

Aplicação de Estatísticas de Ordem Superior e Máquinas de Vetor de Suporte Para Detecção de Falhas Estruturais em Vigas

F. E.M. Borges¹, A.W.M. Pinto¹, D.A. Pereira¹, B.H.G. Barbosa¹, R.R. Magalhães¹,
D.D. Ferreira¹, T.S. Barbosa²

¹ Universidade Federal de Lavras (UFLA), Lavras – MG, Brasil.

fernandoelias-mb@outlook.com

andrey.marques96@gmail.com

danielpereira@deg.ufla.br

brunohb@gmail.com

ricardorm@deg.ufla.br

danton@deg.ufla.br

² Centro Federal de Educação Tecnológica de Minas Gerais (CEFET-MG), Unidade Nepomuceno, Nepomuceno-MG, Brasil.

tassiospuri@gmail.com

Abstract. In this article, it is proposed a method for detection of structural faults or damages using Higher-Order Statistics (HOS). Taking vibration signals measured using an accelerometer, characteristics are extracted by cumulants and selected with the Fischer's Discriminant. Subsequently, the classification is carried out with the aid of Supporting Vector Machines, aiming to determine the presence or not of faults in the structure. The method was experimentally tested in a cantilever beam, providing high detection rates. Advantages presented are low computational cost and no requirement of information about the damaged structure.

Keywords: Vibration Analysis, Structural Health Monitoring, HOS.

1 Introdução

O acelerado ritmo de inovação e desenvolvimento tecnológico vivenciado nas últimas décadas permitiu que diversas operações industriais passassem a ser desempenhadas quase exclusivamente por máquinas, com o mínimo de intervenção humana. Assim, o chão de fábrica caracterizou-se como um ambiente com elevado grau de automação e intenso uso de tecnologia da informação.

Atualmente, muito se discute sobre a entrada em uma nova era de desenvolvimento tecnológico traduzida no conceito de indústria inteligente ou indústria 4.0 [1], que intensificará o emprego da automação e caracterizará um ambiente fabril cada vez mais dominado por máquinas interconectadas e que trabalham autonomamente. No entanto,

as máquinas continuarão suscetíveis a falhas ou danos que poderão implicar em sérios riscos à saúde e à segurança das pessoas que interagem com elas, além de prejuízos financeiros e ao meio ambiente.

Para evitar ou minimizar tais danos, devem ser aplicadas práticas de manutenção preventiva e preditiva, esta última também conhecida como manutenção baseada na condição [2]. No presente trabalho é realizada uma das práticas de manutenção preditiva, o SHM (da sigla em inglês, *Structural Health Monitoring*) ou Monitoramento de Integridade Estrutural. Nesta linha de pesquisa há diversos trabalhos que envolvem técnicas avançadas de processamento de sinais e reconhecimento de padrões, que são a base conceitual para as técnicas que foram implementadas neste trabalho. Em [3] foram apresentadas revisões detalhadas sobre técnicas de detecção de falhas com enfoque na análise de vibrações. Na literatura, apresentam-se vários estudos e aplicações do SHM, como é o caso em [4], onde foi estudada a aplicação do SHM para detecção de falhas em turbinas eólicas. O trabalho feito em [5] propôs uma metodologia de monitoramento das condições de uma ponte baseado em análise de vibrações e reconhecimento de padrões. O SHM também é aplicado para detecção de falhas em sensores como é demonstrado em [6] onde os autores utilizaram monitoramento estatístico (como PCA) para o mesmo. Em [7] é realizado um estudo utilizando método de elementos finitos e análise de vibrações para a detecção de falhas em uma viga engastada.

No presente artigo é proposta uma metodologia de prática de SHM baseada na análise de vibrações, com o uso de máquinas de vetor de suporte como classificador dos sinais de vibração. O método de Máquinas de Vetor de Suporte (SVM – *Support Vector Machine*) usado neste trabalho é de configuração *one-class* [8] [9]. Tal metodologia é funcional e já fora utilizada anteriormente, como em [10] onde foi aplicado o SVM em componentes de uma máquina agrícola.

2 Método Proposto

O método proposto será aplicado em uma viga engastada. Para a aquisição de dados de vibração será utilizado um sensor acelerômetro (tendo antes um filtro *anti-aliasing*), este controlado por um microcontrolador ARDUINO®. Primeiramente, será realizada uma coleta de dados com a estrutura sem falha. Logo em seguida ocorrerá uma segunda etapa de testes, com a introdução de falha, caracterizada por um corte retangular transversal. Após ambas as coletas serão realizados os testes com o detector de falhas. Para extração de características, será usada a técnica de Estatísticas de Ordem Superior (EOS). Já para a seleção de características, será utilizado o Discriminante Linear de Fisher (FDR), que selecionará os parâmetros mais relevantes para a detecção. Tal método de extração e seleção de características já foi utilizado com sucesso por [11] e será aplicado neste trabalho. E, por fim, para classificação dos sinais, serão utilizadas as máquinas de vetor de suporte (SVM). O método proposto compreende quatro etapas que são descritas nas seções seguintes e que podem ser visualizadas de forma resumida na Fig. 1.

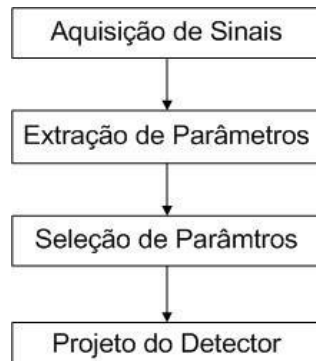


Fig. 1. Diagrama esquemático do projeto do método proposto.

2.1 Aquisição de Sinais

Os testes em bancada foram realizados no Laboratório de Controle do Departamento de Engenharia da Universidade Federal de Lavras (UFLA). O material analisado foi uma viga de alumínio, com dimensões 330 mm de comprimento, 35 mm de largura e 2 mm de espessura. Para a geração de vibrações na viga, usou-se um motor de corrente contínua (CC) de 24 mm de diâmetro por 12 mm de comprimento na base e um eixo de 2 mm de diâmetro por 10 mm de comprimento; comprimento total (Base + Eixo) = 22 mm; Massa: 21,0 g; E uma variação de frequência máxima de até 90Hz.

Na captação das vibrações da viga foi usado um acelerômetro de três eixos modelo MMA7361, com dimensões de 27,9 mm x 18,6 mm; Frequência de Bandwidth média no eixo X e Y de 400Hz e no eixo Z de 300Hz; Massa: 2,5g; Power Spectral Density RMS (0.1 Hz – 1kHz).

No controle mútuo do acelerômetro e do motor, utilizou-se o microcontrolador ARDUINO® modelo MEGA2560. Um filtro passa-baixas com frequência de corte de 100Hz (anti-aliasing) foi utilizado. Para alimentação do circuito integrado do filtro e do motor, foi usada uma fonte do tipo ATX.

Para a realização da aquisição de sinais, o microcontrolador foi conectado a um computador via porta USB e os dados foram arquivados em uma planilha para análises posteriores no software MatLab®.

Para a realização dos testes, a viga teve uma extremidade fixada por um suporte e a outra livre (situação de engaste em balanço), sendo o motor fixado com uma fita dupla face adesiva, próximo à extremidade fixa e o acelerômetro na extremidade livre, que também foi fixado com a fita, como é visto na Fig. 2. Foi utilizado um motor com velocidade ajustável, com a função de excitar a viga em uma gama variada de frequências. Para isso foi feito um controle automático programado no ARDUINO®, em que a velocidade do motor foi variada de zero à máxima velocidade (com frequência em torno de 90Hz) e em seguida retornando da máxima velocidade a zero de forma gradativa e contínua.




Fig. 2. Esquema da coleta: "A" onde o motor é acoplado e "B" onde o sensor é fixado.

Após a montagem do experimento, foram realizadas 10 aquisições de sinais em uma viga sem falhas. Cada aquisição teve duração de 2 minutos e os sinais foram coletados com um intervalo de tempo entre uma amostra e outra de 0,005 segundos (o que leva a uma frequência de amostragem de 200Hz), o que gera um total de 24.000 amostras em cada sinal.

Em seguida, foi introduzida uma falha na viga, um corte de 1 mm de comprimento por 10 mm de largura, como pode ser visto na Fig. 4, e novamente foram realizadas 10 aquisições de sinais com a viga sendo excitada pelo motor CC sob as mesmas condições do experimento realizado com a viga sem falha. Tal falha foi induzida com o objetivo de simular uma falha real de nível intermediário com o objetivo de se fazer a detecção desta utilizando o método proposto. A Fig. 3 demonstra a montagem experimental realizada em laboratório.




Fig. 3. Montagem experimental para aquisição de sinais.

As Figs. 4, 5 e 6 mostram, respectivamente, em detalhes as placas com e sem falha, o motor e o acelerômetro utilizados no experimento.

Importante ressaltar que a cada aquisição de sinal, a bancada mostrada na Fig. 3 era desfeita e refeita novamente, com a finalidade de se comprovar a capacidade de repetibilidade do experimento.



Fig. 4. Demonstração de uma placa sem falha (esquerda) e placa com a falha introduzida (direita).



Fig. 5. Motor usado no experimento.




Fig. 6. Sensor acelerômetro usado no experimento.

2.2 Extração de Parâmetros

A Extração de Parâmetros de EOS é realizada através do cálculo dos cumulantes de segunda, terceira e quarta ordens do sinal de vibração. As expressões matemáticas para os cumulantes de segunda, terceira e quarta ordens de um sinal aleatório $x[n]$, quando $E\{x[n]\} = 0$, são, respectivamente [12]:

$$C_{2,x}[i] = E\{x[n]x[n+i]\}, \quad (1)$$

$$C_{3,x}[i] = E\{x[n]x^2[n+i]\}, \quad (2)$$

$$C_{4,x}[i] = E\{x[n]x^3[n+i]\} - 3C_{2,x}[i]C_{2,x}[0], \quad (3)$$

Para um vetor com comprimento finito (N), as aproximações estocásticas oferecem as seguintes expressões [11]:

$$\hat{C}_{2,x}[i] = \frac{2}{N} \sum_{n=0}^{N-1-i} \{x[n]x[n+i]\}, \quad (4)$$

$$\hat{C}_{3,x}[i] = \frac{2}{N} \sum_{n=0}^{N-1-i} \{x[n]x^2[n+i]\}, \quad (5)$$

$$\hat{C}_{4,x}[i] = \frac{2}{N} \sum_{n=0}^{N-1-i} \{x[n]x^3[n+i]\} - \frac{2}{N^2} \sum_{n=0}^{N-1-i} \{x[n]x[n+i]\} \sum_{n=0}^{N-1-i} \{x^2[n]\}, \quad (6)$$

Em que $i = 0, 1, \dots, N/2 - 1$.

2.3 Seleção de Parâmetros

Os parâmetros de EOS e a quantidade destes podem ser escolhidos de forma a haver um melhor compromisso entre baixo custo computacional e desempenho. Com o propósito de selecionar os cumulantes mais representativos para o problema de detecção

de falhas em viga, o Discriminante Linear de Fisher (FDR - Fisher's Discriminant Ratio) foi utilizado em [13]. Sua função custo é:

$$J_c = (\boldsymbol{\mu}_i - \boldsymbol{\mu}_j)^2 \circ \left(\frac{1}{\sigma_i^2 + \sigma_j^2} \right) \quad (7)$$

Onde $\boldsymbol{\mu}_i$ e $\boldsymbol{\mu}_j$, e σ_i e σ_j são os vetores de médias e variâncias das características extraídas das classes i e j , respectivamente. O símbolo \circ é o produto de Hadamard. Dessa forma, os valores maiores do vetor J_c indicarão as características mais relevantes para a separação entre as classes i e j , pois apresentam as maiores distâncias entre classes e as menores medidas intra-classes. Este apresenta os parâmetros mais relevantes para a classificação, apresentando a maior distância entre as classes da viga com e sem falha e a menor distância de um evento para o outro pertencente à mesma classe.

2.4 Projeto do Classificador

O SVM constitui uma técnica de aprendizagem de máquina fundamentada pela teoria de aprendizado estatístico desenvolvido por [14]. O objetivo do SVM é encontrar um hiperplano que divide as duas classes estudadas neste trabalho (classe da viga sem falha e com falha), de tal forma que todos os pontos com as mesmas características estejam do mesmo lado do hiperplano, enquanto maximiza a distância entre as duas classes do hiperplano [9].

Algumas vantagens do SVM são o uso da função kernel, que permite uma alta eficiência na obtenção dos limites da região a ser separada. O princípio desta função é o tratamento dos dados não linearmente separáveis, fazendo com que o SVM promova uma transformação do espaço de entradas para um espaço de dimensão mais alta, este denominado espaço de parâmetros, como função kernel foi utilizada a função do tipo gaussiana. Neste trabalho, utilizou-se a versão *one-class learning* do SVM, desenvolvida por [8]. A equação que demonstra o problema dual, cujo objetivo é minimizá-la é descrita a seguir:

$$0.5 \sum_{jk} \alpha_j \alpha_k G(x_j, x_k) \quad (8)$$

3 Resultados

As Figs. 7 e 8 mostram, respectivamente, os sinais de vibração de uma viga sem falha e o de uma viga com falha, coletados conforme descrito na seção 2. Observa-se em ambos os sinais a característica de aceleração e desaceleração do motor CC, que é refletida no sinal de vibração das vigas. Além disso, os picos indicam a excitação dos modos de baixa frequência da viga.




Fig. 7. Coleta do sinal de vibração da viga sem falha.




Fig. 8. Coleta do sinal de vibração da viga com falha.

Cada sinal de vibração coletado, contendo um total de 24.000 amostras, foi particionado em dois de 12.000 amostras, resultando em um total de 20 eventos para cada classe (viga com falha e viga sem falha). Os dados referentes à viga sem falha foram divididos em treino (12 eventos) e teste (8 eventos). Todos os dados referentes à viga com falha foram utilizados para teste.

Após a amostragem foram selecionados os melhores parâmetros com o uso do FDR. A Fig. 9 mostra o FDR obtido para cada parâmetro. Os primeiros 12.000 parâmetros

são referentes aos cumulantes de segunda ordem, os próximos 12.000 aos de terceira ordem e os últimos 12.000 aos de quarta ordem. Observe que os cumulantes de terceira ordem mostraram-se mais representativos, com valores de J_c mais expressivos.

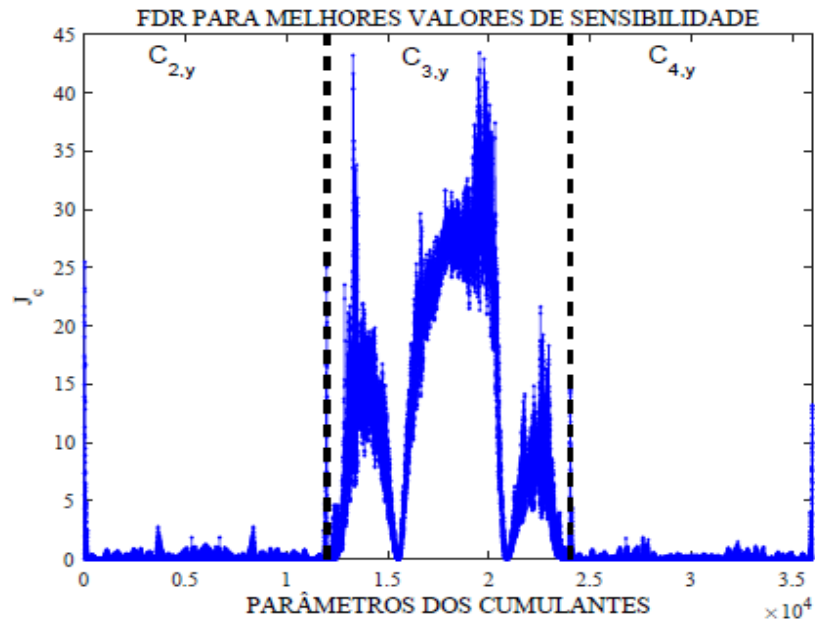


Fig. 9. FDR obtido para o vetor de parâmetros durante os testes com a viga engastada.

A fim de reduzir a dimensão dos dados e, conseqüentemente, a complexidade computacional, foram escolhidos apenas dois parâmetros, aqueles com J_c mais elevado.

Estes parâmetros foram então apresentados ao classificador. Após o projeto e a execução do classificador foi observada uma acurácia de 100% do método, conforme mostra a Fig. 10, que é uma representação do espaço de parâmetros construído pelos dois cumulantes de terceira ordem mais relevantes.

A região cinza representa a região fechada construída pelo SVM tal que eventos dentro dela são classificados como sem falha e os eventos fora dela como com falha. Observe que há uma separação linear nítida entre os eventos com falha e sem falha. Importante observar também que os eventos sem falha do conjunto de teste foram corretamente classificados mostrando a generalização do método, o que também comprova a capacidade de repetibilidade do experimento montado.




Fig. 10. Espaço de parâmetros obtido e fronteira de decisão do classificador (região cinza), os dados em formato de círculos azuis e pretos representam, respectivamente, os dados da viga sem falha de treino e teste, já os dados em formato de asterisco, representam os dados da viga com falha.

4 Discussão

Observando os resultados obtidos e os gráficos mostrados anteriormente podem-se destacar alguns pontos importantes.

Primeiro, o uso do FDR faz com que a distância entre as classes seja maximizada de maneira bastante simples, tanto no sentido matemático (as equações do FDR são mais simples, se comparadas com outras equações que possuem a mesma função), quanto computacionalmente (o algoritmo é executado apenas na fase de treinamento).

Segundo, o uso do SVM não supervisionado faz com que não seja necessário o conhecimento específico das falhas nem a realização de ensaios para obter dados referentes à viga com falha, o que facilita bastante o projeto do método.

Avaliando os custos computacionais, o procedimento requer pouco processamento, pois o treino do detector é realizado somente uma vez, já os demais testes, levam pouco tempo para serem realizados porque são utilizados apenas dois parâmetros para a detecção.

Outro ponto a ser destacado é que o método não fez uso de algum pré-processamento específico para remoção ou redução de ruídos provenientes do processo de aquisição de sinais, a não ser o filtro *anti-aliasing*. Isso mostra a boa capacidade das EOS de extrair informações relevantes de sinais de vibração.

5 Conclusão

O método proposto foi capaz de detectar, em testes experimentais, a falha estrutural em uma estrutura vibratória do tipo viga em balanço.

O uso das EOS e a seleção de parâmetros com o FDR permitiu a redução do número de dimensões para classificação para apenas dois parâmetros extraídos das EOS, gerando uma separação linear entre as classes com e sem falha.

Tal resultado condiz com o objetivo deste trabalho, com um método de alta eficiência e baixo custo de instalação. Esta técnica pode ser empregada para auxiliar numa melhor tomada de decisão acerca de uma troca de componentes de máquina, otimizando assim a vida estrutural das peças, reduzindo custos no processo de produção e aumentando a segurança nos mesmos.

Pontos de destaque foram principalmente no quesito eficiência do método e baixos custos operacionais e computacionais. Para projetos futuros, espera-se propor uma abordagem que mensure o nível de falha, classificando a sua gravidade, além de indicar a sua localização na estrutura.

6 Agradecimentos

A Pró Reitoria de Pesquisa (PRP) da Universidade Federal de Lavras (UFLA), ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), à Coordenação e Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) pelo suporte financeiro.

Referências

1. Thoben KD, Wiesner S, Wuest T (2017) “Industrie 4.0” and Smart Manufacturing—A Review of Research Issues and Application Examples. *Int. J. of Automation Technology*. vol 11(1). doi: 10.20965/ijat.2017.p0004
2. Liao W, Wang, Y (2013) Data-driven Machinery Prognostics Approach using in a Predictive Maintenance Model. *JCP*, 8(1), pp 225-231. doi:10.4304/jcp.8.1.225-231
3. Farrar C, Worden K (2012) *Structural Health Monitoring*, John Wiley and Sons Ltd.
4. Avendano-Valencia D, Fassois, SD (2014) Robust fault detection based on multiple functional series TAR models for structures with time-dependent dynamics. In: *EWSHM-7th European Workshop on Structural Health Monitoring*. hal-01020452
5. Mustapha S, Hu Y, Nguyen K, Alamdari MM., Runcie P, Dackermann U, Nguyen VV, Li J, Ye L (2015). Pattern recognition based on time series analysis using vibration data for structural health monitoring in civil structures. *Electronic Journal of Structural Engineering*, vol 14 (1), pp. 106 – 115. <http://hdl.handle.net/10453/40126>
6. Hernandez-Garcia MR, Masri SF (2014) Application of statistical monitoring using latent-variable techniques for detection of faults in sensor networks. *Journal of Intelligent Material Systems and Structures*, vol 25(2), pp 121-136. doi: 10.1177/1045389X13479182

7. Jassim ZA, Ali NN, Mustapha F, Jalil NA (2013) A review on the vibration analysis for a damage occurrence of a cantilever beam. *Engineering Failure Analysis*, vol 31, pp 442-461. doi: 10.1016/j.engfailanal.2013.02.016
8. Schölkopf B, Platt JC, Shawe-Taylor J, Smola AJ, Williamson RC (2001) Estimating the support of a high-dimensional distribution. *Neural computation*, vol 13(7), pp 1443-1471. doi: 10.1162/089976601750264965
9. Theodoridis S, Koutroumbas K (2009) *Pattern recognition*. 4 edn, Academic Press.
10. Ruiz-Gonzalez R, Gomez-Gil J, Gomez-Gil FJ, Martínez-Martínez V (2014) An SVM-based classifier for estimating the state of various rotating components in agro-Industrial machinery with a vibration signal acquired from a single point on the machine chassis. *Sensors*, vol 14(11), pp 20713-20735. doi:10.3390/s141120713
11. Barbosa TS, Ferreira DD, Pereira DA, Magalhães RR, Barbosa BH (2016) Fault Detection and Classification in Cantilever Beams Through Vibration Signal Analysis and Higher-Order Statistics. *Journal of Control, Automation and Electrical Systems*, vol 27(5), pp 535-541. doi: 10.1007/s40313-016-0255-1
12. Mendel JM (1991) Tutorial on higher-order statistics (spectra) in signal processing and system theory: Theoretical results and some applications. *Proceedings of the IEEE*, vol 79(3), pp 278-305 doi: 10.1109/5.75086
13. Duda RO, Hart PE, Stork DG (2000) *Pattern classification*. Wiley-Interscience.
14. Vapnik VN, Vapnik V (1998) *Statistical learning theory*. vol. 1. Wiley, New York.