

Extração de características de padrões *speckle* para sensores a fibra óptica

Ingrid A. Reis * Evandro O. T. Salles * Anselmo Frizera *

* Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Espírito Santo, ES, (e-mail: ingridandrareis@gmail.com, evandro.salles@ufes.br e frizera@ieee.org).

Abstract: This work presents a classification system, based on texture features extracted from the speckle pattern, to determine 3 different regions in which an optical fiber is mechanically perturbed. Two different descriptors are used: the Local Binary Pattern (LBP) and the Gray Level Co-occurrence Matrix (GLCM) for extracting characteristics, which are applied to an Artificial Neural Network. Accuracy was analyzed for seven different characteristic amounts. The results show that, for an optical fiber of 50 μm automatically disturbed, both descriptors were able to classify the location of the deformation, reaching 94.2% accuracy with 236 features extracted with LBP and 79.3% accuracy with 16 features extracted with GLCM.

Resumo: Neste trabalho é apresentado um sistema de classificação, baseado na extração de características de texturas de padrões *speckle*, para determinação de 3 regiões em que uma fibra óptica é perturbada mecanicamente. São utilizados dois diferentes descritores de textura, o *Local Binary Pattern* (LBP) e a *Gray Level Co-occurrence Matrix* (GLCM) para extração de características, as quais são empregadas em uma Rede Neural Artificial *feedforward*. A acurácia foi analisada para sete diferentes quantidades de características. Os resultados mostram que, para uma fibra óptica de 50 μm perturbada de forma automática, ambos descritores foram capazes de classificar a localização da deformação, alcançando 94,2% de acurácia com 236 características extraídas com LBP e 79,3% de acurácia com 16 características extraídas com GLCM.

Keywords: Feature Extraction; Texture Analysis; Speckle; LBP; GLCM; Machine Learning; Neural Network

Palavras-chaves: Extração de características; Análise de Textura; *Speckle*; LBP; GLCM; Aprendizado de Máquina; Redes Neurais

1. INTRODUÇÃO

O sensoriamento é de grande relevância para uma ampla gama de processos, considerando que decisões são tomadas com base em seus resultados. A utilização de fibras ópticas tem sido crescente e importante no desenvolvimento de sensores para diversas aplicações, como robótica, processos industriais e medicina (Leal-Junior et al., 2018). Elas são capazes de compor sistemas que medem múltiplas propriedades físicas, entre elas temperatura, tensão e deslocamento e se diferenciam de outros elementos por serem flexíveis, terem baixo custo e resistência a interferência eletromagnética (Zawawi et al., 2013).

A maneira como o conteúdo dos feixes de luz é propagado na fibra óptica caracteriza o tipo de sensor. Para aplicações que envolvem a detecção de vibração, em particular, a utilização dos fenômenos de interferência se destaca ao prover propriedades relevantes (Rodríguez-Cuevas et al., 2018). Nesse sentido, os sensores de fibra baseados em specklegrama (FSSs - *Fiber Optic Specklegram Sensors*) apresentam notável sensibilidade e podem ser aplicados, por exemplo, para medição de frequência cardíaca de pacientes e de movimento sem contato (Rodríguez-Cuevas et al., 2017).

Os FSSs exploram a modificação dos padrões de manchas (*speckles*) resultantes da contribuição de todas as interferências entre os modos de propagação na fibra óptica. Essa interação aleatória é um efeito indesejado em transmissão de dados visto que é conhecido como um ruído modal em sistemas de comunicação óptica. No entanto, como as características espaço-temporais do padrão *speckle* são afetadas pelas condições de propagação da luz, a sua mudança pode ser correlacionada com a mudanças no ambiente externo, possibilitando obter um sistema com alta confiabilidade (Leal-Junior et al., 2018). Além disso, o specklegrama pode ser capturado por um sistema simples composto por um laser e uma câmera, tornando os FSSs sensores com baixa complexidade e baixo custo.

Dessa forma, diversas pesquisas têm sido desenvolvidas para o processamento das imagens capturadas. Autores como Yu et al. (1993); Fujiwara et al. (2017); Li et al. (2019); Feng et al. (2018) quantificaram a diferença entre os padrões *speckle* por meio do coeficiente normalizado do produto interno (NIPC - *Normalized inner-product coefficient*). Ainda que apresentassem bons resultados, melhorias na precisão foram obtidas por Efendioglu et al. (2011) ao lançar mão de atributos estatísticos, chamados de momentos de primeira e segunda ordem, aplicados a uma Rede Neural Artificial (RNA).

Por possuírem a habilidade de generalização de dados ruidosos e incompletos, a utilização de RNAs pode ser útil ao se analisar specklegramas. Entretanto, determinar quais devem ser as informações de entrada para esse algoritmo de aprendizado de máquina ainda é um desafio. O alto custo computacional decorrente da necessidade de grande volume de dados pode limitar o desenvolvimento de aplicações práticas.

Assim, a extração de características se apresenta como abordagem promissora para redução da complexidade computacional e para o aumento do desempenho da rede neural. Por representar um padrão de manchas granulares, extrair do specklegrama informações sobre seu aspecto de textura pode produzir classificações com alta acurácia Dash et al. (2015).

O presente trabalho busca apresentar uma metodologia capaz de classificar onde uma perturbação ocorreu em uma fibra óptica, baseada em características de textura do padrão *speckle*. Para extração delas, utilizou-se os descritores *Local Binary Pattern* (LBP) e *Gray Level Co-occurrence Matrix* (GLCM), cujos vetores resultantes foram aplicados a uma RNA *feedforward*.

O restante deste artigo está organizado em outras quatro seções. Na seção 2, são descritas as técnicas utilizadas na pesquisa e o banco de imagens. A seção 3 descreve a metodologia desenvolvida e a aplicação dos algoritmos. Os resultados obtidos são apresentados e discutidos na seção 4. Por fim, na seção 5 são emitidas as considerações finais desta pesquisa.

2. MATERIAIS E MÉTODOS

São apresentados nesta seção o banco de imagens, os métodos para extração e classificação utilizados, bem como seus fundamentos teóricos.

2.1 Banco de Imagens

O conjunto de imagens analisado neste artigo foi gentilmente cedido pelos autores de (Rodríguez-Cuevas et al., 2018) e consiste em uma versão modificada daquele presente em seu trabalho.

A configuração utilizada para a captura das imagens consistia em uma fibra óptica plástica que serpenteava fileiras de suportes fixados a uma mesa e que era acoplada a um laser em uma extremidade e a uma câmera CCD em outra. A porção da fibra a ser perturbada é de 6 metros e as perturbações ocorreram em 3 diferentes locais, a 2 metros, a 4 metros e a 6 metros de distância do laser. Além disso, foram aplicadas distintas formas de perturbação: uma manual e uma automática. Nesta última foi utilizado um batedor conectado a um motor de passo linear, que por sua vez era acionado a uma velocidade constante e prefixada, em diferentes pontos da fibra. Um computador era utilizado para realizar o controle do motor, do laser e da câmera.

Os testes foram realizados usando-se 2 tipos diferentes de fibra: uma POF com núcleo de 50 μm (tipo 1) e outra de 240 μm (tipo 2). Ambas foram iluminadas por um laser de comprimento de onda $\lambda = 638 \text{ nm}$.

Cada perturbação feita no sistema durava pouco menos de 0,33 s. A câmera empregada opera a 30 quadros por segundos ajustada para resolução de 60 por 80 pixels. Assim, para cada perturbação mecânica na fibra, um vídeo colorido de 9 *frames* foi gravado.

As imagens cedidas já haviam sido pré-processadas. Esse pré-processamento consistiu em converter para o nível de cinza cada um dos *frames*, subtrair os valores de intensidade entre *frames* subjacentes e formar apenas 1 imagem com a soma e normalização dos 8 *frames* resultantes. Isso foi feito de forma a assegurar que as classificações realizadas seriam decorrentes da mudança do padrão *speckle*.

Sendo assim, o banco de imagens foi composto conforme apresentado na Tabela 1.

Tabela 1. Quantidade e dimensão das amostras do banco de imagens.

Subgrupo	Fibra	Perturbação	Dimensão	Amostras
A	50 μm	Automática	55x58	149.940
B	50 μm	Manual	55x58	22.728
C	240 μm	Automática	60x80	57.360
D	240 μm	Manual	60x80	19.392

As imagens foram categorizadas em subgrupos (A, B, C e D), de acordo com a tipo de fibra (50 ou 240 μm) e com o tipo de perturbação (automática ou manual).

São exemplificadas amostras de diferentes categorias de cada um dos subgrupos na Figura 1. A categoria 1 se refere à perturbação realizada a 2 metros, a categoria 2, a 4 metros e a categoria 3, a 6 metros de distância do laser.




Figura 1. Exemplos de amostras dos subgrupos.

As imagens do subgrupo C e D são as mesmas utilizadas em (Rodríguez-Cuevas et al., 2018), com dimensão de 60 por 80 pixels, enquanto que as do subgrupo A e B foram cedidas imagens recortadas, com dimensão 55 por 58 pixels. Tendo em vista que o recorte disponibilizado é a região na qual a imagem possui maior enfoque no padrão *speckle*, a redução na dimensão não compromete as análises realizadas. Elas, inclusive, podem auxiliar o processo de verificação das mudanças microtexturais devido a perturbação aplicada à fibra óptica.

2.2 Descritores de Textura

Nesta pesquisa, é realizada uma análise comparativa de duas técnicas de extração de características baseadas em textura: *Local Binary Pattern* (LBP) e a *Gray Level Co-occurrence Matrix* (GLCM). Esses e outros descritores contribuem para o processo de reconhecimento de padrões realizado na classificação, visto que representam de forma mais compacta uma imagem por meio de um vetor de características (Gonzalez and Woods, 2010). Cada um a seu modo busca descrever quais atributos destacam melhor as propriedades de uma imagem, como cor, forma e textura.

As texturas fornecem importantes informações sobre a como a tonalidade de uma imagem é distribuída ao longo do espaço, possibilitando uma impressão visual mais rugosa ou mais suave, por exemplo (Schwartz et al., 2012). Quando se busca descrever texturas baseando-se na estimação da distribuição local do nível de cinza dos pixels, é utilizada a abordagem estatística da textura, cujos representantes são LBP e GLCM.

O LBP é um método proposto por Ojala et al. (1996), no qual a estrutura local de uma imagem é resumida a partir de uma avaliação dos níveis de cinza dos pixels circundantes a um pixel central. Ele é notável pelo alto poder discriminativo e pouca complexidade computacional (Marcel et al., 2007).

O vetor de características extraídas pelo LBP corresponde ao histograma que representa a distribuição de frequência dos valores resultantes da aplicação do operador LBP a todos os pixels da imagem. Ojala et al. (2002) propõem um operador invariante a rotação e uniforme (*rotation invariant and uniform*), descrito como

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

sendo

$$s(x) = \begin{cases} 1 & \text{se } x \geq 0 \\ 0 & x < 0 \end{cases} \quad (2)$$

e

$$U(LBP_{P,R}) = |s(g_{P-1} - g_c) - s(g_0 - g_c)| + \sum_{p=1}^{P-1} |s(g_p - g_c) - s(g_{p-1} - g_c)|, \quad (3)$$

que leva em consideração uma vizinhança (P, R) de um pixel central com coordenadas x_c e y_c , em que P representa a quantidade de pontos de amostragem em um raio R . Ademais, g_p e g_c indicam a intensidade de nível de cinza de um dado pixel analisado na vizinhança e a intensidade de nível de cinza do pixel central, respectivamente.

O operador $LBP_{P,R}^{riu2}$ utiliza os chamados padrões uniformes para quantizar com maior detalhe o espaço angular e para medir a uniformidade U . Um padrão é dito uniforme se, após a aplicação da função $s(x)$, há 2 ou menos transições 0/1 ou 1/0 entre bits no conjunto da vizinhança. Padrões uniformes chegam a representar 90% dos padrões de textura (Ojala et al., 2002). Assim, a invariância a rotação é conseguida por meio de um mapeamento no qual há um rótulo para cada padrão uniforme e atribui-se os

não-uniformes a um único rótulo, conforme ilustrado na Figura 2. Na figura, pequenos círculos pretos equivalem a 1 e pequenos círculos brancos equivalem a 0.




Figura 2. Mapeamento do padrões uniformes referentes a 8 pontos de amostragem, sendo pontos de variantes a rotação (esquerda) para invariantes a rotação (direita).

Dessa forma, um padrão obtido após análise de 8 pontos de amostragem na vizinhança ($P=8$) pode ser mapeado ou para um dos 58 rótulos uniformes apresentados no lado esquerdo da Figura 2, ou é mapeado para 1 único padrão que representa todos os padrões não-uniformes. Assim, totalizam-se 59 possíveis rótulos quando não há invariância a rotação.

Quando tal propriedade é desejada, os rótulos que se diferenciam entre si apenas pela rotação são agrupados e mapeados para apenas 9 rótulos uniformes, representados no lado direito da Figura 2, e 1 rótulo para padrões não-uniformes, totalizando 10 possíveis rótulos.

Por isso, tem-se, ao final do processo de extração das características do LBP um vetor de características com 10 posições - caso invariante a rotação - e 59 posições - caso variante a rotação -, cada uma referente a distribuição da frequência de cada um dos rótulos numa imagem.

Por sua vez, com a GLCM, o vetor de características é composto por medidas estatísticas extraídas da sua matriz. Cada elemento (m, n) da matriz de coocorrência representa a probabilidade de que o nível de cinza m esteja espacialmente relacionado com o nível de cinza n , de acordo com os parâmetros de distância d e o ângulo θ entre pixels. Ou seja, para cada imagem de entrada I , de dimensões $M \times N$, e contendo M_c níveis de cinza, gera-se uma matriz de co-ocorrência de dimensões $M_c \times M_c$, aqui denominada por $F(m, n)$. Geralmente, trabalha-se com a matriz $f(m, n)$, normalizada segundo

$$f(m, n) = \frac{F(m, n)}{\sum_{i=0}^{M_c} \sum_{j=0}^{M_c} F(i, j)} \quad \text{para } m, n = 0, \dots, M_c - 1. \quad (4)$$

na qual $F(m, n)$ é a frequência de transições entre cada par de níveis de cinza na m -ésima linha e n -ésima coluna da malha de pixels.

Em Haralick et al. (1973) são propostas 14 medidas estatísticas que são originadas a partir da análise da matriz GLCM. Tendo em vista que algumas possuem correlações

entre si, diminuindo a capacidade de discriminação, é utilizado em aplicações práticas um conjunto com apenas algumas dessas medidas.

As medidas estatísticas de Homogeneidade e Contraste foram utilizadas por Liu et al. (2018) para sensoriamento de deslocamento lateral baseado no specklegrama e apresentaram resultados melhores que abordagens baseadas em variação da intensidade. A Homogeneidade mede a proximidade da distribuição dos elementos à diagonal da matriz de coocorrência e varia de 0 a 1. Quanto maior for frequência de ocorrência de um determinado nível de cinza, maior será a uniformidade local e maior o valor da Homogeneidade. Já o Contraste mede as variações locais de intensidade de um pixel relacionado a sua vizinhança. Dessa forma, ele é zero quando não há variação, ou seja, toda a imagem é composta por apenas um nível de cinza.

Também são utilizadas neste trabalho as medidas de Energia e Correlação. A Energia é capaz de representar o nível total de intensidade de uma imagem, alcançando seu valor máximo (igual a 1) quando a imagem possui o mesmo nível de cinza em todos os pixels. A Correlação mede o quão previsível, por meio de uma regressão linear dos valores dos pixels vizinhos, é o nível de cinza de um pixel e seus valores variam de -1 a 1. Para imagens constantes, a correlação é indefinida, visto que o desvio padrão entre os pixels é zero.

Portanto, tem-se, ao final do processo de extração das características com a GLCM um vetor de características com 4 posições referentes as medidas estatísticas de Contraste, Correlação, Energia e Homogeneidade.

3. METODOLOGIA

Para identificar a região onde ocorreu uma perturbação em uma fibra óptica, a partir de um banco de imagens já existente, são necessárias as etapas de extração de características, com os descritores LBP e GLCM, e de classificação, com a rede neural.

As texturas das imagens do padrão *speckle* são descritas por vetores de características de diferentes tamanhos.

Baseando-se na conjectura de que o specklegrama possui característica de microtextura, analisar vizinhanças menores possibilitaria representar com maior detalhamento o padrão *speckle*. Em razão disso, utiliza-se um descritor LBP com oito pixels de amostragem ($P=8$) e raio unitário ($R=1$). Para avaliar o impacto do mapeamento realizado para a invariância a rotação do operador, são analisados tanto com invariância a rotação (10 características) quanto sem invariância a rotação (59 características).

Para aumentar tanto o detalhamento local da análise da imagem quanto o tamanho do vetor de características, o LBP também é aplicado tanto às imagens inteiras quanto em blocos não sobrepostos do mesmo tamanho. Dessa maneira, são calculados histogramas, de 10 ou 59 características, para cada região da imagem e ao final esses histogramas são concatenados (Chen et al., 2009).

Além das imagens inteiras, cada uma é analisada em blocos. Para análise do LBP com invariância a rotação, ao particionar em 4 blocos, cada um contribuirá com 10 características, totalizando 40 características, e em 25

blocos, será formado um vetor de características com 250 características. Já para a análise sem invariância a rotação, por apresentar um número maior de características para cada bloco, cada imagem foi particionada em apenas 4 blocos, totalizando 236 características.

Para análise com base na GLCM, escolheu-se como parâmetro de distância $d=1$, refletindo a conjectura de microtexturas, e variou-se os ângulos adotados, a fim de investigar mais pixels de uma mesma vizinhança. Assim, foram formados dois conjuntos: um para apenas $\theta=0^\circ$, com 4 características, e outro $\theta = 0^\circ, 45^\circ, 90^\circ$ e 135° , totalizando 16 características.

Os bancos de características formados pelo processo de extração com LBP e GLCM são então utilizados no modelo de aprendizado de máquina, 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. O algoritmo é uma rede neural artificial com arquitetura *feed-forward*, com 3 camadas, tendo a camada intermediária 10 neurônios e a de saída com 3 neurônios (3 tipos de perturbação). Sua configuração apresenta função de ativação tangente hiperbólica para as camadas intermediárias e softmax para a de saída, algoritmo de treinamento com gradiente conjugado escalado e função de custo calculada pela entropia cruzada.

Empregou-se o método de validação cruzada *K-Fold* com $K=10$ (Rodríguez et al., 2010). Para cada um, a taxa de aprendizagem foi de 0,01 com um máximo de 1000 épocas e gradiente mínimo de erro de 10^{-6} . O critério de parada do segmento de validação consistiu em 6 iterações consecutivas nas quais houvesse crescimento do erro.

As métricas obtidas ao final dos treinamentos e testes foram o tempo de execução e a acurácia média das 10 repetições do método *K-Fold*. Em cada execução, a taxa de acurácia (AC) é calculada a partir da matriz de confusão. A matriz de confusão apresenta os valores de Verdadeiro Positivo (VP), Verdadeiro Negativo (VN), Falso Positivo (FP) e Falso Negativo (FN). VP representa a quantidade de amostras que o modelo classifica corretamente como uma localização, ou seja, uma categoria de interesse (1, 2 ou 3, neste caso), VN é a quantidade de amostras que o modelo classifica corretamente como não sendo de uma categoria de interesse, FP é a quantidade de amostras que o modelo classifica incorretamente a localização da perturbação e FN é a quantidade de amostras classificadas incorretamente como não sendo de uma categoria de interesse. Os valores de VN, FP e FN serão a soma das amostras classificadas como das outras duas categorias que não a de interesse. Dessa forma a acurácia é dada por:

$$AC = \frac{VP + VN}{VP + VP + FP + FN}, \quad (5)$$

4. RESULTADOS

Nas Figuras 3, 4, 5 e 6 são apresentadas os resultados referentes a acurácia média entre as 10 execuções de treinamento e teste da rede neural, segundo o *10-Fold*. Nelas, é possível verificar o impacto da quantidade de características e dos diferentes descritores na taxa de acerto do classificador.




Figura 3. Acurácia - Subgrupo A.




Figura 4. Acurácia - Subgrupo B.




Figura 5. Acurácia - Subgrupo C.




Figura 6. Acurácia - Subgrupo D.

Observa-se que o subgrupo A, cujas imagens foram obtidas com perturbação automática na fibra óptica tipo 1 (50 μ m), foi o que apresentou maior acurácia. Com uso do LBP, essa métrica chegou a 94,2% 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 categorias para este subgrupo está representada na Figura 7.

Nota-se que, a Categoria 2 foi a que apresentou maior taxa de acerto, ou seja, uma quantidade menor de suas amostras

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%
		Classe Verdadeira			

Figura 7. Matriz de confusão resultante da classificação das imagens do subgrupo A com 250 características extraídas pelo operador LBP (classes balanceadas).

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 Subgrupo A pode ter diversas razões. A principal delas é a quantidade de amostras utilizadas para treinamento e teste da rede neural. O subgrupo A possui quase 3 vezes mais imagens que o subgrupo C, segundo com maior número de amostras, conforme apresentado na Tabela 1. Além disso, são imagens com menor dimensão visto que a região de interesse foi recortada 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 μ m (subgrupos C e D), o uso do descritor GLCM resultou numa acurácia superior ao LBP. No entanto, ela não ultrapassa 55,6%, o que denota uma maior capacidade do GLCM em representar a textura do padrão *speckle*, mas uma limitação da rede neural projetada em realizar a classificação.

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 subgrupo A, quando são apresentados 3190 características, que representam todos os pixels de imagens 55 $\times$ 58, a uma rede neural rasa, sem realização de validação cruzada. Entretanto, isso pode acarretar grande custo computacional, considerando que além do aumento do número de características, o grande número 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.

5. CONCLUSÃO

Neste trabalho, apresentou-se uma metodologia de identificação de padrão *speckle* empregando-se uma abordagem

por aprendizado de máquina. Para tanto, utilizou-se um banco de dados de perturbações causadas em uma fibra óptica. Nesse banco, cada perturbação produziu um padrão *speckle* específico na qual conjecturou-se que a imagem obtida tem comportamento de uma microtextura. Para avaliar essa conjectura, empregou-se 2 típicos extratores de características de texturas: LBP e GLCM. As características foram usadas para treinar uma rede neural rasa, da qual avaliou-se a acurácia do sistema em diferentes cenários.

Os resultados demonstraram que, para uma perturbação automática realizada em uma fibra de 50 μm , a textura do specklegrama possibilita bons resultados na classificação. Para esse caso, verificou-se que o descritor LBP invariante a rotação teve resultado superior ao GLCM e que as melhores taxas foram obtidas quando as imagens foram divididas em 25 regiões.

Para trabalhos futuros pretende-se analisar o padrão *speckle* com outros descritores e investigar o desempenho da classificação também em outros algoritmos de aprendizado de máquina além das redes neurais artificiais.

AGRADECIMENTOS

Os autores agradecem a equipe do pesquisador Alberto Rodríguez-Cuevas por ceder seu banco de imagens utilizado neste trabalho.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, da Fundação de Amparo a Pesquisa do Espírito Santo (FAPES) - Processo 84336650 e do CNPq - Processo 304049/2019-0.

REFERÊNCIAS

- Chen, L., Wang, Y.H., Wang, Y.D., and Huang, D. (2009). Face recognition with statistical local binary patterns. *Proceedings of the 2009 International Conference on Machine Learning and Cybernetics*, 4(February), 2433–2439. doi:10.1109/ICMLC.2009.5212189.
- Dash, S., Chiranjeevi, K., Jena, U.R., and Trinadh, A. (2015). Comparative study of image texture classification techniques. *International Conference on Electrical, Electronics, Signals, Communication and Optimization*.
- Efendioglu, H.S., Yildirim, T., and Toker, O. (2011). Advanced image processing and artificial intelligence based approaches to fiber optic statistical mode sensor design. *Smart Sensor Phenomena, Technology, Networks, and Systems 2011*, 7982, 79820T. doi:10.1117/12.880054.
- Feng, F., Chen, W., Chen, D., Lin, W., and Chen, S.C. (2018). In-situ ultrasensitive label-free DNA hybridization detection using optical fiber specklegram. *Sensors and Actuators, B: Chemical*. doi:10.1016/j.snb.2018.05.099.
- Fujiwara, E., Wu, Y.T., Santos, M.F., Schenkel, E.A., and Suzuki, C.K. (2017). Optical Fiber Specklegram Sensor for Measurement of Force Myography Signals. *IEEE Sensors Journal*. doi:10.1109/JSEN.2016.2638831.
- Gonzalez, R.C. and Woods, R.E. (2010). *Processamento Digital de Imagens*. Pearson Prentice Hall, São Paulo, 3ª edição.
- Haralick, R.M., Shanmugan, K., and Dinstein, I. (1973). Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3(3), 610–621. doi:10.1109/TSMC.1973.4309314.
- Leal-Junior, A.G., Marques, C., Frizzera, A., and Pontes, M.J. (2018). Multi-interface level in oil tanks and applications of optical fiber sensors. *Optical Fiber Technology*, 40(October 2017), 82–92. doi:10.1016/j.yofte.2017.11.006. URL <https://doi.org/10.1016/j.yofte.2017.11.006>.
- Li, D., Liu, X., Liang, Y., Fan, J., and Wang, L. (2019). A Low-Cost Portable Nanophotonic Sensor Based on a Smartphone: A System Readily Available for Many Applications. *IEEE Nanotechnology Magazine*, 13(3), 6–12. doi:10.1109/MNANO.2019.2904774.
- Liu, Y., Qin, Q., Liu, H.h., Tan, Z.w., and Wang, M.g. (2018). Investigation of an image processing method of step-index multimode fiber specklegram and its application on lateral displacement sensing. *Optical Fiber Technology*, 46(June), 48–53. doi:10.1016/j.yofte.2018.09.007.
- Marcel, S., Rodriguez, Y., and Heusch, G. (2007). On the Recent Use of Local Binary Patterns for Face Authentication. *International Journal on Image and Video Processing Special Issue on Facial Image Processing*, 1–9. doi:10.1.1.330.2492.
- Ojala, T., Pietikäinen, M., and Harwood, D. (1996). A comparative study of texture measures with classification based on feature distributions. *Pattern Recognition*, 29(1), 51–59. doi:10.1016/0031-3203(95)00067-4.
- Ojala, T., Pietikäinen, M., and Mäenpää, T. (2002). Multi-resolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(7), 971–987. doi:10.1109/TPAMI.2002.1017623.
- Rodríguez, J.D., Pérez, A., and Lozano, J.A. (2010). Sensitivity Analysis of k-Fold Cross Validation in Prediction Error Estimation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 32(3), 569–575. doi:10.1109/TPAMI.2009.187.
- Rodríguez-Cuevas, A., Fontana, M., Rodríguez-Cobo, L., Lomer, M., and Lopez-Higuera, J.M. (2018). Machine Learning for Turning Optical Fiber Specklegram Sensor into a Spatially-Resolved Sensing System. Proof of Concept. *Journal of Lightwave Technology*, 36(17), 3733–3738. doi:10.1109/JLT.2018.2850801.
- Rodríguez-Cuevas, A., Peña, E.R., Rodríguez-Cobo, L., Lomer, M., and Higuera, J.M.L. (2017). Low-cost fiber specklegram sensor for noncontact continuous patient monitoring. *Journal of Biomedical Optics*, 22(3), 037001. doi:10.1117/1.jbo.22.3.037001.
- Schwartz, W.R., Siqueira, F.R.d., and Pedrini, H. (2012). Evaluation of feature descriptors for texture classification. *Journal of Electronic Imaging*, 21(2), 023016. doi:10.1117/1.jei.21.2.023016.
- Yu, F.T.S., Wen, M., Yin, S., and Uang, C.M. (1993). Sub-micrometer displacement sensing using inner-product multimode fiber speckle fields. *Applied Optics*, 32(25), 4685. doi:10.1364/ao.32.004685.
- Zawawi, M.A., O’Keffe, S., and Lewis, E. (2013). Intensity-modulated fiber optic sensor for health monitoring applications: A comparative review. *Sensor Review*, 33(1), 57–67. doi:10.1108/02602281311294351.