

REDES NEURAIS CONVOLUCIONAIS APLICADAS EM MONITORAMENTO DE PEÇAS METÁLICAS

JULIO H. L. ALMEIDA*, LUIS A. R. LOPES*, JORGE L. M. AMARAL†, MARCO A. B. SILVA†

*Laboratório de Redes Industriais e Sistemas de Automação (LARISA), *Programa de Pós-Graduação em Engenharia Eletrônica (PEL), †Departamento de Eletrônica e Telecomunicações (DETEL), Universidade do Estado do Rio de Janeiro*

R. São Francisco Xavier, 524 - Maracanã, Rio de Janeiro - RJ, 20550-900

E-mails: jh.juliohenrique@gmail.com, luisantonio_eng@yahoo.com.br, jamaral@uerj.br, marcoground@gmail.com

Abstract— This work presents an intelligent structural monitoring system of metallic parts. It consists of two steps: the first one is a non-destructive test using electromechanical impedance and the second one, an impedance curve is classified by a deep learning algorithm, Convolutional Neural Networks. The experiments were performed using two different ways of handling on the input vector: keep it one-dimensional and convert it into a two-dimensional array. The electromechanical impedance test was performed by using a PZT transducer coupled with 1020 carbon steel plates, which simulate turbine blades. Unlike the related works, the fixation was non-permanent with aid of a custom-made support with springs, instead of the common method, which consists on a permanent fixation of the sensor, with a high-strength adhesive. The purpose of this study is to identify the mechanical condition of the steel plates from the electrical impedance curves extracted from PZT transducer. The Convolutional Neural networks were compared with the classifiers k-nearest neighbors, support vector machine, logistic regression and submitted competitive results. In this work, electric impedance curves formed by 50000 points was used, and even with this high dimensionality, the Convolutional Neural Networks reached high accuracy, showing the great potential of this algorithm to work with vectors of high dimensionality.

Keywords— Deep learning, Gas turbine blades, Health Structure monitoring, Electromechanical impedance, Intelligent systems.

Resumo— Este trabalho apresenta um sistema inteligente de monitoramento estrutural de peças metálicas. Ele consiste de duas etapas: na primeira realiza-se um ensaio não destrutivo utilizando-se impedância eletromecânica e na segunda, a curva de impedância é classificada por um algoritmo de aprendizagem profunda, Redes Neurais Convolucionais, as quais foram executadas utilizando duas formas diferentes de tratamento do vetor de entrada, que são: mantê-lo unidimensional e convertê-lo em uma matriz bidimensional quadrada. O ensaio de impedância eletromecânica foi realizado através da fixação de um transdutor PZT em chapas de aço carbono 1020, que simulam palhetas de turbina. Diferentemente dos trabalhos relacionados, a fixação foi feita de modo não permanente utilizando um suporte com molas, ao invés do método comum, que consiste na fixação permanente do sensor, através da colagem com um adesivo de alta resistência. O objetivo deste trabalho é identificar a condição mecânica das chapas de aço a partir das curvas de impedância elétrica extraídas do transdutor PZT. As Redes Neurais Convolucionais foram comparadas com os classificadores k-vizinhos mais próximos, máquina de vetores de suporte, regressão logística, e apresentaram resultados competitivos. Neste trabalho foi utilizado curvas de impedância elétrica formadas por 50000 pontos, e mesmo com essa alta dimensionalidade, as Redes Neurais Convolucionais alcançaram altas acurácias, mostrando o grande potencial deste algoritmo em trabalhar com vetores de dimensionalidade elevada.

Palavras-chave— Aprendizagem Profunda, Palhetas de Turbinas a gás, Monitoramento de estruturas, Impedância eletromecânica, Sistemas inteligentes.

1 Introdução

Em diversas construções dentro da Engenharia Mecânica, Civil e Aeronáutica, deve ser dada uma especial atenção ao monitoramento de estruturas, pois quando há uma ocorrência de alguma falha estrutural, a mesma pode acarretar em altos prejuízos materiais ou até mesmo a perda de vidas humanas, como por exemplo: A queda do viaduto “Batalha do Guararapes” em Belo Horizonte (Em.com.br, 2017) o desabamento da arquibancada, que causou 7 mortes (Gazeta do Povo, 2016) e também na área aeronáutica, o acidente com a aeronave *aloha airlines* (Farrar, et al., 2005), que teve sua fuselagem separada durante um voo. Estes exemplos demonstram o quanto é importante a utilização e desenvolvimento de processos que realizam a monitoração das condições mecânicas da estrutura, de tal forma que seja possível evitar falhas catastróficas.

Para solução deste tipo de problema, pode ser aplicado um sistema de Monitoramento da Integridade

Estrutural (SHM – do inglês *Structure Health Monitoring*), que é definido em (Farrar, et al., 2005) como o processo de detecção de dano em estruturas dentro da Engenharia Civil, Mecânica e Aeronáutica. A utilização de SHM permite identificar o atual estado em termos de integridade da estrutura monitorada, através de ferramentas estatísticas aplicadas nas informações extraídas periodicamente por sensores acoplados na mesma.

Dentro das possibilidades, onde pode ser aplicado sistemas de SHM, tem-se o problema de monitoramento das condições estruturais de palhetas de turbinas a gás, as quais tratam-se de componentes de máquinas, que operam em alta rotação sob elevada temperatura e pressão, por conta disso alguns ocasionais danos podem ocorrer nas palhetas, como por exemplo: O dobramento da ponta da palheta devido ao roçamento com a carcaça da máquina, trincas devido à alta sollicitação mecânica durante a operação da turbina, remoção de material e deformação da superfície devido ao impacto por objeto estranho (Sobrinho, 2013). O monitoramento

deste componente é importante, pois a eficiência da turbina é dependente das suas condições estruturais, além disso por conta da alta exigência mecânica sofrida pelas palhetas, os danos presentes podem se propagar a ponto de culminar em uma falha, que exija a parada da máquina, resultando em prejuízos significativos.

Normalmente as palhetas são monitoradas através de uma inspeção ocular, onde o inspetor utiliza um instrumento conhecido como videoscópio para visualizar a palheta no interior da máquina (Sobrinho, 2013), este método de inspeção possui alguns problemas, pois é suscetível a erros, já que depende da visualização do dano na palheta pelo inspetor, sendo que o mesmo pode ter dimensões pequenas ou até mesmo estar em uma posição de difícil acesso, além disso este processo de inspeção depende da mão de obra qualificada do inspetor, o que aumenta o custo para ser realizado.

Diante dos problemas existentes na forma atual de inspecionar palhetas, sugere-se a utilização do Método de Impedância Eletromecânica (EMI – do inglês *Electromechanical Impedance Method*), que é um método de avaliação não destrutivo, o qual utiliza sensores piezoelétricos para monitorar a integridade estrutural de um determinado componente (Sun, et al., 1995). O EMI funciona acoplado o sensor piezoelétrico na estrutura, sendo que após o acoplamento, a impedância elétrica do sensor torna-se dependente da impedância mecânica da mesma. Portanto, se a impedância mecânica variar com a ocorrência de danos, a impedância elétrica do sensor acoplado também variará (Sun, et al., 1995). Este método monitora a integridade da estrutura através da avaliação das curvas de impedância elétrica, de um sensor piezoelétrico acoplado na mesma. Geralmente é aplicado métricas estatísticas que quantificam a dissimilaridade entre as curvas de impedância elétrica de um sensor acoplado em uma estrutura sem danos (comumente chamado de *baseline*), com as curvas de um acoplado na estrutura monitorada (Baptista, et al., 2011) (Baptista, 2010) (Palomino, 2008) (Sun, et al., 1995) (Franco, 2009) (Bhalla, et al., 2009) (Finzi, et al., 2010) assim quanto maior a dissimilaridade entre as curvas, maior é a probabilidade de haver danos na estrutura monitorada.

Uma outra opção para realizar a análise das curvas de impedância elétrica é utilizar classificadores do campo de aprendizado de máquinas (Lopes, 2013), pois ao levantar uma base de dados de curvas, onde cada curva está atrelada a uma classe referente a um tipo de dano, a tarefa de monitoramento de estruturas pode ser tratada como um problema de classificação.

Dentro de aprendizado de máquinas existe um conjunto de técnicas, que está em destaque por alcançar resultados satisfatórios em diferentes tipos de problemas, que são as técnicas de *Deep Learning*.

Estas técnicas possuem como vantagem a extração de atributos de forma automática, diferentemente das técnicas convencionais de Aprendizado de Máquinas, os algoritmos de *Deep Learning* durante o treinamento aprendem quais são

os atributos mais relevantes para identificar a classe que a amostra pertence, por conta disso além de alcançarem altos níveis de acurácia, os mesmos conseguem trabalhar melhor com vetores de entrada de dimensões elevadas, pois na extração de atributos o tamanho da entrada é reduzido.

Em função dos resultados satisfatórios que a Rede Neural Convolutiva (Ketkar, 2017) apresentou em diferentes trabalhos (Atha and Jahanshahi, 2017) (Zhang, et al., 2016) (Krizhevsky, et al., 2012) (Zeiler and Fergus, 2013) (Szegedy, et al., 2014) (Simonyan and Zisserman, 2015) (He, et al., 2015), a mesma foi escolhida para classificar as curvas de impedância elétrica oriundas da aplicação do EMI. A Rede Neural Convolutiva é bastante aplicada para classificação de imagens, devido ao seu bom desempenho em tarefas deste tipo, em função disso é investigado a possibilidade de converter a curva de impedância elétrica em uma matriz quadrada para ser a entrada da Rede Neural Convolutiva, desta forma o problema se torna uma tarefa de classificação de imagens, visto que uma imagem pode ser modelada por uma matriz bidimensional. E para avaliar se há benefícios em realizar esta conversão, esta Rede é comparada com uma Rede Neural Convolutiva, que recebe como entrada a curva de impedância elétrica unidimensional.

As Redes Neurais Convolutivas foram comparadas com os classificadores tradicionais: Máquina de vetores de suporte (SVM, do inglês *support vector machine*), utilizando o kernel RBF (do inglês, *radial basis function*), k-vizinhos mais próximos (KNN, do inglês *k-nearest neighbors*) e Regressão Logística (RL) (Shwartz and David, 2014).

Este artigo está organizado da seguinte forma: Seção 1 é a introdução, que contempla a motivação, justificativa e objetivo, além de realizar uma explicação sucinta de conceitos dentro da área de SHM, EMI e *Deep Learning*. Na seção 2 será explicado de forma sucinta o funcionamento da Rede Neural Convolutiva. A seção 3 abordará os trabalhos relacionados. Na seção 4 será apresentado o modelo proposto para o monitoramento estrutural de peças metálicas. A seção 5 descreverá como foi realizado o processo experimental para levantar a base de dados. A seção 6 apresentará os resultados obtidos e discussões, e a seção 7 contempla as conclusões deste trabalho.

2 Redes Neurais Convolutivas

Rede Neural Convolutiva é um algoritmo bastante utilizado para classificação de imagens e tem contribuído significativamente no desenvolvimento na área de *Deep Learning*.

A principal diferença entre uma Rede Neural Convolutiva e uma Rede Neural Perceptron Múltiplas Camadas (neste trabalho será chamada de Rede Neural Convolutiva) é que a Rede Neural Convolutiva possui uma etapa de extração de características, que processa diferentes características

do dado de entrada para depois utilizá-las como entrada de uma Rede Neural Convencional.

A etapa de extração de características é composta por camadas de convolução, que aplicam um conjunto de convoluções na imagem de entrada, resultando em um número de imagens igual ao número de filtros (também conhecido como máscara, do inglês *kernel*). Uma outra camada importante é a camada de agrupamento (do inglês, *pooling*), a qual tem como função reduzir o tamanho da imagem de entrada, aplicando funções de maneira análoga a uma convolução. Normalmente estas funções incluem o cálculo da média da região que o filtro está sobrepondo ou a obtenção do máximo, e então, posteriormente, o resultado da aplicação destas camadas é utilizado como entrada para uma Rede Neural Convencional.

A Figura 1 ilustra a arquitetura utilizada nas Redes Neurais Convolucionais propostas e em quais camadas as funções de ativação: *ReLU* (do inglês *rectified linear unit*), *Softmax* e Tangente Hiperbólica (Ketkar, 2017) foram utilizadas.

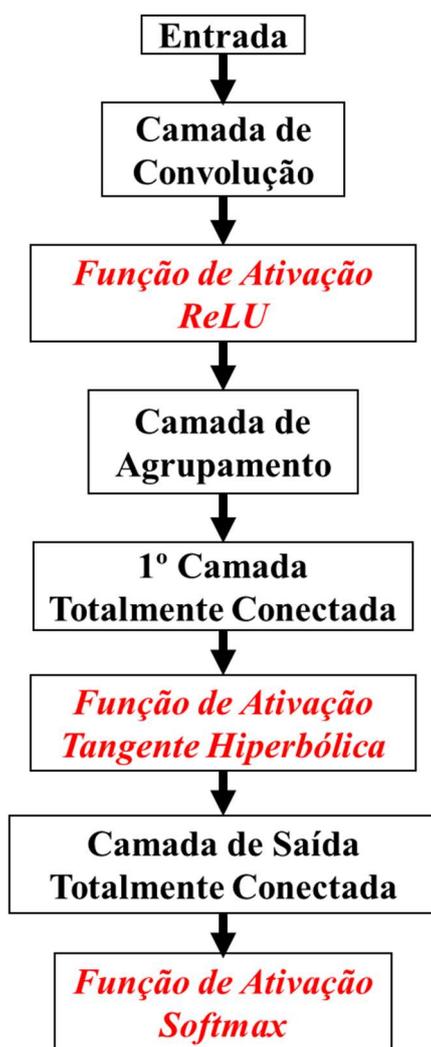


Figura 1. Arquitetura das Redes Neurais Convolucionais.

3 Trabalhos Relacionados

Foi realizado uma pesquisa bibliográfica sobre aplicações de técnicas de *Deep Learning* em SHM, com intuito de verificar a performance destas técnicas neste tipo de problema. Os parágrafos abaixo descrevem as aplicações encontradas de *Deep Learning* em SHM.

Quando se trata de aeronaves, realizar o monitoramento da estrutura é uma tarefa complexa devido às condições incertas de operação que estas são sujeitas, como por exemplo temperatura, pressão e umidade, assim, devido a estes fatores, a estrutura da asa de uma aeronave pode sofrer problemas mecânicos como por exemplo corrosão e trinca, e quando não detectados a tempo, estes se desenvolvem gradativamente até culminar em uma falha catastrófica, então em (Tamilselvan, et al., 2012) foi proposto um sistema de sensoriamento em conjunto com um classificador, o qual é denominado como *Deep Belief Network* para realizar o monitoramento constante da estrutura da asa da aeronave. Pode-se citar como exemplo também de estrutura bem solicitada mecanicamente, as pontes, pois sofrem esforços com a ação do vento e do constante tráfego de carros, então em (Guo, et al., 2014) é elaborado um sistema que conta com a utilização de uma rede wireless de sensores composta por acelerômetros acoplados na estrutura para monitoramento em tempo real. Em (Guo, et al., 2014) a classificação da condição estrutural é baseada nas informações extraídas pelos sensores, e é realizada por uma Rede Neural, a qual utiliza uma técnica de *Deep Learning* chamada de *Sparse Coding* para extração automática de atributos do vetor de entrada. Em (Xuejun and Yan, 2017), também foi desenvolvido um sistema para monitorar as condições estruturais de uma ponte, porém foi utilizado a técnica *Deep Belief Network* para detectar trincas através de imagens. A corrosão também é um fator que influencia negativamente nas propriedades mecânicas da estrutura, assim sendo possível o monitoramento da integridade estrutural por parte desta, então com esta finalidade foi desenvolvido o trabalho (Atha and Jahanshahi, 2017), o qual utiliza Redes Neurais Convolucionais para a classificação de imagens de regiões como corroídas ou não. Também aplicando Redes Neurais Convolucionais, é proposto em (Zhang, et al., 2016) um detector de trincas para ser utilizado em estradas. A Rede proposta em (Zhang, et al., 2016) tem como entrada, imagens de partes da estrada capturadas por um *smartphone* de baixo custo.

Uma característica comum nos trabalhos mencionados anteriormente, é que as técnicas de *Deep Learning* obtiveram uma boa performance, atingindo níveis de acurácia em torno de 90%, o que é um bom indicativo de que algoritmos de *Deep Learning* funcionam bem em tarefas de SHM.

Dentre os classificadores mencionados, o classificador, Rede Neural Convencional (Ketkar, 2017), chamou bastante atenção, pois obteve bom desempenho em SHM nos trabalhos mencionados

anteriormente. Além disso, este classificador em tarefas complexas de classificação de imagens consegue alcançar altos níveis de acurácia, como por exemplo, as Redes Neurais Convolucionais utilizadas no desafio *ImageNet Large Scale Visual Recognition Competition* (ILSVRC) (IMAGENET, 2016), que são: AlexNet (Krizhevsky, et al., 2012), a qual foi desenvolvida por Alex Krizhevsky, Ilya Sutskever e Geoff Hinton e popularizou as Redes Neurais Convolucionais por ter alcançado uma taxa de erro em torno de 16% no ILSVRC. A ZF Net (Zeiler and Fergus, 2013), que teve um significativo sucesso no desafio ILSVRC de 2013, a GoogLeNet (Szegedy, et al., 2014) que venceu o desafio em seguida, tendo em segundo lugar a Rede Neural Convolucional VGGNet (Simonyan and Zisserman, 2015), e a ResNet (He, et al., 2015), que alcançou o estado da arte no desafio ILSVRC de 2015 (Stanford, 2017).

4 Modelo Proposto

O sistema proposto utiliza um sistema de aquisição para extrair curvas de impedância elétrica de um sensor piezoelétrico acoplado à uma peça metálica, e posteriormente a curva é utilizada como entrada da Rede Neural Convolucional previamente treinada. A Rede classifica a peça metálica através da curva de impedância entre 4 classes diferentes, as quais são: “Sem Dano” (SD), “Remoção de material por impacto” (RMI), “Deformação por impacto” (DI) e “Deformação por impacto em posição diferente” (DIPD), tal como ilustra a Figura 2. A Figura 3 contém exemplos de peças metálicas referentes à cada classe.

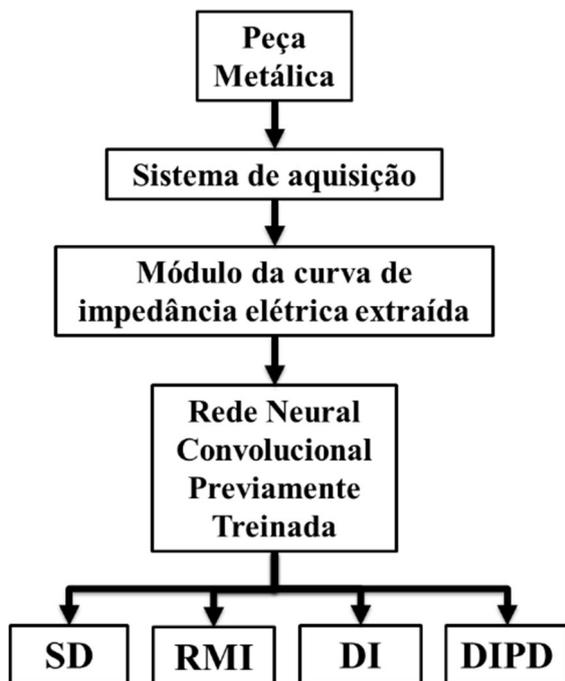


Figura 2. Fluxograma do funcionamento do sistema proposto.



Figura 3. a) Peça metálica referente à classe SD. b) Peça metálica referente à classe RMI. c) Peça metálica referente à classe DI. d) Peça metálica referente à classe DIPD

4.1 Sistema de aquisição

O sistema de aquisição utilizado é composto por um dispositivo DAQ (*Data Acquisition*), por um sensor piezoelétrico PZT (*Pb-Lead Zirconate Titanate*) e por um resistor. O dispositivo DAQ é conectado eletricamente ao PZT através de uma saída analógica e em série com o resistor, conforme ilustrado na Figura 4:

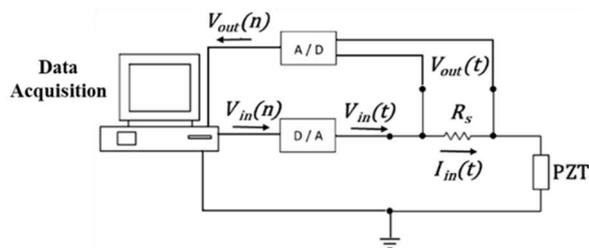


Figura 4. Ilustração do circuito utilizado no sistema de aquisição proposto.

Onde V_{in} é a tensão de entrada gerada pelo DAQ, I_{in} é a corrente de entrada, R_s a resistência do resistor, V_{out} a tensão de saída medida pelo DAQ.

Utiliza-se um resistor de baixo custo em série com o transdutor PZT para possibilitar o cálculo de I_{in} através da Equação 1, pois o valor de V_{out} é medido pelo DAQ.

$$I_{in}(n) = \frac{V_{out}(n)}{R_s} \quad (1)$$

Com o cálculo de I_{in} , é possível calcular a impedância elétrica do circuito no domínio da frequência, utilizando a Transformada de Fourier (TF)

(Oppenheim and Willsky, 2010) de V_{in} e de I_{in} , conforme a Equação 2:

$$\mathbf{Z}(e^{j\omega}) = \frac{\mathbf{V}_{in}(e^{j\omega})}{\mathbf{I}_{in}(e^{j\omega})} = |\mathbf{Z}(e^{j\omega})|e^{j\theta(\omega)} \quad (2)$$

Onde $\mathbf{Z}(e^{j\omega})$ é a Impedância elétrica do circuito no domínio da frequência, $\mathbf{V}_{in}(e^{j\omega})$ a TF da tensão de entrada e $\mathbf{I}_{in}(e^{j\omega})$ a TF da corrente de entrada.

Para o cálculo do módulo da impedância elétrica do circuito, foi utilizado a Equação 3:

$$|\mathbf{Z}(e^{j\omega})| = \sqrt{\mathbf{Z}_{re}^2(e^{j\omega}) + \mathbf{Z}_{im}^2(e^{j\omega})} \quad (3)$$

Sendo que, $\mathbf{Z}_{re}(e^{j\omega})$ é a parte real da impedância elétrica do circuito e $\mathbf{Z}_{im}(e^{j\omega})$ é a parte imaginária.

Foram utilizados 3 sinais de excitação diferentes (ou tensão de entrada V_{in}) no sistema de aquisição, os quais são: Aleatório, Pseudo-Aleatório Binário e Chirp. Os módulos das curvas de impedância elétrica do circuito no domínio da frequência (Equação 3) foram utilizados na classificação.

Os módulos das curvas de impedância elétrica no domínio da frequência serão referenciados adiante como curvas de impedância elétrica para facilitar a leitura.

4.2 Redes Neurais Convolucionais propostas

Para classificação das curvas de impedância elétrica foram utilizadas duas Redes Neurais Convolucionais diferentes, uma o pré-processamento da curva de impedância consiste em convertê-la de um vetor unidimensional para uma matriz bidimensional quadrada (será referenciada como Conv2D), e outra utiliza como vetor de entrada, a curva unidimensional de impedância elétrica sem pré-processamento (será referenciada como Conv1D). A conversão das curvas unidimensionais em matrizes quadradas consiste em dividir a curva em segmentos para posteriormente empilhá-los, formando assim a matriz bidimensional quadrada.

A Tabela 1 demonstra os hiperparâmetros utilizados nas duas Redes Neurais Convolucionais, os quais foram fixados em todos experimentos.

Estes hiperparâmetros foram escolhidos com base nos resultados obtidos em (Almeida, 2018), pois neste trabalho foi realizado um processo de validação dos hiperparâmetros das Redes Neurais Convolucionais, entretanto estas Redes foram utilizadas em conjuntos de dados compostos por curvas de impedância de menor dimensionalidade.

Tabela 1. Hiperparâmetros utilizados nas Redes Neurais Convolucionais

		Dado de Entrada	
		Matriz Bidimensional	Vetor Unidimensional
Hiperparâmetros	Taxa de aprendizado	0,001	0,001
	n° de filtros	32	32
	Tamanho do filtro da camada de convolução	4x4	5
	Tamanho do filtro da camada de agrupamento	2x2	2
	Função de custo	Entropia Cruzada	Entropia Cruzada
	n° neurônios da 1° camada totalmente conectada	20	20
	n° neurônios da camada de saída	4	4
	n° de épocas máximo	20	20

5 Processo Experimental

O dispositivo DAQ (*Data Acquisition*) utilizado é da *National Instruments* (modelo USB-6211), e foi controlado pela ferramenta computacional, MATLAB®. O sensor piezoelétrico escolhido consiste em um transdutor PZT-4 tipo disco com 25 mm de diâmetro e 0,6 mm de espessura.

Em cada experimento foi realizado um número n ($n=3$) de extrações de curvas de impedância elétrica para cada sinal de excitação, com intuito de calcular a curva resultante da média entre as 3 curvas extraídas, assim diminuindo a variância entre as curvas na base de dados.

Foram utilizadas 20 peças metálicas de aço SAE 1020 para levantar a base de dados, as mesmas possuem danos causados intencionalmente em laboratório. O intuito de utilizar estas peças metálicas é de simular a palheta da turbina com danos presentes.

No levantamento da base de dados foram utilizadas 5 peças metálicas para cada classe de dano.

Os trabalhos realizados sobre monitoração de estruturas através da impedância eletromecânica, normalmente fixam de forma permanente o sensor piezoelétrico na estrutura, utilizando um adesivo de alta resistência (Baptista, 2010), (Baptista, et al., 2011), (Overly, et al., 2008), (Park and Inman, 2005), (Lopes, 2013). Este processo de fixação para o presente trabalho não seria viável, uma vez que o objetivo é investigar a possibilidade de aplicar o sistema de SHM em palhetas de turbinas. Pois fixar permanentemente o sensor na palheta poderia degradar o desempenho da turbina.

Foi utilizado um suporte com molas (Figura 5), para fixar o sensor de tal forma que seja possível obter informações referentes à peça metálica, e removê-lo após a extração das curvas de impedância elétrica.

Este suporte foi desenvolvido e fabricado em uma impressora 3D no Laboratório de Redes Industriais e Sistemas de Automação (LARISA) da UERJ.

Com a utilização do suporte com molas, não foi necessário fixar permanentemente 20 sensores PZT

(um para cada peça metálica) para o levantamento da base de dados, o que reduziu o custo do experimento, pois a fixação não permanente possibilitou a utilização de apenas 3 sensores PZT (foram utilizados 3 sensores para ter uma generalização maior na base de dados).

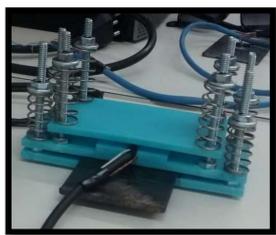


Figura 5. Experimento com suporte com molas

O suporte com molas trata-se de um dispositivo de prensa, onde o sensor piezoelétrico é pressionado contra a peça metálica. Para melhorar o contato entre o sensor e a peça metálica é utilizado uma camada de gel condutor de ultrassonografia entre ambos.

Como dito anteriormente foram utilizados 3 sinais de excitação (Aleatório, Pseudo-Aleatório Binário e Chirp), e os mesmos foram gerados com 2 volts de amplitude (1 volt de pico) durante 1 segundo, utilizando funções do software MATLAB®.

Para representação dos sinais V_{in} e I_{in} no domínio da frequência, foi utilizado a função *fft* (*Fast Fourier Transform*) também do MATLAB®, a qual tem como saída padrão a representação do sinal no domínio da frequência com o mesmo número de pontos da entrada, desta forma os sinais foram representados com 250 mil pontos.

Devido à elevada quantidade de pontos da curva de impedância elétrica, foi utilizado para classificação apenas os 50 mil primeiros pontos. A escolha por 50 mil pontos foi tomada baseada nas observações realizadas sobre os gráficos das curvas de impedância, pois os mesmos exibiram excitações de harmônicos nestes primeiros pontos, o que sugere a presença de informações relevantes para classificação. A redução ainda maior das curvas de impedância poderia resultar em grande perda de informações referentes às condições mecânicas das peças metálicas, o que dificultaria a classificação.

Foram adicionados 176 pontos iguais à 0 no final da curva de impedância elétrica nos experimentos utilizando a Conv2D, com intuito de possibilitar a conversão da curva em uma matriz quadrada.

A Figura 6 exhibe exemplos de curvas de impedância elétrica referentes a cada classe de dano e extraídas utilizando sinal de excitação Chirp. O sinal de excitação Chirp varreu uma faixa de frequência de 0 à 12,6 kHz, já os outros sinais varreram uma faixa de 0 à 50 kHz.

Foi levantado um conjunto de 2390 amostras de curvas de impedância elétrica para a base dados, utilizando cada sinal de excitação, o que resulta em um total de 3 conjuntos de dados. Cada classe possui em torno de 600 amostras de curva de impedância.

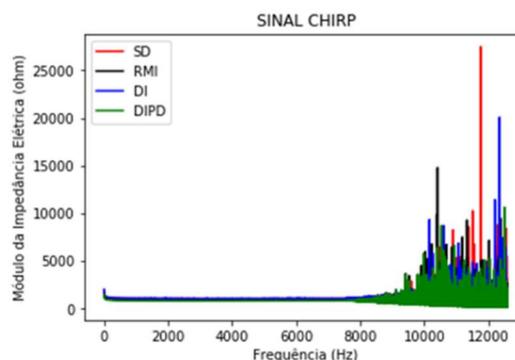


Figura 6. Exemplos de amostras de curvas de impedância elétrica extraídas utilizando o sinal Chirp

6 Resultados

Foi adicionado um ruído branco nos conjuntos de dados, pois os mesmos foram levantados em laboratório sem considerar algumas variáveis existentes em condições normais, como por exemplo: posições diferentes do dano, umidade e variações de temperatura.

Foi realizado um processo de busca de hiperparâmetros nos classificadores tradicionais SVM e KNN, o qual consiste em uma pesquisa em *grid* com validação cruzada k-pastas estratificado, pois desta forma os classificadores terão sua performance avaliada para diferentes combinações de hiperparâmetros, com a garantia de que cada k-pasta mantenha a mesma proporção entre as classes dos conjuntos de dados completos (Muller and Guido, 2016), foram utilizadas 3 pastas neste processo de busca. Não foi realizado a busca por hiperparâmetros nas Redes Neurais Convolucionais e na Regressão Logística por conta do alto custo computacional de trabalhar com curvas de 50 mil pontos.

Os hiperparâmetros validados no processo de busca aplicado no classificador SVM foram: C e γ , sendo que ambos foram testados no intervalo de valores: (0,001; 0,01; 0,1; 1; 10; 100). Já o hiperparâmetro validado do KNN foi o número de k vizinhos, o qual foi testado no intervalo de valores: (1,3,5,7, 9, 11, 13, 14).

Foram separadas, em cada conjunto levantado, 478 amostras de curva de impedância elétrica para formar o conjunto de teste, e as 1912 amostras restantes foram utilizadas no conjunto de treinamento e validação.

As Redes Neurais Convolucionais foram implementadas em Python, utilizando a biblioteca Keras, e os outros classificadores também foram implementados em Python, porém com o auxílio da biblioteca Scikit-Learn.

Os classificadores tiveram sua generalização avaliada pela acurácia alcançada no conjunto de teste (este conjunto também possui a proporção entre as classes igual à do conjunto completo) referente a cada sinal de excitação. Os classificadores que possuem características estocásticas (Redes Neurais Convolucionais e a Regressão Logística, devido à inicialização aleatória dos pesos) foram treinados 5

vezes, com intuito de calcular a média e o desvio padrão das acurácias resultantes na avaliação da generalização. No treinamento das Redes Neurais Convolucionais foi utilizado a parada antecipada.

A Tabela 2 contém os resultados das acurácias em porcentagem dos experimentos realizados na avaliação da generalização. As maiores acurácias alcançadas utilizando cada sinal de excitação estão em negrito e sublinhadas.

Tabela 2. Acurácias em porcentagem dos experimentos realizados no conjunto de teste

Classificadores	Sinais de excitação		
	Aleatório	Chirp	Pseudo Aleatório Binário
SVM	25,94	25,94	25,94
KNN	62,76	56,9	74,69
RL	45,48	80,92	48,03
Conv1D	52,26	87,36	61,34
Conv2D	52	84,56	58,79

Como pode ser visto na Tabela 2, o classificador, que obteve a maior acurácia entre todos os estudos de caso, foi a Conv1D, com valor de 87,36% alcançada no conjunto de teste referente ao sinal Chirp. A segunda maior acurácia entre todos os estudos de caso foi obtida pela Conv2D, alcançando um valor de 84,56% também no conjunto referente ao sinal Chirp.

Dentre todos os estudos de caso, os únicos classificadores que alcançaram uma acurácia acima de 84% foram as Redes Neurais Convolucionais.

A melhor performance geral alcançada pelas Redes Neurais Convolucionais, principalmente pela Conv1D, é justificada pelo fato destas Redes trabalharem bem com dados de entrada de alta dimensionalidade, já que durante o treinamento, as mesmas aprendem a selecionar quais são os atributos relevantes para classificação, desta forma diminuindo a dimensionalidade do dado de entrada.

A alta dimensionalidade de 50 mil atributos do dado de entrada afetou principalmente o SVM, pois o mesmo alcançou uma acurácia de 25,94% em todos os estudos de caso.

Um outro resultado interessante foi que as Redes Neurais Convolucionais só alcançaram uma acurácia alta no conjunto de teste referente ao sinal Chirp, já nos outros conjuntos, o classificador KNN alcançou as maiores acurácias, atingindo valores de 62,76% e 74,69%.

7 Conclusão

Conclui-se que as Redes Neurais Convolucionais são adequadas para o presente problema, pois as mesmas alcançaram altas acurácias, que inclusive superaram os classificadores tradicionais.

A configuração do sistema de SHM, a qual utiliza o sinal de excitação Chirp e o classificador Conv1D foi mais adequada para o presente problema, pois como dito anteriormente, a Conv1D alcançou a maior acurácia entre todos os experimentos.

Devido ao fato dos classificadores propostos terem alcançado acurácias em torno de 84%, pode-se

afirmar, que o suporte com molas funcionou de forma adequada.

De acordo com os resultados a Conv1D superou a Conv2D em todos os estudos de caso, porém com acurácias próximas, logo não foi vantajoso realizar a conversão do vetor unidimensional para a matriz bidimensional.

De acordo com os resultados, os hiperparâmetros utilizados no processo de busca não foram os adequados para o classificador SVM, já que a sua acurácia não teve aumento em nenhum estudo de caso.

As Redes Neurais Convolucionais, ainda merecem estudos para melhorar o desempenho, principalmente nos estudos de casos utilizando os conjuntos referentes aos sinais aleatório e pseudo-aleatório binário, como por exemplo: analisar a utilização da camada *dropout* (Buduma and Locascio, 2017), aplicar uma pesquisa em grid pelos melhores hiperparâmetros, investigar outras formas de converter o vetor unidimensional em uma matriz bidimensional e analisar outras arquiteturas.

Os experimentos foram realizados em condições controladas em laboratório, sendo assim, um passo bastante importante para trabalhos futuros, avaliar a performance do sistema de SHM proposto instalado com as devidas adaptações na palheta real de uma turbina. Outra tarefa importante para trabalhos futuros é o aprimoramento do sistema, com intuito de considerar a possibilidade de haver mais de um tipo de dano na mesma peça.

Agradecimentos

Agradecemos à FAPERJ pelo apoio prestado neste projeto.

Referências Bibliográficas

- Almeida, J. (2018). *Redes Neurais Convolucionais aplicadas em monitoramento de estruturas metálicas*. Mestre. Universidade do Estado do Rio de Janeiro.
- Atha, D. and Jahanshahi, M. (2017). Evaluation of deep learning approaches based on convolutional neural networks for corrosion detection. *Structural Health Monitoring*, pp. 1–19. doi: 10.1177/1475921717737051.
- Baptista, F. (2010). *Uma Contribuição aos Sistemas de Monitoramento de Integridade Estrutural Baseados na Impedância Eletromecânica*. Doutor. Universidade Estadual Paulista.
- Baptista, F., Filho, J. and Inman, D. (2011). Real-time multi-sensors measurement system with temperature effects compensation for impedance-based structural health monitoring. *Structural Health Monitoring*, 11(2), pp.173-186.
- Bhalla, S., Gupta, A., Bansal, S. and Garg, T. (2009). Ultra Low-cost Adaptations of Electro-mechanical Impedance Technique for Structural Health Monitoring. *Journal of Intelligent Material Systems and Structures*, 20(8), pp.991-999.

- Buduma, N. and Locascio, N. (2017). *Fundamentals of deep learning: Designing Next-Generation Machine Intelligence Algorithms*. Sebastopol: O'REILLY.
- Em.com.br. (2017). *Saiba detalhes do inquérito sobre a queda do Viaduto Batalha dos Guararapes - Gerais - Estado de Minas*. [online] Available at: https://www.em.com.br/app/noticia/gerais/2015/05/05/interna_gerais,644334/saiba-detalhes-do-inquerito-sobre-a-queda-do-viaduto-batalha-dos-guara.shtml [Accessed 6 Dec. 2017].
- Farrar, C., Lieven, N. and Bement, M. (2005). An Introduction to Damage Prognosis. In: D. Inman, C. Farrar, V. Junior and V. Junior, ed., *Damage Prognosis: For Aerospace, Civil and Mechanical Systems*. John Wiley & Sons.
- Finzi Neto, R., Steffen Jr, V., Rade, D., Gallo, C. and Palomino, L. (2010). A low-cost electromechanical impedance-based SHM architecture for multiplexed piezoceramic actuators. *Structural Health Monitoring*, 10(4), pp.391-402.
- Franco, V. (2009). *Monitoramento da Integridade em Estruturas Aeronáuticas*. Mestre. Universidade Estadual Paulista.
- Gazeta do Povo. (2016). *Arquibancada da Fonte Nova cede e deixa pelo menos sete mortos*. [online] Available at: <http://www.gazetadopovo.com.br/esportes/arquibancada-da-fonte-nova-cede-e-deixa-pelo-menos-sete-mortos-aqpdld9gg4d16umshal5w5cni> [Accessed 5 Nov. 2016].
- Guo, J., Xie, X., Bie, R. and Sun, L. (2014). Structural health monitoring by using a sparse coding-based deep learning algorithm with wireless sensor networks. *Personal and Ubiquitous Computing*, 18(8), pp.1977-1987.
- He, K., Zhang, X., Ren, S. and Sun, J. (2015). Deep Residual Learning for Image Recognition. Available at: <https://arxiv.org/abs/1512.03385>.
- IMAGENET. (2016). *ImageNet*. [online] Available at: <http://www.image-net.org> [Accessed 10 Dec. 2016].
- Park, G. and Inman, D. (2005). Impedance-Based Structural Health Monitoring. In: D. Inman, C. Farrar, V. Junior and V. Junior, ed., *Damage Prognosis: For Aerospace, Civil and Mechanical Systems*. John Wiley & Sons.
- Ketkar, N. (2017). *Deep Learning with Python A Hands-on Introduction*. 1st ed. Apress. doi: 10.1007/978-1-4842-2766-4.
- Krizhevsky, A., Sutskever, I. and Hinton, G. (2012). ImageNet classification with deep convolutional neural networks. In: *Proceedings of the 25th International Conference on Neural Information Processing Systems*. pp.1-9. Available at: <http://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural-networks>.
- Lopes, L. A. R. (2013). *Sistemas inteligentes aplicados em monitoramento de estrutura aeronáutica*. Mestre. Universidade do Estado do Rio de Janeiro.
- Müller, A. and Guido, S. (2016). *Introduction to machine learning with Python*. 1st ed. Sebastopol: O'Reilly.
- Oppenheim, A. and Willsky, A. (2010). *Sinais e Sistemas*. 2nd ed. São Paulo: Pearson.
- Overly, T., Park, G., Farinholt, K. and Farrar, C. (2008). Development of an extremely compact impedance-based wireless sensing device. *Smart Materials and Structures*, 17(6).
- Palomino, L. (2008). *Análise das métricas de dano associadas à técnica da impedância eletromecânica para o monitoramento de integridade estrutural*. Mestre. Universidade Federal de Uberlândia.
- Simonyan, K. and Zisserman, A. (2015). Very Deep Convolutional Networks for Large-Scale Image Recognition, pp. 1–14. Available at: <https://arxiv.org/abs/1409.1556>.
- Shwartz, S. and David, S. (2014). *Understanding Machine Learning: From Theory to Algorithms*. 1st ed. Cambridge University Press.
- Sobrinho, E. P. (2013). *Inspecção Em Turbinas a Gás Com o Uso do Boroscópio*. Monografia. Instituto Federal de Educação, Ciência e Tecnologia Fluminense.
- Stanford. (2017). *CS231n Convolutional Neural Networks for Visual Recognition*. [online] Available at: <http://cs231n.github.io/convolutional-networks/> [Accessed 9 Nov. 2017].
- Sun, F., Chaudhry, Z., Liang, C. and Rogers, C. (1995). Truss Structure Integrity Identification Using PZT Sensor-Actuator. *Journal of Intelligent Material Systems and Structures*, 6(1), pp.134-139.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V and Rabinovich, A. (2014). Going deeper with convolutions. Available at: <https://arxiv.org/abs/1409.4842>.
- Tamilselvan, P., Wang, Y. and Wang, P. (2012). Deep Belief Network based state classification for structural health diagnosis. In: *2012 IEEE Aerospace Conference*. IEEE. Big Sky, MT, USA: IEEE, pp. 1–11. doi: 10.1109/AERO.2012.6187366.
- Xuejun, W. and Yan, Z. (2017). The Detection and Recognition of Bridges' Cracks Based on Deep Belief Network. In: *2017 IEEE International Conference on CSE and IEEE International Conference on EUC*. Guangzhou, China: IEEE, pp. 768–771. doi: 10.1109/CSE-EUC.2017.151.
- Zeiler, M. D. and Fergus, R. (2013). Visualizing and Understanding Convolutional Networks. Available at: <https://arxiv.org/abs/1311.2901>.
- Zhang, L., Yang, F., Zhang, Y. and Zhu, Y. (2016). Road crack detection using deep convolutional neural network. In: *2016 IEEE International Conference on Image Processing (ICIP)*. Phoenix: IEEE.