



**Simpósio de Métodos
Numéricos em Engenharia**

25 a 27 de outubro, 2017

Redução de dados das FRFs via análise de componentes principais.

L.R. Völtz.

E.L. Cardoso.

R. De Medeiros

Departamento de Engenharia Mecânica
Universidade do Estado de Santa Catarina

Joinville, Brasil

luisa.voltz@gmail.com

Resumo — A análise de dano de estruturas por meio da alteração de suas propriedades dinâmicas requer a análise de um grande número de dados experimentais, cada qual contendo um grande número de informações de amplitude e de frequência. O grande número de dados pode ser contornado pelo uso de métodos automatizados de análise, como por exemplo o uso de redes neurais artificiais. No entanto, a dificuldade em lidar com um grande número de informações por ensaio ainda permanece. Este trabalho busca realizar uma redução da dimensionalidade dos dados experimentais originais, porém mantendo suas características, através da aplicação da análise de componentes principais. Por meio desta análise, um conjunto de Funções de Resposta em Frequência (FRFs), com 3201 linhas espectrais, é comprimido para uma nova dimensão com 10 variáveis, mantendo as propriedades originais. Por fim, apresentam-se as potencialidades e limitações da presente proposta.

Palavras-chave—*análise de componentes principais; funções de resposta em frequência; machine learning; detecção de dano;*

I. INTRODUÇÃO

Metodologias de detecção de danos estruturais têm sido alvo de diversas pesquisas envolvendo desde técnicas baseadas em vibrações nos domínios já conhecidos como ao uso de técnicas de aprendizagem automática ou *machine learning*, como por exemplo, as Redes Neurais Artificiais (RNA's). Recentes artigos mostram que as redes neurais podem ser treinadas através do uso de Funções de Resposta em Frequência (FRF's), para reconhecimento de padrões de

estruturas intactas e danificadas [1]. Contudo, uma das principais barreiras encontradas é a utilização do tamanho completo dos dados da FRF como entrada na RNA's. Mesmo que atualmente o custo computacional não é mais um contratempo, o problema de saturação ainda contribuiria para o baixo aprendizado da rede. Entradas do tamanho de uma FRF completa, com um tamanho muito grande de variáveis, requerem o uso de um tamanho muito maior de amostras de treino, inviabilizando o uso da técnica [2].

Bandara, Chan e Thambiratam [3] utilizaram um conjunto de 7500 pontos de frequência, sendo estes comprimidos para 13 componentes principais e, posteriormente calculou-se o índice de dano, utilizando-o na rede neural, a rede foi capaz de identificar a localização e a severidade dos danos aplicados à estrutura.

Diante do exposto, o objetivo deste trabalho é investigar a utilização da técnica de análise de componentes principais como uma possibilidade de reduzir a dimensionalidade da FRF e, assim sintetizar o tamanho das variáveis necessárias para alimentar a rede, mantendo as mesmas características das FRF's originais.

II. MATERIAS E MÉTODOS

Os testes experimentais foram realizados com objetivo de obter as características dinâmicas (FRFs) de uma estrutura. Para isso, foram utilizados 24 vigas de alumínio com 496 mm de comprimento, 197 mm de largura e 4.9 mm de espessura. As FRFs foram obtidas através do software *Pulse LabShop* da *Brüel & Kjaer* com o uso de um

acelerômetro modelo 4397 (sensibilidade 10mV/g) e de um martelo de impacto modelo 8203-006 (sensibilidade 1,12mV/N) para a excitação. Foram realizadas medições para as vigas intactas e para as vigas danificadas, inicialmente com um furo central de 2mm, após 4mm e por fim 8mm de diâmetro, totalizando 172 FRF's com 3201 pontos espectrais.

A análise de componentes principais é uma técnica que utiliza os conceitos de variância (primeiro momento estatístico e valores característicos (autovalores), para transformar uma série de variáveis correlacionadas, em um número menor de variáveis chamadas de Componentes Principais, sendo esta efetuada através da transformação de espaço vetorial [4]. Portanto, seja a matriz de FRF $[H(\omega)]_{M \times N}$ com M número de amostras e N números de linhas espectrais. O vetor médio $[\bar{H}_j]$ de j th colunas é dada por,

$$\bar{H}_j = \frac{\sum_{i=1}^M h_{ij}(\omega)}{M}, \quad j = 1, 2, \dots, N. \quad (1)$$

E o desvio padrão,

$$S_j = \sqrt{\frac{\sum_{i=1}^M (h_{ij}(\omega) - \bar{H}_j)^2}{M}}. \quad (2)$$

Através do vetor médio e do desvio padrão, calcula-se a matriz de variância $[\tilde{H}(\omega)]_{M \times N}$,

$$\tilde{h}_{ij}(\omega) = \frac{h_{ij}(\omega) - \bar{H}_j}{S_j \sqrt{M}}. \quad (3)$$

Assim, a matriz de covariância é definida por,

$$cov[\tilde{H}(\omega)]_{N \times N} = [\tilde{H}(\omega)]_{N \times M}^T [\tilde{H}(\omega)]_{M \times N}. \quad (4)$$

Por definição os componentes principais são os autovalores e seus autovetores associados da matriz de covariância, conforme,

$$cov[\tilde{H}(\omega)]\{\varphi_i\} = \lambda_i\{\varphi_i\}, \quad (5)$$

onde o índice i é o componente principal. Portanto, os autovetores encontrados formam uma nova base que segue a variação dos dados. O maior autovalor e seu autovetor associado representam a direção e a máxima variância em relação aos dados originais. Com a nova base, calcula-se o novo espaço, dado pelos componentes principais (p), utilizando-o como entrada na ANN.

$$[A]_{M \times p} = [\tilde{H}(\omega)]_{M \times N} [\varphi]_{N \times p}. \quad (6)$$

III. RESULTADOS E DISCUSSÕES.

A fig.1 apresenta os resultados obtidos para o pré-tratamento das FRF's, a análise de componente principais foi desenvolvida no Scilab. Observam-se as variâncias dispostas individualmente e a cumulativa em relação aos dez primeiros componentes principais. O primeiro componente principal, isto é, o maior autovalor da matriz de

covariância apresenta variância de 69,54% e somando os dez primeiros componentes principais a variância acumulada é de 98,06%. A fig.2 apresenta a FRF original e as FRF's reconstruídas com os dez e com os vinte primeiros componentes principais.

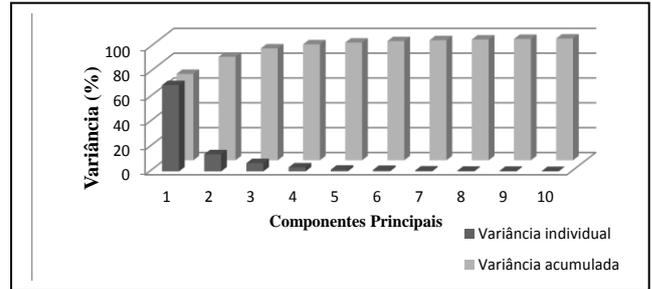


Figura 1. Variância versus Componentes principais.

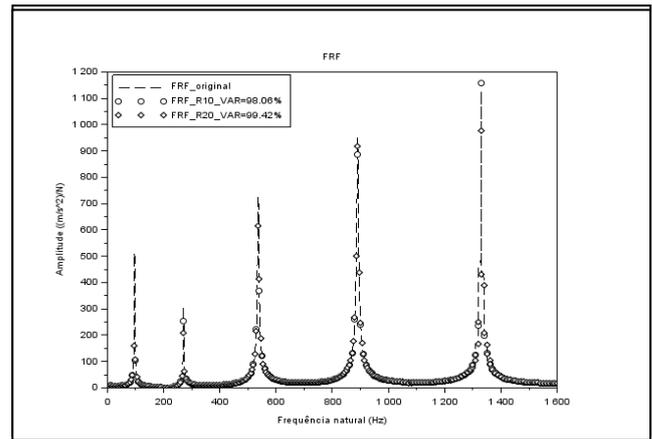


Figura 2. FRF original e FRF's reconstruídas.

IV. CONCLUSÕES.

A análise de componentes principais mostrou-se bastante eficiente para redução de dimensionalidade dos dados originais e de grande valia para seu uso em métodos que limitam o tamanho das variáveis a serem utilizadas. Portanto, a técnica apresentada neste trabalho, juntamente com técnicas de aprendizagem automática, pode ajudar no desenvolvimento de sistemas de monitoramento de estruturas e consequentemente na detecção de falha das mesmas.

REFERÊNCIAS

- [1] J. Tang. "Frequency response based damage detection using principal component analysis". Information Acquisition, 2005 IEEE International Conference on. IEEE, pp. 6, 2005.
- [2] C.Zang and M. Imregun, "Structural damage detection using artificial neural networks and measured FRF data reduced via principal component projection". Journal of Sound and Vibration, vol. 242.5, pp. 813-827, 2001.
- [3] R. O. Bandara, T. H.T. Chan and D.P.Thambiratam. "Frequency response function based damage identification using principal component analysis and pattern recognition technique". Engineering Structures, vol. 66, pp.116-128, 2014.
- [4] J. Shlens. "A tutorial on principal component analysis". arXiv preprint arXiv: 1404.1100, 2014.