMER, M.; LOPEZ-HIGUERA, J. M. Fiber Specklegram Multiplexed Sensor. *Journal of Lightwave Technology*, v. 33, n. 12, p. 2591 – 2597, 2014. Citado na página 27.

RODRÍGUEZ-CUEVAS, A.; FONTANA, M.; RODRÍGUEZ-COBO, L.; LOMER, M.; LOPEZ-HIGUERA, J. M. Machine Learning for Turning Optical Fiber Specklegram Sensor into a Spatially-Resolved Sensing System. Proof of Concept. *Journal of Lightwave Technology*, v. 36, n. 17, p. 3733–3738, 2018. ISSN 07338724. Citado 4 vezes nas páginas 30, 53, 54 e 57.

SCHIEZARO, M. *Seleção de Características Baseada no Algoritmo de Colônia Artificial de Abelhas*. 65 p. Tese (Dissertação de Mestrado) — Universidade Estadual de Campinas, 2014. Disponível em: <http://repositorio.unicamp.br/bitstream/REPOSIP/275568/1/Schiezaro_Mauricio_M.pdf>. Citado na página 25.

SCHWARTZ, W. R.; SIQUEIRA, F. R. de; PEDRINI, H. Evaluation of feature descriptors for texture classification. *Journal of Electronic Imaging*, v. 21, n. 2, p. 023016, 2012. ISSN 1017-9909. Citado na página 33.

SPILLMAN, W. B.; KLINE, B. R.; MAURICE, L. B.; FUHR, P. L. Statistical-mode sensor for fiber optic vibration sensing uses. *Applied Optics*, v. 28, n. 15, p. 3166, 1989. ISSN 0003-6935. Citado na página 26.

VENTURA, V. D. A. *Representação de Imagens Através de Grafos Utilizando o Algoritmo Split-And-Merge Combinado Com Descritores de Cor e Textura*. 123 p. Tese (MSc) — Universidade Federal do Espírito Santo, 2009. Citado na página 33.

YU, F. T. S. Fiber specklegram sensing by means of an adaptive joint transform correlator. *Optical Engineering*, v. 32, n. 11, p. 2884, 1993. ISSN 00913286. Citado na página 28.

YU, F. T. S.; WEN, M.; YIN, S.; UANG, C.-M. Submicrometer displacement sensing using inner-product multimode fiber speckle fields. *Applied Optics*, v. 32, n. 25, p. 4685, 1993. ISSN 0003-6935. Citado 2 vezes nas páginas 29 e 30.