

PROCESSAMENTO DE SENSORES DE FIBER SPECKLE UTILIZANDO ALGORITMOS DE APRENDIZADO DE MÁQUINA

Palavras-Chave: SENSOR DE FIBRA ÓPTICA, SPECKLE, CLASSIFICAÇÃO DE IMAGENS.

Autores:

Vinícius Garcia Balbino, FEM – Unicamp (Aluno)

Prof. Dr. Eric Fujiwara, DSI/FEM - Unicamp (Orientador)

INTRODUÇÃO:

O trabalho trata sobre sensores de fibra óptica baseado em ruído modal, ou seja, sensores que analisam as interferências de ondas eletromagnéticas causadas por perturbação pelo meio externo. A saída captada desses sensores são imagens denominadas specklegrams que variam dependendo do tipo e da intensidade da perturbação externa. Assim, o trabalho tem como objetivo realizar um estudo da análise dos speckles via redes neurais convolucionais (CNN), de modo a classificar as imagens dos sensores e correlacioná-las à variável física ou química a ser mensurada.

METODOLOGIA:

Inicialmente, foi construído um banco de imagens (frames) de experimentos utilizando fibra óptica multimodo (MMF), fibras “no-core” e guias de onda estruturados com diferentes geometrias e dimensões de núcleo/casca e diferentes estímulos físicos aplicados à fibra (Figura 1). As imagens utilizadas são de experimentos previamente realizados já publicados em artigos científicos.

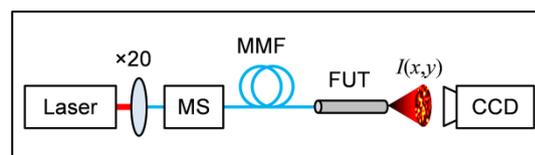


Figura 1 - Montagem experimental de um sensor de fibra óptica, formado por laser de He-Ne (633 nm), lentes objetivas, misturador de modos (MS), fibra multimodo (MMF), fibra sensora (FUT) e câmera CCD. O specklegram $I(x,y)$ é formado na saída da MMF

O vídeo adquirido através do experimento é dividido em frames gerando variações de imagens speckle. As imagens adquiridas são convertidas para escala de cinza, normalizadas, e então reduzidas para otimização de espaço. O banco de dados será expandido através de métodos de “aumentação” (por exemplo, aplicando transformações geométricas e inserindo ruído) com intuito de introduzir variabilidade estatística sobre os conjuntos experimentais e conferir robustez. Essas técnicas são comumente aplicadas em problemas de desenvolvimento e treinamento de redes neurais convolucionais.

As imagens foram separadas aleatoriamente entre conjuntos de treinamento, validação e teste. Na etapa de treinamento, são avaliadas as configurações das camadas da rede bem como do método de otimização e critérios de parada de modo a obter o desempenho desejado para a classificação. Posteriormente, a rede foi validada e testada para conjuntos de dados desconhecidos, permitindo recuperar o valor do estímulo aplicado sobre a fibra.

A rede neural de classificação de imagens speckle foi desenvolvida com a API Keras utilizando a base pré-treinada da arquitetura VGG-16. Keras é uma biblioteca Python de código aberto de redes neurais para realizar o processo de classificação de imagens. Foi escolhida a biblioteca Keras devido à extensa documentação disponível na internet e por ser uma API completa, com muitos recursos e ter uma programação intuitiva ao usuário. Além de ser muito empregada por programadores e desenvolvedores.

RESULTADOS E DISCUSSÃO:

Os objetivos do projeto são estudar as imagens de saída de sensores de fibra óptica multimodo e construir de um banco de imagens para classificação de speckles, desenvolver modelos de rede neural convolucional para a classificação dos speckles, de modo a quantificar os estímulos aplicados sobre a fibra e analisar quantitativamente os algoritmos propostos neste projeto frente às outras técnicas reportadas na literatura.

Inicialmente no projeto, foi utilizado um vídeo do specklegram da fibra óptica. A luz emitida por laser de He-Ne (663~nm) incide sobre uma caneca de porcelana, gerando um padrão de speckles devido à interferência da luz na superfície. O sinal refletido é adquirido por uma câmera CCD sem lente e salvo em um arquivo de vídeo. É possível variar a massa do objeto depositando volumes de líquido no interior da caneca, o que resulta em alterações espaciais na distribuição dos speckles.

A partir desse vídeo queremos identificar os padrões do speckle para cada volume presente no recipiente e via redes neurais convolucionais (CNN) classificar as imagens pelo volume. foi feita a divisão do vídeo em frames e através da biblioteca OpenCV (cv2) do Python obtendo um banco de imagens de 3118 frames.

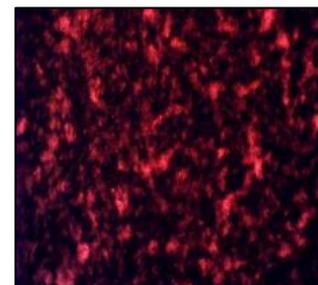


Figura 2 - Frame 1 (100 mL)

Utilizando o frame 1 como referência foi construído um gráfico Intensidade e Correlação por frame. No gráfico Intensidade e Correlação por frame representado na Figura \ref{fig:graficolxCxF}, podemos identificar os patamares nos quais a correlação permanece aproximadamente constante, ou seja, nesses pontos o volume presente no recipiente permanece constante. Também, há regiões nas quais há a variação da correlação, isso indica que houve uma adição ou subtração no volume. A Tabela \ref{tab:dados_volume_horizontal} indica o volume e sua variação utilizados no experimento.

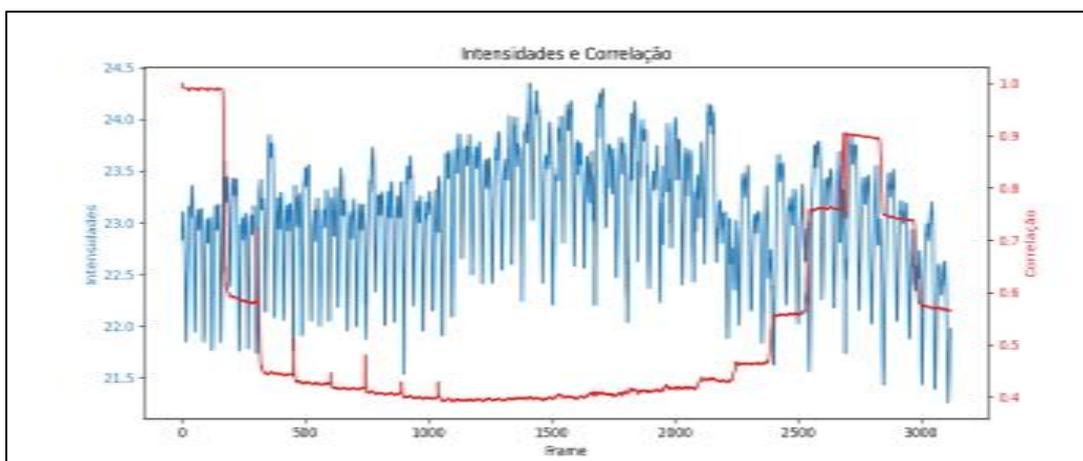


Figura 3 - Gráfico Intensidade e Correlação por frame.

Para treinar, validar e testar a rede neural convolucional para esse experimento, criou-se um banco de imagens (803 imagens) classificadas pelo volume (100mL G100, 150mL G150, 200mL G200, 220mL G220, 240mL G240, 260mL G260, 280mL G280, 300mL G300). Para o treinamento dessas 8 classes foi utilizado 90% dos dados, o restante foi utilizado para validação e testes durante a compilação da rede neural. As imagens também foram reduzidas para o tamanho 224x224, padrão do modelo VGG-16. Para melhorar a performance do aprendizado da rede foi aplicado técnicas de aumento de dados - translação na altura e largura, rotação, zoom - utilizando a classe ImageDataGenerator da biblioteca Keras/TensorFlow.

O código de treinamento de classificação de imagens utiliza a rede neural pré-treinada VGG-16. Primeiro, ele carrega e processa imagens de um diretório, separando-as em conjuntos de treinamento, validação e teste. As imagens são aumentadas usando técnicas de transformação, como deslocamento, zoom, cisalhamento e rotação, para melhorar a generalização do modelo. Em seguida, as imagens são normalizadas e as etiquetas são convertidas em uma codificação one-hot. A rede VGG-16, que já foi treinada com dados do ImageNet, é utilizada como base, com suas camadas congeladas e uma camada densa adicional é adicionada para a classificação multiclasse. O modelo é compilado com o otimizador Adam e a função de perda de entropia cruzada categórica, treinado com os dados de treinamento e validação, e finalmente salvo em um arquivo .keras.

Após compilar o modelo criado obteve-se uma exatidão (accuracy) de 0.8906, um valor satisfatório mesmo com os empecilhos do banco de imagens reduzido.

A matriz de confusão da Figura 4 apresenta os resultados da rede neural desenvolvida. Foi inserido 40 imagens de cada classe no modelo e verificou-se a classe com maior probabilidade e plotamos no eixo vertical os Grupos Verdadeiros e no eixo horizontal os Grupos Previstos pela rede neural. Quanto mais denso os dados na diagonal

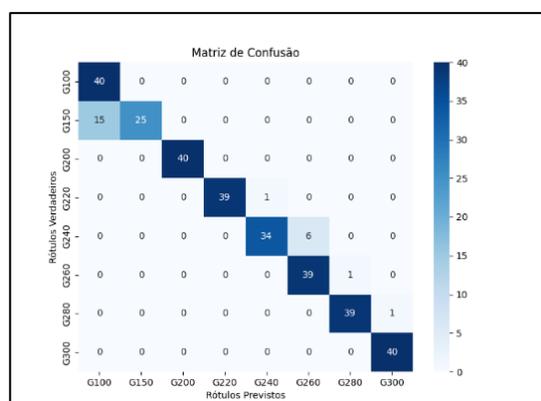


Figura 4 - Matriz de confusão do modelo de rede neural para classificação de imagens de fiber speckle

principal da matriz, melhor é o modelo criado.

CONCLUSÕES:

Foi abordado o desenvolvimento e a aplicação de técnicas de aprendizado de máquina, especificamente redes neurais convolucionais (CNN), para a análise e classificação de imagens de speckle obtidas de sensores de fibra óptica. A pesquisa demonstrou a viabilidade do uso dessas técnicas para identificar e correlacionar padrões de speckle com variáveis físicas, como o volume de líquido em um recipiente. Apesar das limitações encontradas, como o tamanho reduzido do banco de dados de imagens, os resultados obtidos foram promissores.

BIBLIOGRAFIA

E. Fujiwara, J. A. Fracarolli, C. M. B. Cordeiro. **“Didactic laser speckle experiments with a lensless camera”**. Eur. J. Physics, vol. 42, 065303 (2021).

E. Fujiwara, Y. Ri, Y. T. Wu, H. Fujimoto, C. K. Suzuki. **“Evaluation of image matching techniques for optical fiber specklegram sensor analysis”**. Appl. Opt., vol. 57, 9845-9854 (2018).

K. Simonyan, A. Zisserman et al. **“Very deep convolutional networks for large-scale image recognition”**, Disponível em: <https://arxiv.org/abs/1409.1556>. Acesso em: 9 de março de 2024.

Documentation. Keras: Deep Learning for humans. Disponível em: <https://keras.io/>. Acesso em: 8 de março de 2024.

Y. Fu, C. Aldrich. **“Using convolutional neural networks to develop state-of-the-art flotation froth image sensors”**. IFAC-PapersOnLine, vol. 51, pp. 152-157 (2018).