



TÁSSIO SPURI BARBOSA

**DETECÇÃO DE FALHAS EM VIGAS EM
BALANÇO ATRAVÉS DA ANÁLISE DE SINAIS
DE VIBRAÇÃO E ESTATÍSTICAS DE ORDEM
SUPERIOR**

LAVRAS – MG

2015

TÁSSIO SPURI BARBOSA

**DETECÇÃO DE FALHAS EM VIGAS EM BALANÇO ATRAVÉS DA
ANÁLISE DE SINAIS DE VIBRAÇÃO E ESTATÍSTICAS DE ORDEM
SUPERIOR**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas e Automação, área de concentração em Engenharia de Sistemas e Automação, para a obtenção do título de Mestre.

Orientador

Dr. Danton Diego Ferreira

Coorientador

Dr. Daniel Augusto Pereira

LAVRAS - MG

2015

Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).

Barbosa, Tássio Spuri.

Detecção de falhas em vigas em balanço através da análise de sinais de vibração e estatísticas de ordem superior / Tássio Spuri Barbosa. – Lavras : UFLA, 2015.

89 p. : il.

Dissertação (mestrado acadêmico)–Universidade Federal de Lavras, 2015.

Orientador(a): Danton Diego Ferreira.

Bibliografia.

1. Vigas Em balanço. 2. Análise de Vibração. 3. Estatísticas de Ordem Superior. I. Universidade Federal de Lavras. II. Título.

TÁSSIO SPURI BARBOSA

**DETECÇÃO DE FALHAS EM VIGAS EM BALANÇO ATRAVÉS DA
ANÁLISE DE SINAIS DE VIBRAÇÃO E ESTATÍSTICAS DE ORDEM
SUPERIOR**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas e Automação, área de concentração em Engenharia de Sistemas e Automação, para a obtenção do título de Mestre.

APROVADO em 23 de fevereiro de 2015.

Dr. Daniel Augusto Pereira UFLA

Dr. Ricardo Rodrigues Magalhães UFLA

Dr. Augusto Santiago Cerqueira UFJF

Dr. Danton Diego Ferreira
Orientador

LAVRAS - MG

2015

RESUMO

Vigas em balanço são grandes aliadas no desenvolvimento de novas tecnologias para a Manutenção Preditiva, pois simulam de maneira eficiente estruturas comuns no dia a dia da Engenharia. Sua construção/composição assemelha-se a diversas estruturas presentes no dia a dia de equipamentos industriais e da construção civil e, por isso, são muito empregadas no desenvolvimento e teste de métodos de análise de detecção de falhas em estruturas. Pelo bom desempenho das vigas no auxílio do desenvolvimento desses métodos, objetivou-se, neste trabalho, propor uma nova técnica para a detecção de falhas em vigas em balanço, através da análise de sinais de vibração e Estatísticas de Ordem Superior (EOS). A inovação do trabalho está no emprego de cumulantes de segunda, terceira e quarta ordens, extraídos dos sinais de vibração da viga em balanço, para detectar a presença ou não de falhas, bem como o nível da falha, se houver. Para isso, foi desenvolvida uma bancada para a coleta dos sinais de vibração que foram então processados via software MatLab®. As EOS mais representativas, no que tange à detecção/classificação das falhas foram selecionadas utilizando-se do Discriminante Linear de Fisher e, em seguida, apresentadas a dois classificadores propostos para abordagens diferentes. Utilizou-se o classificador SVM (máquinas de vetor de suporte) não supervisionado para fazer a detecção de falhas numa abordagem em que não se conhecem as falhas. Para a abordagem em que as falhas são conhecidas utilizou-se um perceptron multicamadas (MLP), que detecta e identifica o nível da falha. Os resultados mostraram que as EOS são capazes de formar assinaturas compactas (apenas dois ou três parâmetros) dos tipos de falhas e dos sinais de vibração da viga sem falha, levando a classificadores com arquiteturas simples, que alcançaram desempenhos de 100% para as reduzidas janelas de sinais processadas.

Palavras-chave: Vigas Em balanço. Análise de Vibração. Estatísticas de Ordem Superior.

ABSTRACT

Cantilever Beams are great allies in the development of new technologies for Predictive Maintenance, given that they efficiently simulate common structures present in the daily life of engineering. The construction/composition of cantilever beams resembles many structures present in the daily life of industrial equipment and construction and, therefore, are widely employed in the development and testing of new analysis methods for detecting flaws in structures. Motivated by the good performance of beams in aiding the development of these methods, this paper proposes a new technique for the detection of flaws in cantilever beams by means of vibration signal analysis and Higher Order Statistics (HOS). The innovation of the work is in the use of second, third and fourth order cumulants, extracted from the vibration signals of the cantilever beam in order to detect flaws, if any, as well as to identify the level of the flaws. For this, we developed an experimental bench to collect vibration signals, which were subsequently processed via MatLab® software. The most representative HOS, in terms of flaw detection/classification capability, were selected using the Fisher's Discriminant Ratio and, later, presented to two classifiers proposed for different approaches. We used the unsupervised SVM (support vector machines) classifier for flaw detection in a scenario in which flaws are unknown. For the approach in which flaws are known, we used a multilayer perceptron (MLP), which detects and identifies the level of the flaws. The results showed that the HOS are capable of forming compact vector signatures (with only two or three parameters) of the types of flaws and of the vibration signals from the cantilever beam without flaw, leading to simple architecture classifiers that reach performances of 100% for small processed signal windows.

Keywords: Cantilever Beams. Vibration Analysis. Higher Order Statistics.

LISTA DE FIGURAS

Tabela 1	Estatísticas do sinal usadas como características sensíveis ao dano	24
Tabela 2	Desempenho do classificador SVM para a viga de alumínio	68
Tabela 3	Desempenho do classificador SVM para a viga de aço	69
Tabela 4	Desempenho da Rede Neural. SF= Sem Falha, FS = Falha Suave, FI = Falha Intermediária, FG = Falha Grave	71
Tabela 5	Desempenho da Rede Neural considerando 3 parâmetros. SF= Sem Falha, FS = Falha Suave, FI = Falha Intermediária, FG = Falha Grave	72

SUMÁRIO

1	INTRODUÇÃO	8
1.1	O que foi feito	10
1.2	Organização do Trabalho	12
2	REFERENCIAL TEÓRICO	14
2.1	Manutenção	14
2.2	Vigas em balanço	17
2.3	Análise de Vibração	20
2.4	Processamento dos Sinais	24
2.5	Estatísticas de Ordem Superior	26
2.5.1	Definições	28
2.6	Discriminante Linear de Fischer	31
2.6.1	FDR como classificador	32
2.6.2	FDR para seleção de parâmetros	33
2.7	Redes Neurais Artificiais	34
2.8	Generalidades	37
2.9	Construção de um hiperplano ótimo no espaço de parâmetros	41
2.10	One-Class-Learning	44
3	MATERIAL E MÉTODOS	46
3.1	Aquisição de Sinais	46
3.2	Análise dos Sinais	54
3.3	Projeto do Detector - Abordagem I	55
3.4	Projeto do Detector - Abordagem II	56
4	RESULTADOS E DISCUSSÃO	57
4.1	Análise de Sinais	57
4.2	Capacidade de discriminação das EOS	60
4.3	Resultados de Detecção - Abordagem I	65
4.4	Resultados de Detecção - Abordagem II	70
5	CONCLUSÃO E PERSPECTIVAS FUTURAS	73
	REFERÊNCIAS	75
	ANEXO	87

1 INTRODUÇÃO

Para fazer frente a mercados globalizados e com uma maior concorrência, as empresas veem-se obrigadas a evoluir para sobreviver. Essa evolução passa pela melhoria da qualidade de seus produtos e serviços, bem como pela redução de custo. De acordo com a *Plant Performance Group*, uma divisão da *Technology for Energy Corporation*, no que se refere ao custo, a atividade de manutenção pode ser responsável por cerca de 15 a 40% dos custos totais de operação de uma indústria (CUNHA, 2005).

A concorrência industrial obriga as empresas a uma constante busca por vantagens competitivas sobre seus principais concorrentes. O cliente final já não se encontra disposto a esperar pela disponibilidade de um produto e não admite defeitos de qualidade provenientes do processo produtivo. Em suma, o mercado atual enfrenta clientes exigentes, com grande facilidade de acesso a variadas marcas de diferentes tipos de produtos. Para satisfazer todos os requisitos e assegurar a sua margem de lucro, as empresas/indústrias precisam diminuir ao extremo todos os tipos de desperdícios, presentes na sua cadeia de produção (PEREIRA, 2012).

Esta eliminação do desperdício não pode ser feita de maneira irresponsável, é necessário prezar pela segurança dos colaboradores da empresa e pela preservação ambiental. Como as indústrias são constituídas por máquinas de grande porte e trabalham com variáveis que oferecem um grande risco à segurança dos colaboradores, se não fossem tomados os devidos cuidados com a manutenção, as chances de acidentes, que colocariam em risco a vida dos trabalhadores, seriam enormes. Ao mesmo tempo, as máquinas dessas indústrias trabalham muitas vezes com produtos poluentes, que se forem vazados para a natureza, por qualquer tipo de falha nas máquinas, podem causar danos ambientais incalculáveis.

Além disto, pensando na diminuição dos custos de produção, as empresas começam a usar materiais cujos prazos de degradação são ainda indeterminados e com margens de segurança inferiores. Nesse aspecto, prever quando a estrutura está perto de ter alguma falha torna-se fundamental na segurança da operação.

A Manutenção Preditiva, que é conhecida como manutenção baseada na condição, utiliza diversas técnicas para prever quando a peça ou componente de uma máquina estará próxima do seu limite de vida útil. Há muitas técnicas eficazes na detecção de defeitos e na avaliação do estado de um componente (COMPARE; ZIO, 2014; HUDA; TAIB, 2013; KALLIGEROS, 2014; LIAO; WANG, 2013; RUIZ-GONZALEZ et al., 2014; YUAN; JIANG; LIU, 2013), muitas são baseadas em análises de vibração, na condição do óleo de lubrificação em motores e em análise termográfica em máquinas rotativas, por exemplo. Quanto mais cedo ocorrer a detecção de falhas/defeitos, mais se tem controle sobre a situação da máquina (XENOS, 2004).

As técnicas preditivas têm por objetivo prevenir falhas e prolongar a vida útil dos equipamentos. Também permitem, através da análise periódica dos parâmetros da máquina, a indicação da natureza da falha, bem como a determinação dos elementos críticos do sistema.

Dentre as técnicas de manutenção preditivas disponíveis, a Análise de Vibração vem sendo muito difundida nos últimos anos pela eficiência em detectar falhas ainda em seu início, principalmente na indústria metal – mecânica e na construção civil. Podem-se destacar alguns trabalhos importantes nessa área, tais como (GARCIA; TRENDAFILOVA, 2014; GILLICH; PRAISACH, 2013; LABIB; KENNEDY; FEATHERSTON, 2014; SHOJAEI et al., 2012; XIANG et al., 2013).

Segundo Rao (2008), qualquer movimento que se repita com o passar de certo tempo pode ser denominado vibração ou oscilação. O número de

repetições por intervalo de tempo é chamado de frequência de vibração. Se após uma perturbação, um sistema continuar a vibrar sem a ação de forças externas, a frequência com que ele oscila é a sua frequência natural, também denominada frequência fundamental.

Um pequeno dano em uma estrutura causa mudanças em suas propriedades estruturais, tais como rigidez e massa, bem como nas propriedades dinâmicas da estrutura, que são as frequências naturais, modos de vibração e taxa de amortecimento (HIBBELER, 1997). Dessa forma, a presença de dano ou falha modifica a resposta vibratória de um sistema.

Neste contexto, o foco dessa dissertação de Mestrado é, através da análise dos sinais de vibração, desenvolver uma metodologia para detecção e análise de falhas em vigas em balanço, explorando as Estatísticas de Ordem Superior (EOS) e técnicas de Reconhecimento de Padrões.

A metodologia proposta é avaliada em sinais de vibrações coletados experimentalmente em laboratório, através de uma bancada de baixo custo, desenvolvida pelos próprios autores dessa dissertação e que é apresentada em detalhes no Capítulo 4.

1.1 O que foi feito

No contexto de análise de vibrações foi proposta uma metodologia para a detecção e classificação do nível de falhas em vigas em balanço, que basicamente utiliza um sistema de aquisição de sinais e reconhecimento de padrões.

Foram feitos diferentes tipos de falhas (cortes simulando trincas) em uma viga em balanço e para cada tipo de corte foi coletado um sinal de vibração, em um determinado intervalo de tempo.

Para a coleta de dados foi desenvolvido um sistema, em que uma placa Arduíno controla a rotação de um motor fixado próximo da extremidade engastada da viga (extremidade fixa), que funciona como atuador do sistema, e um sensor acelerômetro, fixa do próximo da extremidade oposta ao engaste (extremidade livre), que captou os sinais de vibração produzidos por esse atuador na viga em balanço. Para o Arduíno foi desenvolvido um algoritmo (vide Anexo A) para realizar o controle do sistema, acionar o motor e captar os sinais de vibração do sensor.

Usando o software Matlab[®], foram desenvolvidos os algoritmos de processamento de sinais e reconhecimento de padrões. Estatísticas de ordem superior (EOS) foram usadas para extrair os parâmetros dos sinais coletados e o Discriminante Linear de Fisher (FDR) foi aplicado para selecionar os melhores parâmetros dentre os extraídos. Posteriormente, foi projetado um classificador SVM que possibilitou a distinção entre as vigas sem falha e com falhas. Em relação ao classificador, foi utilizado o SVM não supervisionado (SCHOLKOPF et al., 2001), que geralmente é utilizado para detecção de *outliers*. A vantagem desse classificador é que ele pode ser projetado utilizando-se os dados de apenas uma das classes.

A fim de identificar o nível das falhas, foi projetada uma rede neural multicamadas, que permitiu identificar três níveis de falha: falha suave, falha intermediária e falha grave.

Com relação às Estatísticas de Ordem Superior, foram extraídos os cumulantes de segunda, terceira e quarta ordem dos sinais de vibração para diferentes atrasos.

Os sinais coletados foram divididos em diferentes eventos com diferentes números de amostras, a fim de investigar qual a configuração que apresentaria uma melhor eficiência na detecção das falhas.

1.2 Organização do Trabalho

Primeiramente é apresentada uma discussão sobre Manutenção, evolução das técnicas utilizadas na atualidade e como tudo isso influencia na competitividade de uma empresa no mercado, na segurança de seus colaboradores e no meio ambiente. Posteriormente, abordam-se noções sobre os estudos de vigas em balanço, porque são tão usadas para estudo de análise de vibrações e o que se tem estudado sobre esse assunto. Em seguida, apresentam-se algumas definições importantes sobre Análise de Vibração, sua influência na manutenção, modelagens matemáticas e trabalhos atuais sobre o assunto. Subsequente, uma contextualização sobre Processamento de Sinais e a sua importância, quais as vantagens de se trabalhar no domínio do tempo ou da frequência, além de uma apresentação das técnicas mais utilizadas na atualidade. Finalmente, as técnicas empregadas no desenvolvimento do método proposto são apresentadas, em que são mostradas as técnicas de EOS (Estatísticas de Ordem Superior), FDR (*Fisher Discriminat Ratio*), RNA (Redes Neurais Artificiais e SVM (Máquinas de Vetor de Suporte).

O Capítulo 3 refere-se ao que foi feito em relação a Material e Método. Nele são descritas as etapas do projeto, começando pela Aquisição de Sinais, que vai desde a montagem do sistema proposto no projeto até a coleta final dos dados. Depois é descrita a etapa de Análise de Sinais, que explica como foi feita essa análise. E por último, a etapa do projeto do detector, que é a técnica que vai finalizar a classificação das falhas na viga.

No Capítulo 4, são discutidos todos os resultados obtidos no trabalho. São plotados os gráficos desde os primeiros resultados até os de separação dos tipos de falhas na viga. E, por fim, é mostrado qual foi a eficiência obtida no final do projeto.

No Capítulo 5, são apresentadas as conclusões gerais desse trabalho. Mostrando onde se chegou com todas as técnicas propostas e quais os possíveis caminhos a seguir em futuros trabalhos.

2 REFERENCIAL TEÓRICO

2.1 Manutenção

Estudos de vibrações em estruturas como vigas em balanço são cada vez mais usadas na Engenharia para desenvolver técnicas mais modernas de manutenção. A origem da palavra manutenção vem do latim *manus tenere*, que significa “manter o que se tem” e está presente na vida do homem desde que se começou a manusear instrumentos de medição, há milhares de anos.

Shikari (2006) define manutenção como um conjunto de técnicas para manter o bom funcionamento de um sistema. O seu custo representa uma quantia significativa dos custos totais de operação de uma indústria. Em alguns ramos da indústria esse custo pode chegar a ser de 15 a 40 % do total, que representam a parte principal dos custos operacionais totais de todas as plantas industriais de manufatura e de produção. Por exemplo, em indústrias alimentícias, os custos médios de manutenção podem representar cerca de 15% do custo dos bens produzidos; enquanto que nas indústrias siderúrgicas, de papel e celulose, e outras indústrias pesadas, a manutenção pode representar até 30% dos custos totais de produção, de acordo com o *Plant Performance Group*.

Segundo Jardine, Lin e Banjevic (2006), manutenção é a combinação de ações técnicas, administrativas e de supervisão, destinadas a manter ou recolocar um equipamento em condições de desempenhar eficazmente as funções para as quais foi projetado. Representa, ainda, um conjunto de ações sistemáticas e procedimentos que visam manter as condições originais dos equipamentos, introduzindo melhorias para evitar a ocorrência ou reincidência de falhas e reduzir os custos. Deve ainda evitar a indisponibilidade dos equipamentos, abrangendo desde a aparência externa até as perdas de desempenho.

Para Kothamasu (2005), a manutenção designa um conjunto de atividades realizadas num dado sistema para mantê-lo em condições de funcionamento.

Em geral, manutenção é um conjunto de todas as ações e técnicas destinadas a manter a disponibilidade e a confiabilidade de um equipamento ou instalação para que possam desempenhar suas funções sempre que forem requeridos. Hoje, a manutenção é considerada um diferencial de competitividade entre as empresas, reduzindo custos de produção e assegurando qualidade.

Conforme Kardec, Nascif e Baroni (2002), a manutenção deve ser voltada prioritariamente para:

- a) aumento da disponibilidade e da confiabilidade dos equipamentos;
- b) redução da demanda de serviços;
- c) aumento do faturamento e do lucro;
- d) aumento da segurança pessoal e das instalações;
- e) preservação do meio ambiente;
- f) redução dos custos;
- g) segurança operacional;
- h) segurança do meio ambiente.

Há tempos era feita a Manutenção Corretiva conhecida como “quebra-conserta”. É a forma mais óbvia e primária de manutenção. Representa a forma mais cara de manutenção quando encarada do ponto de vista total do sistema. Acarreta uma baixa utilização anual dos equipamentos e máquinas, prejudicando a cadeia produtiva, além de diminuir a vida útil dos equipamentos e instalações. Quebras em horas inoportunas podem significar parada na produção em épocas de pico, levando ao não cumprimento do cronograma da fábrica e até mesmo a elevados prejuízos financeiros.

Com a evolução da indústria desenvolveu-se a Manutenção Preventiva, que consiste na prevenção dos defeitos que possam causar a parada de determinada máquina em operação. Essa prevenção é feita baseada em estudos estatísticos que levam em conta o estado do equipamento, local da instalação, condições elétricas e mecânicas de funcionamento, dados fornecidos pelo fabricante (condições ótimas de funcionamento, pontos e periodicidade de lubrificação, etc.), entre outros. Esse tipo de manutenção acarreta diminuição do número total de intervenções corretivas e, conseqüentemente, um considerável aumento da taxa de utilização anual dos sistemas de produção e de distribuição.

Depois do desenvolvimento de novas tecnologias auxiliadas por computadores, as empresas ganharam um grande aliado na busca pela maior produção possível, a Manutenção Preditiva. A implementação de novas técnicas e equipamentos como ultrassom, câmeras termográficas e testes baseados em análises de vibração faz com que a manutenção preditiva ganhe cada vez mais espaço na indústria atual (BENMOUSSAT et al., 2013; HUDA; TAIB, 2013; LEO et al., 2012; MÁRQUEZ et al., 2012; RAJ; NATARAJAN; GIRIKUMAR, 2013; WANG, 2013).

Este tipo de manutenção, nada mais é do que uma manutenção preventiva baseada na condição do equipamento. É interessante, pois permite o acompanhamento do equipamento através de medições realizadas quando ele estiver em pleno funcionamento, o que possibilita uma maior disponibilidade, já que esse vai sofrer intervenção somente quando estiver próximo de um limite estabelecido previamente pela equipe de manutenção (NOGUEIRA et al., 2012).

A manutenção preditiva é um meio de melhorar a produtividade, a qualidade do produto, o lucro, a efetividade global de plantas industriais de manufatura e de produção, segurança operacional e do meio ambiente. A manutenção preditiva pode também ser definida como uma filosofia ou atitude que usa a condição operacional real do equipamento e sistemas da planta

industrial para aperfeiçoar a operação total da planta industrial (ALMEIDA, 2000).

Recentemente, a identificação de dano estrutural à base de vibração, que é uma técnica de manutenção preditiva, ganhou muito interesse na pesquisa de Engenharia (ZHOU, 2006) e se tornou uma técnica muito popular, principalmente devido ao seu caráter não invasivo e não destrutivo na maioria das aplicações. Na próxima seção, será apresentada uma estrutura que é alvo de estudo de muitos engenheiros e pesquisadores, a viga em balanço. Por ser uma estrutura simples, que simula com eficiência muitas estruturas do mundo real e que pode ser estudada em análises teóricas e experimentais, tornou-se figura de destaque no estudo da manutenção preditiva.

2.2 Vigas em balanço

Muitos componentes de máquinas, veículos e estruturas são submetidos a carregamentos cíclicos, além de estarem sob influência de diversas fontes de vibração. Muitas vezes esses carregamentos e vibrações não geram tensões acima da tensão de escoamento do material, mas mesmo assim o podem gerar danos ao material, levando a uma falha ou dano estrutural do componente, cuja principal característica são perdas localizadas na rigidez da estrutura.

Este processo, que leva à falha do material, é denominado fadiga, que é objeto de estudo há mais de 150 anos, quando se começou a ter a necessidade de investigar as rupturas que ocorriam nos eixos das locomotivas (DOWLING, 1999).

Para estudar essas falhas e danos em geral, uma grande aliada da engenharia é a viga em balanço, que é uma viga com uma extremidade presa e outra extremidade livre, excitada por uma fonte não ideal. A viga é um dos elementos fundamentais de uma estrutura de engenharia, muito comum e

eficiente para se estudar técnicas de detecção de falhas. Ela pode ser usada para modelar diversos sistemas, como, por exemplo, uma semi-asa de avião, pontes, estruturas de aço, entre outros(ANDRADE, 2009).

Rizos e Aspragathos (1990) tiveram muito destaque fazendo a identificação da localização e magnitude de uma falha, em uma viga em balanço, a partir dos modos de vibração. O método pode ser utilizado para identificar fissuras em estruturas medindo as suas características modais. É um método de ensaio não destrutivo para a identificação de falhas e é aplicável a estruturas para as quais é possível uma análise estrutural.

Yang, Swamidas e Seshadri (2001) fizeram um estudo sobre identificação de falhas em vigas, usando o método da energia. Um modelo numérico baseado em energia foi desenvolvido para investigar a influência de rachaduras nas características dinâmicas estruturais, durante a vibração da viga.

Patil e Maiti (2005) fizeram uma verificação experimental de um método de detecção de múltiplas fissuras em vigas, com base em medições de frequências. A análise é baseada em método de energia e representação de uma falha como uma mola.

Fang, Luo e Tang (2005) propuseram a detecção de danos estruturais em uma viga usando uma Rede Neural. Usaram as funções de resposta em frequência como dados de entrada para uma Rede Neural *Back-Propagation*.

Hadjileontiadis, Douka e Trochidis (2005) fizeram a detecção de falhas em vigas usando *kurtosis*. O modo de vibração fundamental da viga com falha foi analisado e tanto a localização quanto o tamanho da falha foram estimados.

Vakil-Baghmisheh et al. (2008) fizeram a detecção de falhas em estruturas tipo vigas usando Algoritmos Genéticos. Foi usado um modelo analítico de uma viga com falha para simular o sistema, e as frequências naturais foram calculadas por métodos numéricos. O método utilizou os algoritmos

genéticos para monitorar as possíveis mudanças nas frequências naturais da estrutura.

Rosales, Filipich e Buezaz (2009) usaram duas técnicas para a detecção de falhas em vigas. Uma delas foi a Técnica de Séries de Potência (PST) e a outra o uso de Redes Neurais Artificiais (RNAs). E, por fim, foi proposto um método de combinação das duas técnicas.

Deokar e Walkchaure (2011) fizeram um experimento para investigar falhas em uma viga em balanço, usando a frequência natural como critério básico. As três primeiras frequências naturais foram consideradas como critério básico para detecção das falhas.

Satpal et al. (2013) estudou o Monitoramento da Integridade Estrutural (SHM – *Structural Health Monitoring*) de uma viga em balanço utilizando Máquinas de Vetor de Suporte (SVM). O SVM é usado para prever a intensidade e localização do dano em uma viga em balanço, simulando os deslocamentos do primeiro modo de vibração.

Yan et al. (2014) estudaram a identificação de danos em vigas baseados em Redes Neurais e Máquinas de Vetor de Suporte. Os dados utilizados foram obtidos a partir de simulações com o *software ANSYS®*. No final, os dois métodos foram comparados e concluiu-se que os dados estimados pelo SVM apresentam erros menores.

Nota-se que as vigas são estruturas importantes no desenvolvimento de técnicas de detecção, predição e localização de falhas, na qual se empregam várias técnicas de processamento de sinais e de aprendizagem de máquinas, usando sinais provenientes de uma fonte que causa a vibração na estrutura. Portanto, a análise de vibração em vigas em balanço tem um papel essencial no contexto desta Dissertação de Mestrado.

2.3 Análise de Vibração

Grande parte dos equipamentos vibram enquanto estão em operação e, através de equipamentos adequados, podemos captar quais são as frequências normais de vibração e quais aquelas que aparecem apenas quando o equipamento se encontra com defeito. A observação do nível de vibração, ao longo do tempo, permite tirar conclusões quanto à intensidade de vibração e às taxas de repetição de um determinado fenômeno. A ocorrência de alterações na forma original do sinal poderá indicar o início de um mecanismo de falha do equipamento ou um de seus componentes (FARRAR; WORDEN, 2013).

Uma fonte de vibração na máquina dá origem a uma perturbação que se propaga pela estrutura da máquina até o ponto de detecção. Transdutores podem detectar perturbação sob forma de sinal elétrico que é coletado e armazenado. Técnicas de análise, processamento e apresentação do sinal fornecem dados para diagnóstico do defeito por análise direta, junto com a análise de tendência e comparação com valores admissíveis, e então apresentam as informações necessárias para que se possa decidir se um planejamento de parada para manutenção deve ser feito na máquina.

Segundo Sinha (2010), a vibração de um sistema mecânico é uma constante troca entre energia cinética e energia potencial, sendo essa reduzida por um elemento dissipador. Assim, pode-se dizer que um corpo armazena energia na forma de vibração, até que seja totalmente dissipada. Caso haja uma excitação constante, o equilíbrio entre a excitação e a energia dissipada resultará em um determinado nível de vibração.

A teoria básica da identificação de um dano estrutural com base na vibração são as alterações nas propriedades estruturais, tais como rigidez e massa (JASSIM et al., 2013). A presença de uma falha influencia a resposta da vibração, bem como as propriedades dinâmicas da estrutura. Essas propriedades

dinâmicas são as frequências naturais, modos de vibração e taxas de amortecimento.

Um dano na estrutura causa a alteração da rigidez, o que leva à mudança dos modos de vibração bem como redução das frequências naturais e aumento das taxas de amortecimento. Muitos trabalhos utilizam esse tipo de análise, já que as alterações nos parâmetros são fáceis de serem observadas, conforme apontado em Maeck (2003).

Conforme Farrar e Worden (2013), várias ferramentas de processamento de sinais podem ser aplicadas na análise em estruturas por meio de sinais de vibrações. Muitas são qualitativas, pois dependem de inspeção visual dos sinais, comparando os que representam falhas de diferentes níveis de sinais com os que não representam falham. Por exemplo, a série temporal, o domínio da frequência, a autocorrelação, correlação cruzada, função de coerência e função resposta ao impulso. A maioria desses métodos, no entanto, requer conhecimento e controle do sinal de excitação, como a correlação cruzada ou até mesmo a análise na frequência e no tempo do sinal de vibração em resposta a alterações na excitação.

Considerando que a maioria das fábricas e processos produtivos baseia-se em equipamentos mecânicos sujeitos à vibração, a manutenção preditiva baseada na análise de vibração constitui uma das principais ferramentas usadas na maioria dos programas de gerência de manutenção, pois garante facilidade em detectar uma falha em seu estado inicial de forma não invasiva (DO; CHONG, 2011; GIUNTA et al., 2013; LIU et al., 2013; THINH; NGUYEN, 2013; VIOLA; TORNABENE; FANTUZZI, 2013). Dessa forma, a manutenção das máquinas tem desempenhado um papel fundamental na estrutura das empresas nos últimos anos, pelo fato de aumentar a confiabilidade e a disponibilidade das máquinas, fundamentais nos processos de fabricação influenciando de forma direta os custos de produção.

Nesta linha, a aplicação adequada de uma estratégia de manutenção preditiva com base em análise de vibração e técnicas complementares tem sido fundamental. O monitoramento da condição (*Condition Monitoring*) tem sido implantado com sucesso em indústrias que empregam máquinas rotativas em geral desde quando começou a ser implantada em refinarias e petroquímicas no início dos anos 70. Esse sucesso é devido a resultados econômicos obtidos em curto prazo, pois a redução das intervenções de manutenção foi de até 70%. Estudos de situações reais mostram uma economia de até 75% nos custos de manutenção nas empresas que aderiram a esse procedimento, e isso resulta em um rápido retorno no investimento com a instrumentação para a monitoração de vibração.

Como a análise de vibração vem sendo cada vez mais difundida, surgiram normas, como a ISO (*International Standard Organization*) 2372, que são usadas para determinar a condição de uma máquina mediante a análise de severidade de vibração. Em muitos casos, o valor da velocidade de vibração em RMS (*Root Mean Square*) é estabelecido em critério de normas.

O estudo da vibração diz respeito aos movimentos oscilatórios de corpos e às forças que lhes são associadas. Todos os corpos dotados de massa e elasticidade são capazes de produzir vibração. Desse modo, a maior parte das máquinas e estruturas está sujeita a certo grau de vibração e o seu projeto requer geralmente o exame de seu comportamento oscilatório.

Estes sistemas oscilatórios podem ser divididos em duas categorias: lineares e não lineares. Os sistemas lineares apresentam modelos matemáticos de fácil aplicação, ao contrário dos sistemas não lineares que necessitam de outros métodos e estudos mais profundos para serem definidos perfeitamente.

Em geral, a principal etapa de um projeto de uma determinada estrutura sujeita às vibrações mecânicas é a determinação de suas frequências naturais,

que devem ser consideradas para verificar a possibilidade da ocorrência do fenômeno da ressonância (ANDRADE, 2009).

Quando o corpo possui apenas vibrações próprias do seu sistema, no caso a vibração natural, ele tem uma vibração do tipo livre. Se ele está sofrendo vibrações devido a esforços externos, ele possui uma vibração forçada. Se essa vibração forçada coincidir com a frequência natural do sistema ocorrerá a ressonância, podendo causar, a partir daí, amplas e perigosas oscilações. Esse efeito de ressonância leva a grandes deformações e falhas mecânicas e é causador de muitos acidentes graves como queda de pontes, edifícios e danos em asas de aviões (FARRAR; WORDEN, 2013).

O trabalho de Farrar e Worden (2013) apresenta uma boa revisão sobre as técnicas de reconhecimento de padrões aplicadas à detecção de falhas por meio de vibrações. Em seu trabalho, Farrar e Worden (2013) destacam alguns parâmetros que podem ser extraídos de um sinal de vibração descrito no tempo $y[k]$, para fins de detecção, classificação e localização de falhas (Tabela 1).

Na prática, os sinais de vibração consistem em um somatório de sinais periódicos de diferentes frequências, não sendo possível a distinção clara entre elas no domínio do tempo. Muitas vezes, através da análise espectral (domínio da frequência) é possível a identificação de cada frequência, com seus respectivos níveis de vibração (AMEZQUITA-SANCHEZ et al., 2013; CHEN et al., 2014; FAN; ZHENG, 2005; MCINERNY; DAI, 2003). Portanto, o uso de técnicas avançadas de processamento de sinais na análise de sinais de vibração é requerido e constituiu-se em um dos objetivos dessa Dissertação de Mestrado.

Tabela 1 Estatísticas do sinal usadas como características sensíveis ao dano

Amplitude de pico y_{peak}	$y_{peak} = \max y_i $
Média (\bar{y})	$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$
Média Quadrada (\bar{y}_{sq})	$\bar{y}_{sq} = \frac{1}{n} \sum_{i=1}^n (y_i)^2$
Raiz da Média Quadrada (rms)	$rms = \sqrt{\frac{1}{n} \sum_{i=1}^n y_i^2}$
Variância (σ^2) ^a	$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2$
Desvio Padrão (σ) ^a	$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2}$
Assimetria (γ) ^a	$\gamma = \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^3}{\sigma^3}$
Kurtosis (k) ^a	$k = \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^4}{\sigma^4}$
Fator de Crista (X_{cf})	$X_{CF} = \frac{y_{peak}}{rms}$
Fator-K (X_k)	$X_k = (y_{peak})(rms)$

2.4 Processamento dos Sinais

O processamento de sinais consiste na análise e transformação de sinais de forma a extrair informações deles e torná-los mais apropriados para alguma aplicação específica. O processamento trabalha com a representação matemática do sinal e com o processo de cálculo para extrair essa informação. “Técnicas de

processamento de sinal são utilizadas na manutenção preditiva para extrair informações que permitam correlacionar características do sinal com o estado do equipamento” (NICTERWITZ, 2013, p. 1).

Antes o processamento de sinais era feito apenas por meio de sinais analógicos, mediante o emprego de componentes analógicos como resistores, capacitores e indutores, entre outros. Esse tipo de processamento era bastante limitado em eficiência e aplicações e essas limitações afetavam consideravelmente a eficiência do processo. Com a evolução e o barateamento dos processadores, memórias, etc, o processamento que antes era feito através de circuitos eletrônicos complexos, passou a ser feito digitalmente, com a filtragem, compactação, codificação, modulação etc. (BAYRAM; SEKER, 2013; FENG; PAN, 2012; MOHAMMED et al., 2013; OLTEAN et al., 2013; WANG; CHENG; ZHAO, 2010).

Em experimentos e aplicações práticas em Engenharia, após a coleta de dados, é necessário usar técnicas para se obter um sinal ideal para a análise. Por exemplo, de acordo com Seifert e Camacho (2007), o sinal de vibração coletado por um acelerômetro apresenta uma perda significativa da sensibilidade e com isso uma perda da capacidade de medição levando a resultados incorretos. Por isso é necessária uma manipulação do sinal adquirido, amplificando-o e filtrando ruídos desnecessários, processo chamado de condicionamento de sinais.

O condicionamento de sinais compreende as etapas de aquisição, filtragem, tratamento e armazenamento. Para realizar essas etapas é necessário compreender vários conceitos da área de processamento de sinais, como amostragem, resolução, correlação, convolução, FFT (*Fast Fourier Transform*) (GEORGOULAS et al., 2013; MITRA, 2000; PENNY; FRISWELL; INMAN, 2012; WANG; KANG, 2012), dentre outros.

Tanto a análise no domínio do tempo quanto no domínio da frequência, apesar de eficientes, possuem algumas limitações. Duas dessas limitações se

referem a quando se tem uma alta frequência: limitação da velocidade do conversor analógico-digital e complexidade da aplicação, inviabilizando a operação em tempo real (MELO, 2008).

A análise no domínio do tempo tem a vantagem de permitir a identificação de fenômenos transitórios e impactos. Além disso, permite uma boa localização dos eventos, embora tenha a desvantagem de, geralmente, não conseguir determinar a natureza desses.

Neste trabalho, os sinais no domínio do tempo e no domínio da frequência foram analisados para verificar a possibilidade de obter-se uma distinção entre as classes, mas não foram nada conclusivos. Então, depois dessa análise preliminar, o primeiro tratamento dos sinais de vibração coletados foi a aplicação das Estatísticas de Ordem Superior (EOS), que extraíram os parâmetros dos sinais para cada tipo de classe das vigas. A seção 2.5 introduz os principais conceitos e definições de EOS.

2.5 Estatísticas de Ordem Superior

A maioria das técnicas de processamento de sinais tem vantagens e limitações que determinam sua aplicação em relação ao tipo de sinal, desempenho e complexidade computacional. Grande parte das estatísticas usadas contemplam apenas a autocorrelação, ou seja, estatísticas de segunda ordem. As principais justificativas para esse fato são que (CHANAVEL, 2002):

- a) processos gaussianos ou hipoteticamente gaussianos são inteiramente caracterizados por seus momentos de primeira e segunda ordens;
- b) muitos resultados de cunho prático utilizam apenas estatísticas de segunda ordem como, por exemplo, a teoria da predição linear;

- c) as estatísticas de segunda ordem também são suficientes para caracterizar sistemas cujas saídas podem ser modeladas como filtros, com resposta em frequência conhecida e ruído branco gaussiano na entrada.

No entanto, alguns problemas são de natureza não gaussiana. Nesses casos, as informações estão presentes não apenas na autocorrelação, mas também na estatística de ordem superior (EOS), definidas por momentos e cumulantes (CHANAVEL, 2002). Embora a EOS seja definida em termos de momentos e cumulantes, esses possuem características distintas. Enquanto momentos são utilizados na análise de sinais determinísticos, os cumulantes são usados na análise de sinais estocásticos (NIKIAS; MENDEL, 1993).

Conforme Mendel (1991), as estatísticas de ordem superior (EOS) podem levar a resultados mais representativos quando empregadas em processos não gaussianos e sistemas não lineares do que as estatísticas de segunda ordem. Sabe-se que um sinal gaussiano é completamente caracterizado pela sua média e variância. Consequentemente, as EOS de um sinal gaussiano são nulas ou possuem informações redundantes. Logo, as EOS são menos afetadas por ruídos gaussianos do que as estatísticas de segunda ordem.

Dado que muitas aplicações práticas possuem ruído aditivo gaussiano, as EOS têm sido utilizadas com bastante frequência, conforme é mostrado em Mendel (1991). No que tange ao monitoramento de sinais, as EOS têm sido utilizadas como parâmetros que alimentam sistemas de detecção e classificação de distúrbios elétricos com bastante sucesso (FERREIRA et al., 2009, 2011; RIBEIRO et al., 2007).

No monitoramento de condições de estruturas destacam-se os trabalhos de Gelman (2013), Hassam et al. (2012), Said, Ali e Fnaiech (2014) e Said et al.(2013), que utilizaram análise espectral de ordem elevada (*High Order*

Spectra) para detecção de barras quebradas em motores de indução, falhas em estruturas de maquinarias e em sistemas aeroespaciais.

Dentre muitas razões para a utilização da EOS em processamento de sinais, além da caracterização de processos não gaussianos, as mais relevantes são (NIKIAS; MENDEL, 1993; NIKIAS; PETROPULU, 1993):

- a) supressão de ruído colorido gaussiano de espectro desconhecido;
- b) identificação e reconstrução de sinais com fase não mínima;
- c) extração de informações quanto ao desvio do modo gaussiano;
- d) detecção e caracterização de propriedades não lineares presentes no sinal;
- e) identificação de sistemas não lineares.

No contexto da presente Dissertação de Mestrado, a escolha pelas estatísticas de ordem superior como parâmetros para análise de sinais de vibração deu-se pelas seguintes razões: i) a literatura atual mostra o sucesso da aplicação de EOS para a caracterização de sinais com fenômenos transitórios, para fins de reconhecimento de padrões (FERREIRA et al., 2009, 2011; RIBEIRO et al., 2007).

2.5.1 Definições

Conforme supracitado e apontado em Mendel (1991), as EOS podem ser definidas em termos de momentos e cumulantes. Momentos são mais indicados para sinais determinísticos, enquanto cumulantes são mais aplicados em sinais aleatórios. Como os sinais de vibração apresentam, em sua maioria, características não lineares (FARRAR; WORDEN, 2013), o uso de métodos baseados em cumulantes pode ser muito promissor na classificação e detecção

de falhas. De fato, vetores extraídos do sinal de vibração com técnicas baseadas em EOS são capazes de fornecer, para cada classe de falhas, informações muito bem definidas.

De acordo com Mendel (1990), o cumulante de segunda ordem $C_{2,x}(\tau)$ é apenas a autocorrelação de $x(t)$. Se $x(t)$ é um processo aleatório simetricamente distribuído então o cumulante de terceira ordem é igual a zero. Nesse caso, o cumulante de quarta ordem seria o mais indicado. Adicionalmente, em alguns processos, os valores dos cumulantes de terceira ordem são muito pequenos enquanto que os valores dos cumulantes de quarta ordem são muito grandes. Nesse caso, o cumulante de quarta ordem também é o mais indicado.

As expressões dos cumulantes de segunda, terceira e quarta ordens de um sinal aleatório $x[n]$, quando $E\{x[n]\} = 0$, são respectivamente (MENDEL, 1991):

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

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

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

em que i é o i -ésimo atraso, e $x[n]$ é o n -ésimo elemento do vetor \mathbf{x} .

Para um vetor com comprimento finito (N), as aproximações estocásticas oferecem as seguintes expressões (MENDEL, 1991):

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

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

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

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

Note que as Equações (4) e (6) não podem ser usadas se $i > N/2 + 1$, pois $n + i$ será maior que N . Dessa forma, perdem-se informações no cálculo dos cumulantes. Em Ribeiro et al. (2007), foi proposta uma abordagem alternativa, em que cada cumulante é calculado utilizando todas as N amostras de sinal disponível. Basicamente, forma-se um tipo de *Buffer* circular nos sinais, de tal forma que se o valor de $n + i$ for maior que N em k unidades, este valor é substituído por k , tomando com isso as amostras antecessoras ao valor i , que anteriormente não eram utilizadas. Na verdade, é como se houvesse uma continuidade da última amostra para a primeira, fazendo com que o sinal seja virtualmente circular.

Matematicamente, a substituição de $n + 1$, quando $n + 1 > N$, pode ser dada por:

$$\text{mod}(n + i, N) = [n + i] - bN, \quad (7)$$

em que b é o número inteiro obtido quando se desconsideram as casas decimais da divisão de $n + i$ por N , o que na verdade resulta no resto da divisão de $n + i$ por N .

Assim, as expressões (1) e (3) podem ser estimadas, para N finito, por:

$$\hat{C}_{2,x}[i] := \frac{2}{N} \sum_{n=0}^N x[n]x[\text{mod}[n + i, N]], \quad (8)$$

$$\hat{C}_{3,x}[i] := \frac{2}{N} \sum_{n=0}^N x[n] x^2[\text{mod}[n+i, N]], \quad (9)$$

e

$$\hat{C}_{4,x}[i] := \frac{2}{N} \sum_{n=0}^N x[n] x^3[\text{mod}[n+i, N]] - \frac{2}{N^2} \sum_{n=0}^N x[n] x[\text{mod}[n+i, N]] \sum_{n=0}^N x^2[n], \quad (10)$$

em que $\text{mod}[n+i, N]$ é o resto inteiro da divisão de $n+i$ por N .

Pode-se observar que, para um sinal com N amostras, tem-se N cumulantes para cada ordem de EOS. Para efeitos de classificação e detecção, a combinação de poucos destes cumulantes é suficiente para a obtenção de um bom desempenho, conforme mostrado em Ferreira et al. (2011) e Ribeiro et al. (2007).

Após a extração dos parâmetros (cumulantes de segunda, terceira e quarta ordens) nos sinais de vibração coletados, o próximo passo é selecionar quais são os melhores parâmetros que irão proporcionar uma melhor eficiência do classificador. A técnica usada para a seleção desses parâmetros foi o Discriminante Linear de Fischer (FDR – *Fischer Discriminant Ratio*).

2.6 Discriminante Linear de Fischer

Após a extração dos parâmetros pelas Estatísticas de Ordem Superior, que foram descritas na seção anterior, será feita a seleção dos melhores parâmetros para classificação através do Discriminante Linear de Fisher (*FDR – Fisher Discriminant Ratio*).

O discriminante linear de Fisher é uma técnica bastante simples para discriminação de dados multidimensionais. Conforme bem discutido em Duda, Hart e Stork (2000), o FDR tem duas principais e diferentes aplicações: pode ser usado como separador de classes e como ferramenta de seleção de parâmetros.

2.6.1 FDR como classificador

Para entender ambas as aplicações do FDR, suponha um espaço de n eventos d -dimensionais, $\mathbf{x}_1, \dots, \mathbf{x}_n$, em que n_1 é o subconjunto de eventos pertencentes à classe 1 (C_1) e n_2 à classe 2 (C_2). Se a média das amostras d -dimensionais da classe i é:

$$\mathbf{m}_i = \frac{1}{n_i} \sum_{\mathbf{x} \in C_i} \mathbf{x} \quad (11)$$

Podem-se definir as matrizes *scatters* \mathbf{S}_i , \mathbf{S}_W e \mathbf{S}_B por:

$$\mathbf{S}_i = \sum_{\mathbf{x} \in C_i} (\mathbf{x} - \mathbf{m}_i) (\mathbf{x} - \mathbf{m}_i)^T \quad (12)$$

$$\mathbf{S}_W = \mathbf{S}_1 + \mathbf{S}_2 \quad (13)$$

e

$$\mathbf{S}_B = (\mathbf{m}_1 - \mathbf{m}_2)(\mathbf{m}_1 - \mathbf{m}_2)^T \quad (14)$$

em que T significa transposto.

A matriz \mathbf{S}_W é conhecida por matriz *scatter* intraclasses e é proporcional à matriz de covariância dos dados. É também simétrica, semidefinida positiva e, usualmente, não singular se $n > d$. A matriz \mathbf{S}_B é também simétrica e semidefinida positiva. É chamada de matriz *scatter* entreclasses.

Em termos de \mathbf{S}_W e \mathbf{S}_B , a função custo para o critério FDR como discriminante é escrita como:

$$\mathbf{J}(\mathbf{w}) = \frac{\mathbf{w}^T \mathbf{S}_B \mathbf{w}}{\mathbf{w}^T \mathbf{S}_W \mathbf{w}} \quad (15)$$

O vetor \mathbf{w} que maximiza $\mathbf{J}(\cdot)$ será:

$$\mathbf{w} = \mathbf{S}_W^{-1}(\mathbf{m}_1 - \mathbf{m}_2) \quad (16)$$

Assim, o vetor \mathbf{w} obtido representa a máxima razão entre a matriz *scatter* entreclasses e a intraclass. Dessa forma, o processo de classificação é convertido de um espaço D -dimensional para um espaço unidimensional. Nesse novo espaço, pode-se obter um limiar que fará a separação entre os dados projetados em \mathbf{w} das classes 1 e 2.

2.6.2 FDR para seleção de parâmetros

Diferentemente do critério FDR para classificação, a função custo do critério FDR como ferramenta de seleção de parâmetros é:

$$\mathbf{J}_C = (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^2 \odot \frac{1}{\sigma_1^2 + \sigma_2^2} \quad (17)$$

Onde $\mathbf{J}_C = [J_1 \cdots J_{L_l}]^T$, L_l é o número total de parâmetros, $\boldsymbol{\mu}_1$ e $\boldsymbol{\mu}_2$, e σ_1^2 e σ_2^2 são, respectivamente, os vetores de média e variância dos dados da classe 1 e da classe 2. O símbolo \odot refere-se ao produto de Hadamard $\mathbf{r} \odot \mathbf{s} = [r_0 s_0 \cdots r_{L_l-1} s_{L_l-1}]^T$.

Pode-se entender que os i -ésimos elementos do vetor de parâmetros, referentes aos maiores valores de J_c , representam os parâmetros que apresentam melhor separabilidade entre classes. Essa técnica é bastante útil em processos de classificação mais complexos, uma vez que torna possível selecionar os melhores parâmetros (que mais discriminam as classes envolvidas) e, conseqüentemente, reduzir o número de parâmetros utilizado na classificação. Essa redução de parâmetros é atraente em sistemas que necessitam de menor complexidade computacional, tais como sistemas que operam em tempo real. Ademais, o uso de um número reduzido de parâmetros pode levar ao projeto de classificadores mais simples e com melhor desempenho, já que os parâmetros responsáveis pela interseção entre classes são, teoricamente, descartados.

A generalização da Equação (17) para o FDR, para M classes é dada por:

$$J_c = \sum_i^M (\mu_i - \mu_j)^2 \odot \frac{1}{\sigma_i^2 + \sigma_j^2} \quad (18)$$

Posteriormente à seleção dos melhores parâmetros, serão trabalhadas duas abordagens, apresentadas em detalhes no Capítulo 4, para a classificação dos sinais de vibração coletados das vigas. Em uma abordagem serão usadas as Redes Neurais Artificiais e na outra abordagem serão usadas as Máquinas de Vetores de Suporte (SVM).

2.7 Redes Neurais Artificiais

As redes neurais artificiais (RNA) (HAYKIN, 2008) apresentam uma grande versatilidade na resolução de diversos tipos de problemas, como em sistemas de reconhecimento de padrões, compressão de voz e imagem, pilotos automáticos de aviões, sistemas de predição de taxa de câmbio, desenvolvimento de produtos, controle de processos, análises de eletroencefalograma (EEG) e

eletrocardiograma (ECG), e vários outros problemas, em diferentes áreas (ERKAYA, 2012; LIU et al., 2013; MOHAMMED et al., 2014; RAO; PAI; NAGABHUSHANA, 2012; SU; CHONG; KUMAR, 2011). E dentro do contexto desta Dissertação de Mestrado, o reconhecimento de padrões será de suma importância na classificação dos tipos de falhas na viga em balanço.

Das diversas arquiteturas (estruturas) de redes, a mais utilizada em aplicações de reconhecimento de padrões é a rede alimentada diretamente com múltiplas camadas. Conforme definido em Haykin (2008), essa rede consiste de um conjunto de unidades sensoriais que constituem a camada de entrada, uma ou mais camadas ocultas e uma camada de saída. O sinal de entrada se propaga para frente através da rede, camada por camada. Tais redes são, normalmente, chamadas de perceptrons de múltiplas camadas (MLP –*Multilayer Perceptron*) (ROSENBLANTT, 1962). A Figura 1 ilustra um perceptron com quatro camadas, sendo duas camadas ocultas.

Os perceptrons de múltiplas camadas têm sido aplicados com bastante sucesso para resolver diversos problemas complexos através do seu treinamento, de forma supervisionada com um algoritmo muito popular conhecido como algoritmo de retropropagação de erro (*error back-propagation*) (HAYKIN, 2008).




Figura 1 Perceptron de múltiplas camadas

As RNA extraem informações relevantes de padrões de informações que lhe forem apresentadas, criando assim uma representação própria. Essa etapa é conhecida por aprendizagem, ou treinamento, e consiste em um processo iterativo de ajuste de parâmetros da rede e dos pesos de conexões entre as unidades de processamento. E esses guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente que está operando.

Nesta etapa, destaca-se o algoritmo *Resilient Propagation* (Rprop) (RIEDMILLER; BRAUN, 1993), que tem capacidade de acelerar o processo de aprendizagem. A principal característica desse algoritmo é que os ajustes dos pesos (ω) e da taxa de aprendizado (η) dependem apenas dos sinais dos gradientes da função erro $E(\omega)$, não dependendo, portanto, da sua amplitude. A função $E(\omega)$ é responsável pela especificação de um critério de desempenho que está associado à rede (HAYKIN, 2008).

No algoritmo Rprop, os pesos e a taxa de aprendizagem são alterados apenas uma única vez a cada época de treinamento. Cada peso ω_{ij} possui sua própria taxa de variação Δ_{ij} , a qual varia conforme a Equação (19) (RIEDMILLER; BRAUN, 1993).

$$\Delta_{ij}^{(t)} = \begin{cases} \eta^+ \Delta_{ij}^{(t-1)}, & \text{se } \frac{\delta E^{(t-1)}}{\delta \Delta w_{ij}} \frac{\delta E^{(t)}}{\delta \Delta w_{ij}} > 0 \\ \eta^- \Delta_{ij}^{(t-1)}, & \text{se } \frac{\delta E^{(t-1)}}{\delta \Delta w_{ij}} \frac{\delta E^{(t)}}{\delta \Delta w_{ij}} < 0 \\ \Delta_{ij}^{(t-1)}, & \text{caso contrário} \end{cases} \quad (19)$$

em que, $0 < \eta^- < 1 < \eta^+$. Assim, cada vez que a derivada parcial do peso correspondente ω_{ij} alterar o sinal, significa que a última atualização foi muito excessiva e o algoritmo pulou o mínimo local. Como consequência, o valor de Δ_{ij} é reduzido pelo fator η^- . Se o sinal da derivada se mantém, o valor de Δ_{ij} é levemente aumentado para acelerar o processo de convergência. Os pesos da rede são então alterados, conforme mostra a Equação (20).

$$\omega_{ij}^{(t+1)} = \omega_{ij}^{(t)} + \Delta_{ij}^{(t)} \quad (20)$$

em que $\omega_{ij}^{(t)}$ é definido conforme Equação (21)

$$\omega_{ij}^{(t)} = \begin{cases} -\omega_{ij}^{(t)}, & \text{se } \frac{\delta E^{(t)}}{\delta \Delta w_{ij}} > 0 \\ +\omega_{ij}^{(t)}, & \text{se } \frac{\delta E^{(t)}}{\delta \Delta w_{ij}} < 0 \\ 0, & \text{caso contrário} \end{cases} \quad (21)$$

2.8 Generalidades

Nas pesquisas desenvolvidas recentemente nas áreas de detecção de falhas nota-se uma preocupação muito grande com dois parâmetros: eficiência elevada aliada a um baixo esforço computacional (FERREIRA, 2007). Por exemplo, em situações em que o método é aplicado em tempo real, um baixo

esforço computacional é essencial, enquanto que para aplicações *off-line* a alta eficiência é mais importante.

O método SVM apresenta uma elevada eficiência na classificação com um esforço computacional relativamente alto, comparado a outros métodos (FERREIRA, 2007). Para compensar o esforço computacional, é recomendável o uso de uma técnica simples e eficiente de extração de parâmetros.

O SVM constitui uma técnica de aprendizado de máquinas, fundamentada pela teoria do aprendizado estatístico desenvolvida por Vapnik (1995). Essa teoria estabelece uma série de princípios que devem ser seguidos na obtenção de classificadores com uma boa generalização. Na formulação do SVM, o espaço de entrada original é mapeado para um espaço de alta dimensão em que uma simples função de separação linear pode ser usada para separar duas classes.

O SVM pode ser usado para classificar dados em duas ou mais classes. Considerando um conjunto de pontos que possuam duas classes, o SVM estabelece um hiperplano que coloca a maioria dos pontos da mesma classe no mesmo lado, enquanto maximiza a distância entre duas classes do presente hiperplano. A distância entre uma classe e um hiperplano é a menor distância entre o hiperplano e os outros pontos da mesma classe, e é chamado de hiperplano de separação ótima. O hiperplano criado pelo SVM contém um subconjunto de pontos das duas classes, chamados de vetores de suporte (BACCARINI et al., 2011).

Diversos trabalhos que utilizam SVM, para o propósito de diagnósticos de falhas mecânicas, vêm sendo realizados recentemente, com destaque para os trabalhos de Baccarini et al. (2011), Kim et al. (2012) e Li et al. (2012).

Boas propriedades de classificação das SVMs, tais como a boa capacidade de generalização e a não necessidade do conhecimento de todas as

classes do problema, foram apresentadas em Burges (1998), Salat e Osowski (2004) e Vapnik (1998).

O objetivo do SVM é encontrar um hiperplano que divide as classes, 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 e o hiperplano. Para tratar dados não linearmente separáveis, SVM promove uma transformação do espaço de entradas para um espaço de dimensão mais alta, denominado espaço de parâmetros. A função que realiza essa transformação é denominada função *kernel*. Um exemplo de um hiperplano ideal com duas classes de dados em duas dimensões é apresentado na Figura 2.

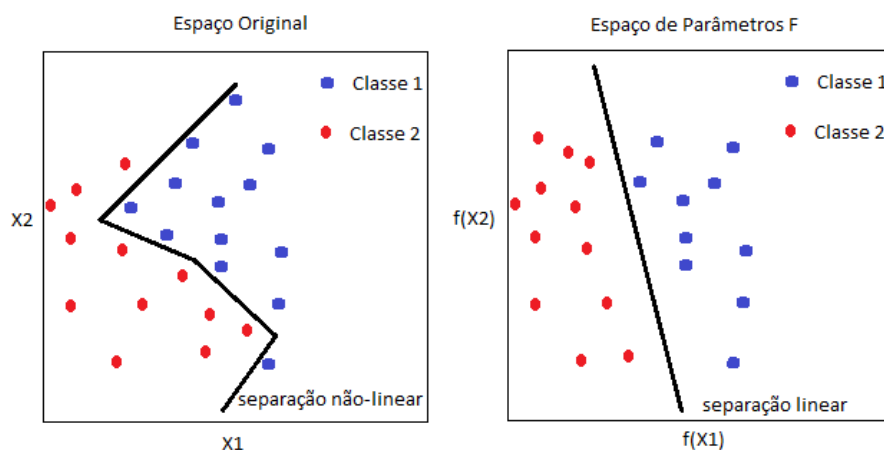


Figura 2 Representação do mapeamento não linear dos vetores de entrada (à esquerda) e os vetores mapeados no novo espaço pelo SVM (à direita)

No novo espaço de parâmetros, conforme ilustrado na Figura 2, a separação linear é obtida e se torna possível a separação entre as duas classes com apenas um hiperplano ótimo, que as separa linearmente.

As principais vantagens das SVMs são o uso de núcleos (*kernels*, que não são necessariamente funções não-lineares), o fato da função ser convexa, o que evita a convergência a ótimos locais, e a alta eficiência obtida pela otimização dos limites. Por outro lado, as principais desvantagens do SVM são a dificuldade de escolha da função *kernel* correta e de seus parâmetros, além da velocidade e dimensão do algoritmo de treinamento, que baseia-se no ajuste dos pesos, e teste, uma vez que o desempenho depende diretamente da escolha da função *kernel* e seus parâmetros, ao passo que a dimensão da máquina depende do conjunto de treinamento e da complexidade do problema.

Além disso, o SVM é capaz de alcançar um desempenho notável sem que qualquer conhecimento da função base, que gera o *kernel*, seja usado no projeto da máquina.

Normalmente, o treinamento de uma SVM consiste de um problema de programação quadrática, que é atrativo por duas razões:

- a) É garantido que se encontre um extremo global da superfície de erro, onde o erro se refere à diferença entre a resposta desejada e a saída do SVM;
- b) os cálculos computacionais podem ser realizados eficientemente.

Se for usado um núcleo do produto interno (*kernel*) adequado, o SVM calcula automaticamente todos os parâmetros importantes da rede, relativos àquela escolha do núcleo.

Considerando um desempenho de generalização similar, as SVMs exigem um pouco mais de esforço computacional que redes neurais, para um desempenho de generalização similar. Segundo Haykin (2008), há duas razões para isso:

- a) não há controle sobre o número de pontos de dados selecionados pelo algoritmo de aprendizagem para serem usados como vetores de suporte;
- b) não há meios para incorporar conhecimento prévio sobre a tarefa em questão no projeto da máquina de aprendizagem.

2.9 Construção de um hiperplano ótimo no espaço de parâmetros

Sendo $\{x_i, y_i\}_{i=1}^N$ um conjunto de treinamentos, onde \mathbf{x}_i é o padrão de entrada para o i -ésimo exemplo e y_i é a resposta desejada correspondente (saídaalvo), o hiperplano de separação é definido como:

$$f(x) = \mathbf{w}\varphi(x) + b, \quad (22)$$

onde \mathbf{w} é um vetor n -dimensional de peso ajustável, b é o desvio e $\varphi(\cdot)$ é a função não-linear que mapeia o vetor de entrada para o espaço de parâmetros.

Considerando um problema de duas classes, pode-se definir $y_i = +1$ para a classe 1 e $y_i = -1$ para a classe 2 e, conseqüentemente, $f(x) > 0$ para o hiperplano de separação se \mathbf{x} pertencer à classe positiva e $f(x) \leq 0$ se \mathbf{x} pertencer à classe negativa, resultando

$$y_i(\mathbf{w}_0\varphi(\mathbf{x}_i) + b_0) > 0 \quad (23)$$

Os pontos de dados particulares (x_i, y_i) , para os quais a Equação (23) é satisfeita com sinal de igualdade, são chamados de *vetores de suporte*. Em termos conceituais, os vetores de suporte são aqueles pontos de dados que se encontram mais próximos da superfície de decisão (HAYKIN, 2008). É

importante ressaltar que a habilidade de generalização das máquinas é maximizada com o hiperplano ótimo.

A distância entre o hiperplano, definido por um dado vetor de peso \mathbf{w} e o desvio b , e o ponto de dado mais próximo, é chamada de margem de separação, denotada por ρ . O objetivo da SVM é encontrar o hiperplano ótimo que maximize a margem de separação. Essa margem pode ser descrita por:

$$\rho = \frac{2}{\|\mathbf{w}\|} \quad (24)$$

que é equivalente a minimizar a norma Euclidiana do vetor de pesos \mathbf{w} . Portanto, o hiperplano ótimo pode ser obtido, solucionando o problema de otimização quadrática, dado por:

$$\text{Minimizar: } \frac{1}{2} \mathbf{w}^T \mathbf{w} \quad (25)$$

$$\text{Sujeito a: } y_i (\mathbf{w} \varphi(\mathbf{x}_i) + b) \geq 1 \quad (26)$$

Este problema de otimização restrito é chamado de *problema primordial* e pode ser solucionado usando o *método dos multiplicadores de Lagrange* (BERTSEKAS, 1997). A função de Lagrange para este problema é dado por:

$$\mathbf{J}_{(w,b,\alpha)} = \frac{1}{2} \mathbf{w}^T \mathbf{w} - \sum_{i=1}^N \alpha_i [y_i (\mathbf{w}^T \varphi(\mathbf{x}_i) + b) - 1], \quad (27)$$

Onde os parâmetros auxiliares não negativos α_i são chamados de *multiplicadores de Lagrange*.

Como a função custo é convexa e o problema de otimização tem restrições lineares, é possível formular um problema dual definido como (BERTSEKAS, 1997):

$$\text{Maximizar: } Q_{(\alpha)} = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \varphi(\mathbf{x}_i) \varphi(\mathbf{x}_j) \quad (28)$$

Sujeito a: $\sum_{i=1}^N \alpha_i y_i = 0, \alpha_i \geq 0$ para $i = 1, \dots, N$.

Definindo o núcleo do produto interno como:

$$K_{(x, x_i)} = \sum_{j=1}^{m_1} \varphi_j(\mathbf{x}) \varphi_j(\mathbf{x}_i) \text{ para } i = 1, 2, \dots, N$$

onde m_1 é o número de pontos do vetor \mathbf{x} .

$Q_{(\alpha)}$ na Equação (28) pode ser reescrita como:

$$Q_{(\alpha)} = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j) \quad (29)$$

O mais importante é que o núcleo do produto interno pode ser usado para construir o hiperplano ótimo no espaço de parâmetros sem ter que considerar o próprio espaço de parâmetros de forma explícita. Essa é uma importante característica das máquinas de vetores de suporte, pois não é necessário conhecer a função não linear $\varphi(\cdot)$, uma vez que apenas o núcleo do produto interno é necessário. O teorema de Mercer (MERCER, 1909) poderia ser usado para dizer se uma determinada função *kernel* é realmente um núcleo do produto interno em algum espaço de parâmetros.

O hiperplano ótimo é agora definido por:

$$\sum_{i=1}^M \alpha_i^0 y_i K(\mathbf{x}, \mathbf{x}_i) + b^0, \quad (30)$$

onde M é o número de vetores de suporte e α_i^0 e b^0 são os multiplicadores de Lagrange.

O hiperplano ótimo é alocado em iguais distâncias dos vetores de suporte para cada classe. Assim, o desvio ótimo é dado por:

$$b^o = \frac{1}{2} \sum_{i=1}^N y_i \alpha_i (K(x_{s1}, \mathbf{x}_i) + K(x_{s2}, \mathbf{x}_i)), \quad (31)$$

onde \mathbf{x}_{s1} e \mathbf{x}_{s2} são respectivamente, vetores de suporte arbitrários para a classe 1 e classe 2.

Finalmente, a função de decisão será:

$$\begin{aligned} f(x) &= \text{sign} \sum \alpha_i^o y_i K(\mathbf{x}_i, \mathbf{x}) + b^o & (32) \\ \text{sign}(z) &= 1 \text{ se } z > 0 \\ \text{sign}(z) &= -1 \text{ se } z < 0. \end{aligned}$$

e o dado desconhecido será classificado de acordo com

se $f(x) = +1$, vetor $\mathbf{x} \in$ Classe 1

se $f(x) = -1$, vetor $\mathbf{x} \in$ Classe 2.

2.10 One-Class-Learning

One-Class-Learning, ou SVM não supervisionada, destina-se a separar os dados da origem em um espaço de alta dimensão e é usado, geralmente, para detectar pontos fora do padrão (*outliers*) (SCHOLKOPF et al., 2001).

O algoritmo se assemelha ao SVM de classificação binária e o objetivo é minimizar a seguinte expressão (SCHOLKOPF et al., 2001):

$$0,5 \sum_{jk} \alpha_j \alpha_k G(x_j, x_k), \quad \text{para } \alpha_1, \dots, \alpha_n \quad (33)$$

Sujeito a: $\sum \alpha_j = nv$

e $0 \leq \alpha_j \leq 1$ para todo $j = 1, \dots, n$

em que $G(x_j, x_k)$ é elemento (j, k) da *Gram Matrix*.

A *Gram Matrix* de um conjunto de n vetores $\{\mathbf{x}_1, \dots, \mathbf{x}_j; \in R^p\}$ é uma matriz $N \times N$ com elemento (j, k) definido como $G(x_j, x_k) = \phi(x_j), \phi(x_k)$, representando o produto interno dos preditores transformados usando a função *kernel* ϕ .

Para SVM não-linear, o algoritmo forma uma *Gram Matrix* utilizando as colunas da matriz do preditor. A dupla formalização substitui o produto interno dos preditores com seu correspondente elemento do resultado da *Gram Matrix* (chamado de “truque *kernel*”). Posteriormente, o SVM não linear opera no espaço transformado para encontrar um hiperplano de separação.

Um pequeno valor de ν leva a menos vetores de suporte e, por consequência, a uma fronteira de decisão imperfeita. Um grande valor de ν leva a mais vetores de suporte, portanto muitas curvas e uma fronteira de decisão flexível. O valor ideal de ν deve ser grande o suficiente para captar a complexidade dos dados, e pequeno o bastante para evitar o *overtraining*. Então $0 \leq \nu \leq 1$ (SCHOLKOPF et al., 2001).

3 MATERIAL E MÉTODOS

A Figura 3 apresenta um diagrama em blocos que ilustra cada etapa da implementação do sistema proposto nesse trabalho. As seções subsequentes descrevem cada etapa.



Figura 3 Diagrama de blocos das etapas do projeto

Duas abordagens serão consideradas neste trabalho:

- a) abordagem I: o tipo de falha não é conhecido e o objetivo final é apenas detectar se há falha ou não na viga analisada;
- b) abordagem II: conhecem-se os tipos de falhas e o objetivo é, além de detectar a presença de falhas, classificar o nível delas em três grupos: falha suave, falha intermediária e falha grave.

3.1 Aquisição de Sinais

O objetivo da primeira etapa do trabalho, a de Aquisição de Sinais, foi montar uma bancada experimental para coleta dos sinais de vibração a serem analisados. Para isso, foi instalada uma fonte de distúrbio (motor elétrico) em uma viga de alumínio em balanço, conforme Figura 4. A fonte de distúrbio faz com que a viga vibre e os sinais de vibração são então coletados por um sensor fixado na extremidade da viga. Primeiramente, foram coletados os sinais de vibração da viga sem falha e, posteriormente, diferentes tipos de falhas foram

executadas na mesma viga e novos sinais de vibração foram coletados. Os sinais coletados pelo sensor foram enviados para um computador, para posterior processamento.




Figura 4 Viga Em balanço. "M" é o ponto de acoplamento do motor e "S" é o ponto de acoplamento do sensor

A viga utilizada para o projeto do método é de alumínio e tem a dimensão de 280 mm de comprimento por 35 mm de largura e 2mm de espessura e foram feitos diferentes tipos de falhas, resultando em quatro classes aqui definidas como: sem falha (SF), falha suave (FS), falha intermediária (FI) e falha grave (FG), como na Figura 5. Na classe FS foi feito um corte de 1mm de largura por 10 mm de comprimento. Na classe FI foi feito um corte de 5mm de largura por 10 mm de comprimento e na de FG um corte de 10mm de largura

por 10 mm de comprimento. Todas essas falhas foram feitas a 140 mm da extremidade engastada.




Figura 5 Padrões de vigas considerados no trabalho: (a) sem falha; (b) falha suave; (c) falha intermediária; (d) falha grave

Na Figura 6, apresenta-se o esquema de montagem do motor na placa Arduino Mega 2560 e seus componentes. O motor é a fonte de excitação do sistema.

Adotou-se como fonte de distúrbio um motor de corrente contínua de 9 V que será acionado pela placa Arduino Mega 2560 (Figura 6). O motor é

fixado, com uma fita adesiva dupla face, a 20 mm da extremidade engastada da viga, conforme esquema mostrado na Figura 4




Figura 6 Esquema de montagem do motor na placa Arduino

Na Figura 7, mostra-se o esquema de montagem do acelerômetro MMA 7361, que é o sensor que capta a vibração da viga e na Figura 8 está o esquema de montagem completo, com sensor, atuador e seus componentes, responsável por fazer a coleta dos sinais de vibração.

O sensor acelerômetro modelo MMA 7361, que será ligado à placa Arduino, conforme apresentou-se na Figura 8, é fixado com fita adesiva dupla face, a 250 mm da extremidade engastada da viga (vide esquema da Figura 4) e capta a vibração produzida pela fonte de distúrbio.




Figura 7 Esquema de montagem do acelerômetro na placa Arduino

Os sinais coletados terão duração de 262,5 segundos (equivalente a 52.500 amostras) para cada classe de falha na viga e também para a viga sem falha, e foram coletados com um intervalo de amostragem de 0,005 segundos.




Figura 8 Esquema de montagem final do projeto

De acordo com a nota de aplicação, escrita por Seifert e Camacho (2007) e fornecida pela fabricante do sensor acelerômetro utilizado, a Freescale Semiconductor, o processo de aquisição de sinais do acelerômetro MMA 7361 pelo Arduíno não está livre de ruídos elétricos e mecânicos. Para eliminar os ruídos elétricos e mecânicos, Seifert e Camacho (2007) propõem o uso de um filtro média móvel e uma janela discriminante. Essa última transforma os sinais de aceleração com valores entre -3m/s^2 e 3m/s^2 em 0. Diferentemente, Ferreira Júnior (2014) utilizou um filtro passa-faixa, já que a faixa de frequência de interesse era bem definida. No entanto, em ambos os trabalhos de Ferreira Júnior (2014) e Seifert e Camacho (2007), o objetivo final foi de se trabalhar com o sinal convertido em deslocamento e não utilizar o sinal coletado em sua forma original, em aceleração. Conforme bem destacado por Seifert e Camacho (2007), o processo de conversão do sinal de aceleração em deslocamento pode amplificar ruídos e, portanto, o pré-processamento com filtros é fundamental.

Na presente proposta de dissertação, optou-se por não utilizar filtros para eliminar ruídos por dois motivos: i) testar a eficiência de EOS, visto que essas são nulas para ruídos gaussianos e ii) os sinais coletados não apresentaram uma frequência ou faixa de frequência dominante, que impede a definição de um filtro adequado ao sinal, ou seja, que garanta a eliminação de apenas ruídos. Na Seção 4.1, apresenta-se uma análise no domínio da frequência em que isso fica evidente.

Foi desenvolvido um algoritmo para o controle da placa Arduíno (vide ANEXO A). Nesse algoritmo é possível definir a frequência de amostragem para a coleta dos dados. Essa frequência de amostragem foi definida com base na rotação do motor, que foi medida com o auxílio de um tacômetro digital modelo TD-813, conforme ilustra a Figura 9.



Figura 9 Medição da rotação do atuador

Com o auxílio do tacômetro foi encontrada uma rotação de 2.000 rpm e isso significa que a frequência de espectro do atuador é de 33,33 Hz.

Segundo o Teorema de Nyquist, a frequência de amostragem de um sinal analógico, para que possa ser reconstituído com o mínimo de perda de informação, deve ser igual ou maior a duas vezes a maior frequência de espectro desse sinal.

Para uma boa margem de segurança, escolheu-se uma frequência de amostragem de 6 vezes maior do que a frequência de espectro encontrada com o auxílio do tacômetro, levando a um intervalo entre amostras de 0,005 segundos.

Um estudo sobre as frequências naturais da viga utilizada no experimento foi realizado. De acordo com Ramires Sobrinho (2007), a primeira, segunda e terceira frequências naturais de uma viga em balanço podem ser calculadas conforme (34), (35) e (36), respectivamente.

$$\omega_{nf} = 1,875^2 \sqrt{\frac{EI}{\rho AL^4}} \quad (34)$$

$$\omega_{nf} = 4,649^2 \sqrt{\frac{EI}{\rho AL^4}} \quad (35)$$

$$\omega_{nf} = 7,855^2 \sqrt{\frac{EI}{\rho AL^4}} \quad (36)$$

em que:

E é o módulo de elasticidade do material ($6,9 \times 10^{10}$ Pa),

I é o momento de inércia da viga ($1,27 \times 10^{-11}$ m⁴),

ρ é a densidade do material da viga (2700 Kg/cm³),

A é a área da secção transversal da viga ($4,3 \times 10^{-4}$ m²), e

L é o comprimento da viga (0,255 m)

Inserindo os valores dos parâmetros referentes ao material e dimensões da viga utilizada, obtêm-se, respectivamente os seguintes valores referentes à primeira, segunda e terceira frequências naturais: 7,48 Hz, 46,97 Hz e 131,32 Hz.

Os materiais usados para montagem do experimento foram:

- a) vigas de alumínio (280 x 3,5 mm)
- b) fios jumper;
- c) placa Arduino Mega 2560 R3;
- d) sensor do tipo Acelerômetro modelo MMA 7361;
- e) motor de corrente contínua 9V;
- f) um computador com o software *Matlab* instalado.

Para a ligação do motor cc na Placa Arduino foram utilizados:

- a) fios jumper;

- b) uma protoboard;
- c) quatro pilhas palito AA;
- d) suporte para pilhas;
- e) um potenciômetro giratório;
- f) um diodo 1N4001;
- g) um transistor TIP120.

Pela Figura 8, apresenta-se o esquema final da montagem do experimento, com atuador e sensor controlados pela mesma placa Arduino. Como pode ser observado, a alimentação do motor será feita por quatro pilhas palito AA, resultando em um total de 6V.

3.2 Análise dos Sinais

A segunda etapa do trabalho consistiu na análise dos sinais obtidos através do software MatLab[®]. Foram usadas, além de representação no tempo e na frequência, estatísticas de ordem superior, descritas na seção 2.5, para extrair informações compactas e que sejam satisfatórias para produzir assinaturas bem definidas das falhas nas vigas, a fim de detectá-las e classificá-las.

Foi feita também a seleção de características a fim de maximizar o desempenho do detector/classificador final, além de reduzir a dimensão do problema e, conseqüentemente, a complexidade computacional e o tempo de processamento. Para isso, foi aplicado o método do Discriminante de Fischer, apresentado na Seção 2.6.

Uma vez extraídos e selecionados os parâmetros mais relevantes, a etapa final do projeto consistiu em projetar um detector e classificador de falhas.

3.3 Projeto do Detector - Abordagem I

O projeto do detector, seguindo a Abordagem I, consistiu em utilizar o conjunto de dados extraídos (via EOS) e selecionados (via FDR) dos sinais de vibração da viga sem falha, para projetar um classificador SVM *one-class* (vide Seção 2.8.3). Esse tipo de SVM tem como vantagem requerer os dados de apenas uma das classes, a de interesse, para construir um hiperplano de separação, que circunda os dados da classe de forma que eventos fora desse hiperplano são considerados como *outliers*. Neste trabalho, *outliers* serão considerados como viga com falhas.

Na Figura 10, ilustram-se as etapas de projeto do detector de falhas proposto para a Abordagem I. As duas primeiras etapas, extração e seleção de EOS, são as etapas de pré-processamento, discutidas na Seção 4.1.

Cumprе ressaltar que a etapa de seleção de EOS via FDR foi realizada apenas no projeto do detector, não sendo necessária, contudo, na operação do mesmo.

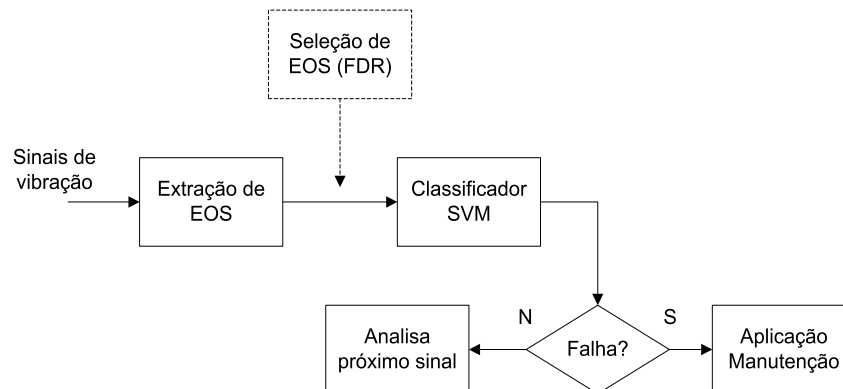


Figura 10 Diagrama em blocos do detector de falhas proposto: Abordagem I

3.4 Projeto do Detector - Abordagem II

Na abordagem II, o projeto do detector consistiu no desenvolvimento, também com base no conjunto de dados dos sinais de vibração extraídos pela EOS e selecionados pela FDR, de uma Rede Neural para a classificação das vigas em balanço em suas respectivas classes de falhas.

Como já citado na Seção 2.7, uma Rede Neural consiste em capturar os princípios básicos de manipulação de informação do cérebro humano e aplicar esse conhecimento na resolução de problemas que exigem aprendizado a partir da experiência.

Com base nisso, uma porcentagem dos conjuntos dos dados de cada classe é separada para treinamento, outra porcentagem é separada para os testes e uma última porcentagem para a validação da rede treinada.

Na Figura 11, mostram-se as etapas do projeto do detector de falhas proposto para a abordagem II.

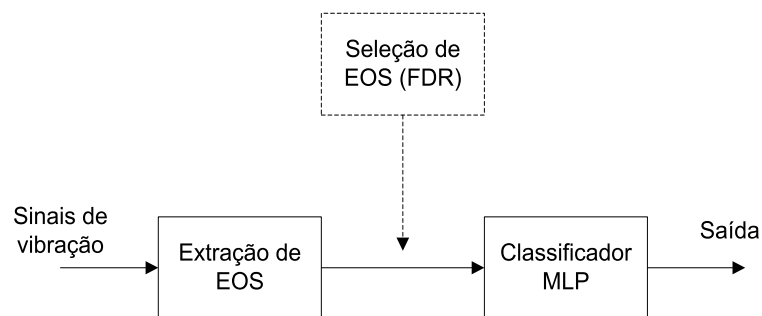


Figura 11 Diagrama em blocos do detector de falhas proposto: Abordagem II

4 RESULTADOS E DISCUSSÃO

Nesta seção são mostrados os resultados, obtidos após as etapas descritas anteriormente, de aquisição de sinais, análise de sinais e projeto do detector.

4.1 Análise de Sinais

O acelerômetro utilizado na aquisição dos sinais capta as vibrações da viga nas três direções (x , y e z , largura, espessura e comprimento, respectivamente), conforme o esquema da Figura 12. Para a detecção e classificação das falhas em viga foram utilizados apenas os sinais referentes à direção y , onde as vibrações da excitação são transmitidas com maior intensidade, devido ao corte e posicionamento da viga (vide Figura 4).




Figura 12 Eixos da viga em balanço

Os sinais de vibração no tempo, em segundos, são compostos por 52.500 amostras discretas de aceleração medidas em g/s^2 (aceleração causada pela gravidade, $9,81 \text{ m/s}^2$), coletados durante 262,5 segundos, a um intervalo de amostragem de 0,005 segundos.

Examinando as séries temporais na Figura 13, observa-se que há distinção entre os sinais de cada viga, porém não suficientes para que os caracterize de acordo com o tipo de falha ou com ausência de falha. Nota-se uma suave diminuição de amplitude do sinal da viga sem falha para o sinal da falha suave e da falha intermediária. Já o sinal da via com falha grave apresenta maior diminuição da amplitude.




Figura 13 Sinais de vibração (em aceleração) da viga sem falha (a), viga com falha suave (b), viga com falha intermediária (c) e viga com falha grave (d)

De acordo com Farrar e Worden (2013), a análise de série do tempo de sinais de vibração medidos em aceleração é uma das formas mais simples de extração de parâmetros. Porém, pela inspeção visual dessas séries é muito difícil quantificar parâmetros que permitam a classificação dos conjuntos de dados em condições de falha ou não falha. No entanto, é fato que esses sinais respondem a variações na entrada do sistema (excitação) e, nesse caso, métodos que investigam correlação entre resposta do sistema e entrada podem se beneficiar.

Por outro lado, as séries de tempo representam vetores de parâmetros de alta dimensão (52.500 dimensões para os dados desta dissertação de mestrado), o que, segundo Farrar e Worden (2013), caracteriza-se como algo “perturbador” para classificadores estatísticos.

Uma análise no domínio da frequência foi também realizada a fim de encontrar alguma diferença entre as vigas que seja evidenciada na frequência. A Figura 14 mostra a função densidade espectral de potência (PSD – *Power spectral density function*) dos sinais, sem falha (a), com falha suave (b), com falha intermediária (c) e com falha grave (d), obtidos para 30 janelas (sem sobreposição) de 1.750 pontos, com método periodograma.

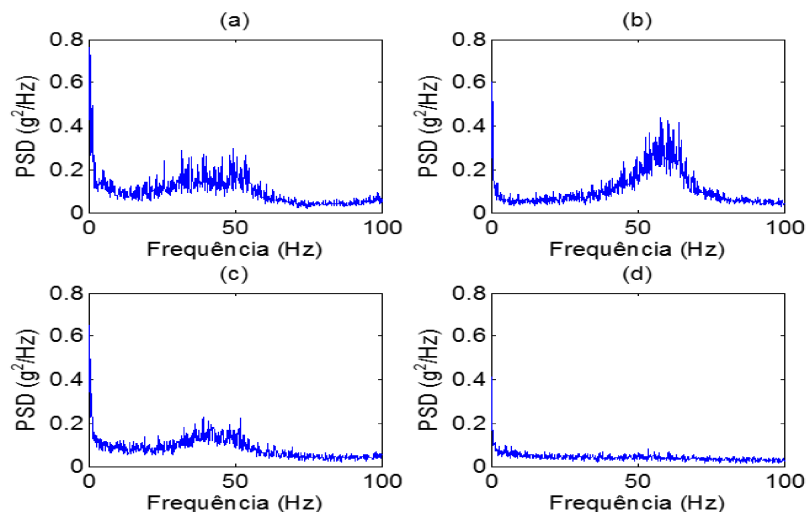


Figura 14 Função densidade espectral de potência de cada sinal mostrado na Figura 13: (a) do sinal sem falha; (b) do sinal com falha suave; (c) do sinal com falha intermediária e (d) do sinal com falha grave

Nota-se um aumento na energia do espectro da viga com falha suave em torno de 60 e 70 Hz, em comparação com o da viga sem falha. Já nas vigas com falhas intermediária e grave, observa-se uma atenuação na energia do espectro

em torno de 30 e 50 Hz, que é mais acentuada para a viga com falha grave. Entretanto, consegue-se perceber, no espectro da viga sem falha, uma energia mais alta em torno da frequência de 33,33 Hz, que foi a frequência calculada através da medição da rotação do motor com o tacômetro, conforme descrito no Capítulo 3. Essa energia mais alta se desloca levemente para a direita no espectro da viga com falha suave. Observam-se também distintas mudanças no espectro em baixa frequência com o progresso da falha.

Observe que as mudanças nos espectros da Figura 14, decorrentes do aparecimento e evolução de uma falha numa viga em balanço não são tão coerentes e óbvias quanto as analisadas no domínio do tempo (Figura 13) e, portanto, parâmetros mais quantitativos devem ser extraídos, a fim de detectar e classificar o tipo de falha na viga.

Em resumo, todas as formas de ondas no domínio do tempo e no domínio da frequência, apresentadas nas Figuras 13 e 14, apresentam alterações em comparação com o sinal viga sem falha, porém é difícil quantificar essas mudanças devido à elevada dimensão dos vetores de parâmetros. De acordo com Farrare Worden (2013), as mudanças observadas em sinais de vibração no tempo e na frequência relacionadas a falhas não indicam onde a falha ocorreu, o tipo ou ao menos o nível da falha e, portanto, propriedades estatísticas extraídas desses sinais, que levem a vetores de parâmetros de menor dimensão, devem ser obtidas.

4.2 Capacidade de discriminação das EOS

Como já citado no capítulo 3, o sinal coletado para cada classe possui 52.500 pontos (amostras). Esses sinais foram transformados em matrizes $M \times N$, em que M é o número de eventos e N é o número de amostras por evento.

Sabe-se que a redução do número de amostras que representa um evento a ser processado pode comprometer a qualidade das informações disponíveis sobre o evento para se construir uma assinatura compacta do mesmo. Por outro lado, o processamento de poucas amostras por evento resulta em menor esforço computacional, ou seja exige menos memória e tempo para realizar a tarefa.

A fim de investigar este compromisso entre complexidade computacional e desempenho, foram feitos testes para diferentes números de amostras por eventos para que se pudesse chegar à melhor combinação para o problema de detecção e classificação de falhas, proposto no contexto dessa Dissertação de Mestrado.

Para cada caso foram extraídas as Estatísticas de Ordem Superior e, posteriormente, o Discriminante Linear de Fisher para selecionar os melhores parâmetros extraídos.

As Figuras 15, 16, 17, 18 e 19, apresentam os resultados do FDR (em (a)) e o espaço de parâmetros construído por apenas dois cumulantes (em (b)) para $N = 100, 210, 350, 750$ e 1.050 amostras, respectivamente. Cumpre ressaltar aqui que foi aplicado o FDR para 4 classes, conforme Equação (18).

Os resultados do FDR mostram o vetor formado pelos cumulantes de segunda, terceira e quarta ordens, nessa sequência, ou seja, $\mathbf{J} = [J_{C2(1:N/2)} J_{C3(1:N)} J_{C4(1:N)}]$. Note que para os cumulantes de segunda ordem, apenas a primeira metade das amostras é considerada, já que o cumulante é simétrico.

Conforme as Figuras 15(a), 16(a), 17(a), 18(a) e 19(a) os cumulantes de segunda, terceira e quarta ordens, para atraso 0, foram os parâmetros mais representativos, no que tange à separação entre classes. Dentre os cumulantes, de atraso 0, os de segunda e terceira ordens mostraram-se mais representativos que os de quarta ordem.

A construção do espaço de parâmetros, a partir dos dois cumulantes mais relevantes, segundo o critério FDR, mostra que é possível uma separação linear entre as quatro classes consideradas (SF - Sem Falha, FS - Falha Suave, FI - Falha Intermediária e FG - Falha Grave), a partir de $N = 700$ amostras.

Conforme o aumento do número de amostras N , a separação das classes fica mais nítida.

É importante observar que, no espaço de parâmetros construído pelos cumulantes em duas dimensões, a classe de falha grave (FG) mostrou-se mais homogênea e mais isolada das demais.

Note-se que, para N igual a 750 (Figura 18) e 1.050 (Figura 19) não existem mais interseções entre as classes e elas podem ser separadas de maneira linear.

Os resultados dessa seção mostram a capacidade das EOS em representar os sinais de vibração, gerando assinaturas compactas, formadas por apenas dois parâmetros, das diferentes falhas consideradas e de vigas sem falhas.

É importante ressaltar também que nenhum tratamento, no sentido de eliminar ruídos, foi realizado nos sinais de vibração coletados, o que reforça a boa capacidade das EOS de capturar informações de sinais de vibrações.




Figura 15 Para $N = 100$. (a) *FDR*. (b) Espaço de parâmetros. SF= Sem Falha, FS = Falha Suave, FI = Falha Intermediária, FG = Falha Grave

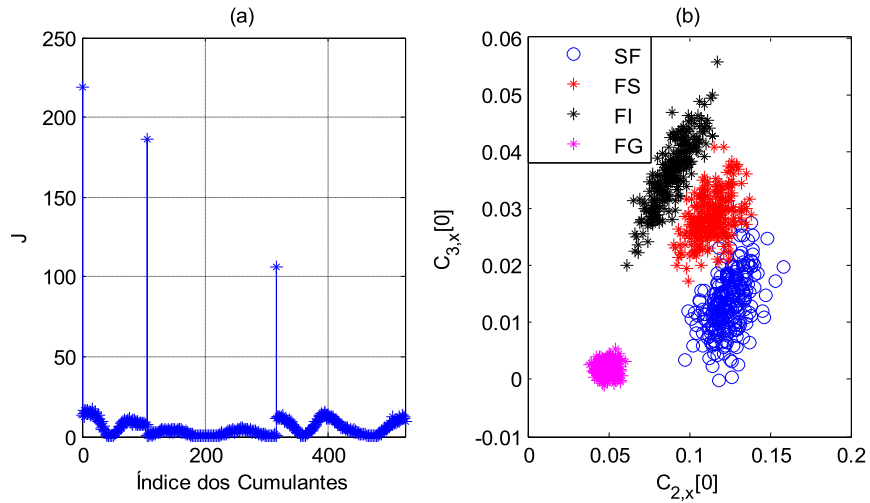


Figura 16 Para $N = 210$. (a) *FDR*. (b) Espaço de parâmetros. SF= Sem Falha, FS = Falha Suave, FI = Falha Intermediária, FG = Falha Grave

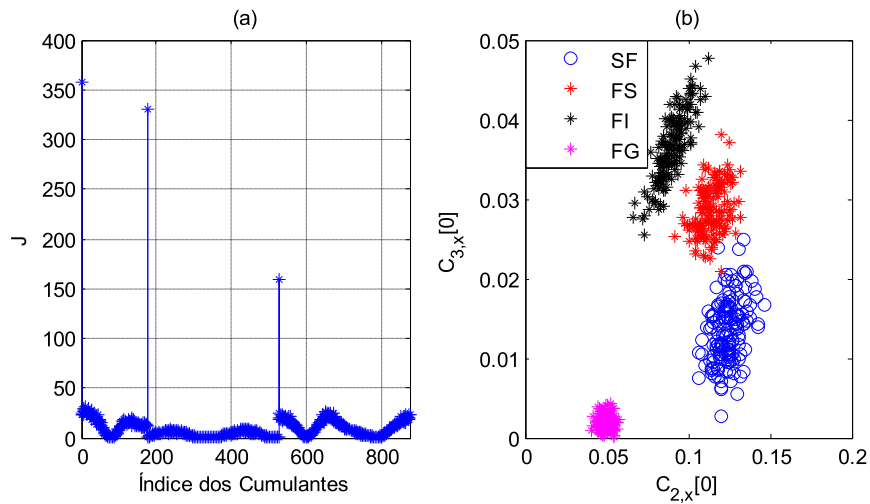


Figura 17 Para $N = 350$. (a) *FDR*. (b) Espaço de parâmetros. SF= Sem Falha, FS = Falha Suave, FI = Falha Intermediária, FG = Falha Grave

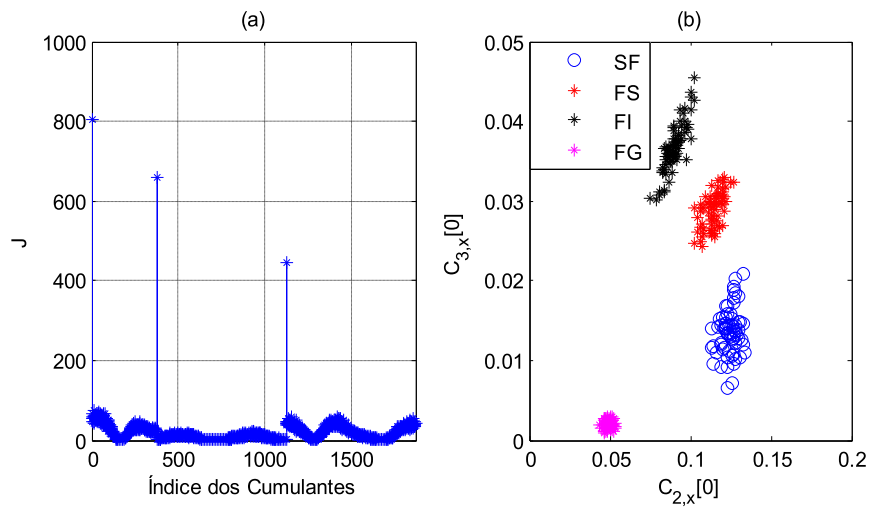


Figura 18 Para $N = 750$. (a) *FDR*. (b) Espaço de parâmetros. SF= Sem Falha, FS = Falha Suave, FI = Falha Intermediária, FG = Falha Grave

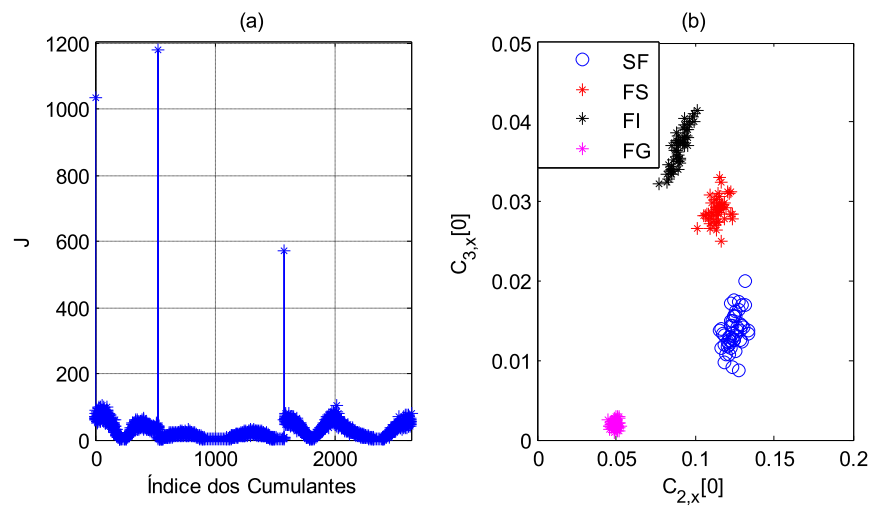


Figura 19 Para $N = 1.050$. (a) *FDR*. (b) Espaço de parâmetros. SF= Sem Falha, FS = Falha Suave, FI = Falha Intermediária, FG = Falha Grave

4.3 Resultados de Detecção - Abordagem I

Após encontrar os melhores parâmetros e fazer os testes da separação das classes, a nova etapa foi o projeto do SVM, que constrói uma região fechada que delimita a classe sem falha e, a partir dessa região, todos os pontos que estiverem fora são classificados como falha.

Foi considerado o caso N igual a 1.050 amostras, que leva a 100% de separação entre classes. A Figura 20 mostra o espaço de parâmetros formado pelos cumulantes de segunda e terceira ordens, atraso zero, para as quatro classes consideradas. A região sombreada em cinza, ao redor da classe de eventos sem falha, delimita a região de classificação construída pelo SVM *oneclass* projetado. Eventos fora dessa região são considerados eventos com falhas.

Para o projeto do SVM *oneclass*, utilizou-se a função kernel gaussiana para uma fração de *outliers* de 0% no conjunto de treinamento.

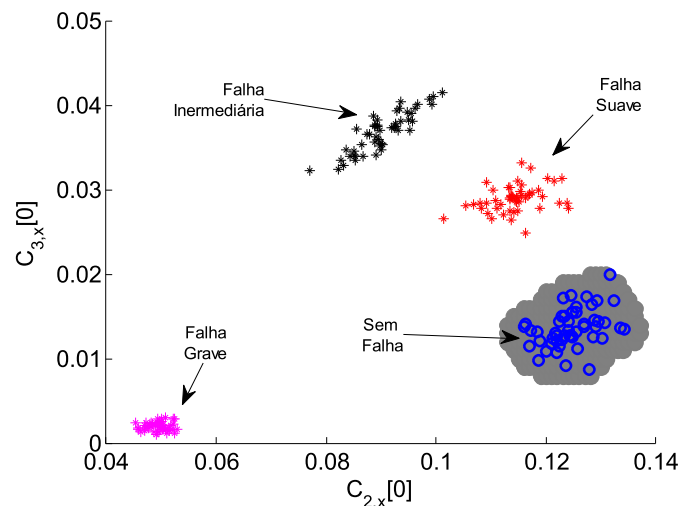


Figura 20 - Projeto do SVM para $N = 1.050$

Pode-se notar que o classificador SVM alcança um desempenho de separação de 100% para eventos representados por 1.050 amostras, quando estes são reproduzidos no espaço de parâmetros dos cumulantes.

A Tabela 2 mostra o desempenho, em percentual, do classificador SVM para diferentes tamanhos de janelas ($N = 1.050, 750, 350, 210$ e 100), de sinal processado. Observe que à medida que o número de amostras diminuiu, o desempenho do classificador também diminuiu, visto que, para janelas de sinal menores do que 750 amostras, existem interseções entre a classe sem falha e as classes com falha, conforme mostrado pelas Figuras 21, 22 e 23.


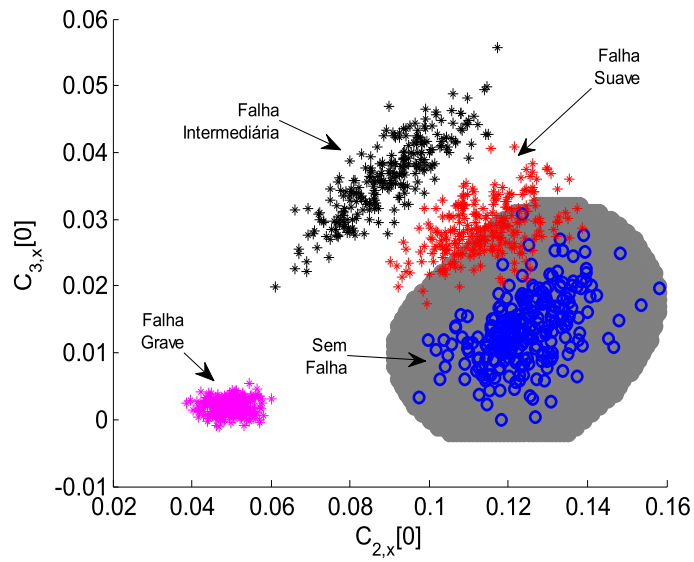
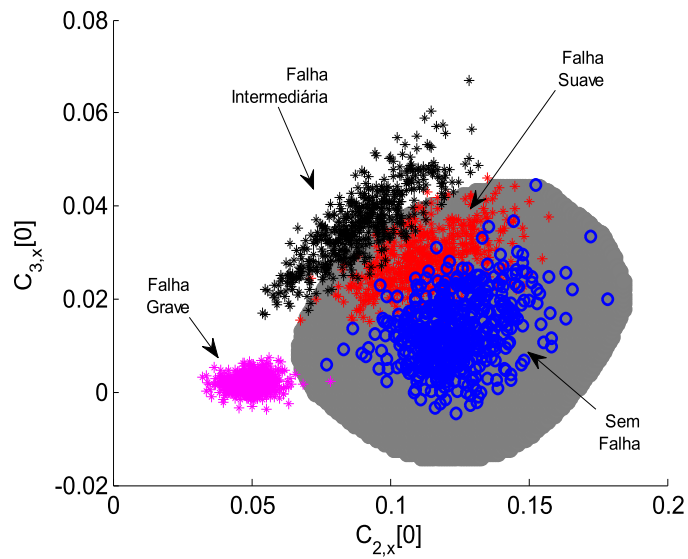


Figura 21 Projeto do SVM para $N = 350$

Figura 22 Projeto do SVM para $N = 210$ Figura 23 Projeto do SVM para $N = 100$

Pode-se notar que, para N igual a 350 e 210, as classes de Falhas Intermediária e Grave alcançam 100% de separação, enquanto as classes de Falhas Suaves e Sem Falha apresentaram interseção. Para N igual a 100, a classe de Falha Intermediária já se mistura na região que delimita a classe Sem Falha e a classe de Falha Grave já não apresenta mais 100% de separação. A Tabela 2 mostra o desempenho do classificador.

Vale lembrar que, para esta Abordagem I, o classificador proposto é responsável por classificar apenas duas classes: eventos com falha e eventos sem falha.

Tabela 2 Desempenho do classificador SVM para a viga de alumínio

Tamanho da Janela Processada (N)	Desempenho (%)
1.050	100
750	100
350	99,77
210	86,26
100	61,46

A fim de testar o desempenho do método para uma viga com material diferente, uma viga de aço 1020 foi utilizada (vide Figura 24). A nova viga possui 300 mm de comprimento e 30 mm de largura e 3 mm de espessura e também foi engastada em uma das extremidades. Primeiramente, foram coletados os dados da viga sem falha (52.500 amostras) e depois da viga com falha (foi feita uma falha de 5 x 2 mm a 140 mm da extremidade engastada).




Figura 24 Padrões de vigas de aço 1020 para segundo teste: (a) sem falha; (b) com falha

Como já havia sido projetado, bastou usar os mesmos parâmetros (cumulante de ordem 2 e cumulante de ordem 3 com atraso zero) sem precisar de fazer novamente o FDR e nem investigar quais os melhores parâmetros. Os resultados para essa viga de aço são mostrados na Tabela 3. Observa-se que o método apresentou uma significativa capacidade de generalização, visto que alcançou bom desempenho para vigas de materiais diferentes.

Tabela 3 Desempenho do classificador SVM para a viga de aço

Tamanho da Janela Processada (N)	Desempenho (%)
1.050	100
750	100
350	100
210	100
100	99,81

4.4 Resultados de Detecção - Abordagem II

Após os testes com o classificador SVM, foi desenvolvido outro método para a classificação das classes de falhas e não falha das vigas.

Assim como na Abordagem I, foram feitos os testes para os valores de N igual 1.050, 750, 350, 210 e 100.

Foi utilizado como classificador uma Rede Perceptron de Múltiplas Camadas (MLP), com uma única camada escondida.

No projeto da Rede foram utilizados 2 nodos de entradas (ou seja, uma entrada para cada parâmetro selecionado por Fischer, um cumulante de segunda ordem e um de terceira ordem) e 4 neurônios na camada de saída, um neurônio para cada classe, de forma que os alvos foram vetores de forma $[1 \ -1 \ -1 \ -1]^T$, $[-1 \ 1 \ -1 \ -1]^T$, $[-1 \ -1 \ 1 \ -1]^T$ e $[-1 \ -1 \ -1 \ 1]^T$ para as classes Sem Falha (SF), Falha Suave (FS), Falha Intermediária (FI) e Falha Grave (FG), respectivamente.

Sabe-se que o número de neurônios na camada intermediária define a capacidade de discriminação da rede neural e varia de problema para problema. Uma rede subdimensionada, com poucos neurônios na camada intermediária pode perder a capacidade de discriminação, enquanto que uma rede superdimensionada, com muitos neurônios na camada intermediária, torna-se complexa tanto para o treinamento quanto para a operação, além de perder a capacidade de generalização (HAYKIN, 2008). O número de neurônios na camada intermediária foi variado de 2 a 5 neurônios, mas no final, para todos os N , o melhor resultado foi encontrado para 3 neurônios na camada intermediária.

A função de ativação usada na Rede Neural foi a tangente hiperbólica, tanto na camada intermediária, quanto na camada de saída. O algoritmo de treinamento utilizado foi o *Resilient Propagation* (Rprop) (RIEDMILLER; BRAUN, 1993).

O conjunto de dados foi dividido em três grupos: dados de treino (60% dos dados), dados de teste (20% dos dados) e dados de validação (20%).

Com esses parâmetros, a Rede Neural foi treinada e alcançou os resultados apresentados na Tabela 4, para diferentes tamanhos (N) de janela processada.

Tabela 4 Desempenho da Rede Neural. SF= Sem Falha, FS = Falha Suave, FI = Falha Intermediária, FG = Falha Grave

N	Treino (%)				Teste (%)				Validação (%)			
	SF	FS	FI	FG	SF	FS	FI	FG	SF	FS	FI	FG
1050	100	100	100	100	100	100	100	100	100	100	100	100
750	100	100	100	100	100	100	100	100	100	100	100	100
350	98,7	100	100	100	100	97,1	100	100	100	100	100	100
210	97,6	99,2	100	100	93,3	100	100	100	93,3	100	100	100
100	93,6	89,7	95,3	100	95,5	85,7	97	100	92,8	81	96	100

Nota-se que, assim como no classificador da Abordagem I, o classificador proposto alcança um desempenho de 100% para o conjunto de dados utilizados para janelas de sinal iguais a $N = 1.050$ e 750 amostras. À medida que N vai diminuindo, diminuiu também a eficiência, que está em consenso com as análises do espaço de parâmetros realizadas na Seção 5.2, onde fica evidente a interseção entre as classes para N igual a 350, 210 e 100.

Interessante observar que, para N igual a 350 e 210, as interseções entre classes aconteceram apenas para as classes Sem Falha e Falha Suave, fazendo com que 6,7% dos dados de teste e validação da classe Sem Falha fossem classificados como Falha Suave.

Afim de melhorar o desempenho para as janelas de processamento $N = 350$, 210 e 100, o cumulante de ordem 4, atraso 0, foi também utilizado como

entrada da rede neural, juntamente com os cumulantes de segunda e terceira ordens, atraso 0.

Na Tabela 5, mostram-se os resultados para este novo teste. Observe que, em comparação com os resultados utilizando apenas dois parâmetros (cumulantes de segunda e terceira ordens) (Tabela 4), o desempenho da classificação melhorou razoavelmente, sendo que, para $N=350$, conseguiu-se atingir 100% de classificação, para os conjuntos de treino, teste e validação. Para N igual a 210 e 100 ainda ocorre interseção entre as classes Sem Falha e Falha Suave. Note que, em todos os casos, a rede consegue uma classificação 100% para a classe Falha Grave. Neste caso, o melhor resultado para N igual a 350 foi com 3 neurônios na camada intermediária e para N igual a 210 e 100 foi com 4 neurônios na camada intermediária.

Tabela 5 Desempenho da Rede Neural considerando 3 parâmetros. SF= Sem Falha, FS = Falha Suave, FI = Falha Intermediária, FG = Falha Grave

N	Treino (%)				Teste (%)				Validação (%)			
	SF	FS	FI	FG	SF	FS	FI	FG	SF	FS	FI	FG
350	100	100	100	100	100	100	100	100	100	100	100	100
210	100	100	100	100	100	98,3	100	100	96,6	100	100	100
100	96,1	95,6	95,3	100	95,5	93,7	99,1	100	91,9	89,2	98	100

5 CONCLUSÃO E PERSPECTIVAS FUTURAS

O presente trabalho de Dissertação de Mestrado propôs um método de análise e detecção de falhas em vigas em balanço, utilizando Estatísticas de Ordem Superior extraídas de sinais de vibração.

O método da extração de parâmetros através de Estatísticas de Ordem Superior mostrou ser eficiente para o problema de reconhecimento de padrões, como o proposto neste trabalho, no qual o objetivo foi detectar e classificar diferentes tipos de falhas produzidas artificialmente em uma viga em balanço. A grande eficiência da extração de parâmetros levou a uma redução de dimensão considerável (para apenas 2 ou 3 parâmetros). Isso facilitou o trabalho de dois classificadores testados, o SVM e as Redes Neurais, possibilitando resultados muito satisfatórios e chegando, em alguns casos, a 100% de eficiência.

Duas abordagens foram consideradas. Em uma das abordagens supõe-se o não conhecimento prévio das falhas, e portanto, o treinamento do classificador deve ser não supervisionado. Essa abordagem leva a um problema mais complexo devido à característica não supervisionada do mesmo. Neste caso, foi utilizado o classificador SVM *oneclass*, que foi alimentado por EOS extraídas de sinais de vibração de uma viga “saudável” (sem falha) no treinamento. Na segunda abordagem, foram utilizadas redes neurais multicamadas (MLP) para atacar o problema de detecção e classificação de falhas, sendo esse um problema supervisionado, para ser aplicado em uma situação em que se conhecem os tipos de falhas. As Redes Neurais apresentaram resultados ligeiramente melhores que as Máquinas de Vetores de Suporte, para a detecção de falhas, quando janelas reduzidas de sinais são processadas.

O método proposto apresentou significativa capacidade de generalização, quando testado em uma viga de material diferente (Aço 1020).

Em comparação com os trabalhos da literatura, discutidos na Seção 2.2, o método aqui proposto apresenta a vantagem de ser automático, ou seja, independente de análise qualitativa, e não requerer a análise e/ou controle do sinal de excitação do sistema, causador da vibração na viga em balanço. Essa última evita problemas com ruídos e erros provenientes da aquisição do sinal de excitação.

Um ponto importante a ser ressaltado é a capacidade das EOS de extrair informações relevantes à detecção e classificação das falhas, a partir de reduzidas janelas do sinal de aquisição (de apenas 100 amostras), equivalente a janelas de duração de apenas, aproximadamente, 0,5 segundos.

São propostas de continuidade para essa Dissertação de Mestrado:

- a) Desenvolver, utilizando também EOS, um método para estimar a localização da falha na viga em balanço;
- b) Testar o método em uma nova bancada, desta vez, com sinais de excitação conhecidos, possibilitando o projeto de um filtro que retire os ruídos existentes na coleta dos dados;
- c) Desenvolver um método que possa identificar o grau da falha em uma escala já definida, não precisando de um padrão de falha previamente conhecido;
- d) Desenvolver um dispositivo que possibilite o acompanhamento da vibração da máquina/estrutura no local onde estão localizadas, possibilitando assim, uma análise on-line, detectando qualquer distúrbio na vibração da mesma.

REFERÊNCIAS

- ALMEIDA, M. T. de. **Manutenção preditiva: confiabilidade e qualidade**. Itajubá: MTAEV, 2000. Disponível em: <<http://www.mtaev.com.br/download/mnt1.pdf>>. Acesso em: 14 dez. 2013.
- AMEZQUITA-SANCHEZ, J. P. et al. High-resolution spectral-analysis for identifying the natural modes of a truss-type structure by means of vibration. **Journal of Vibration and Control**, Thousand Oaks, v. 19, n. 16, p. 2347-2356, Dec. 2013.
- ANDRADE, V. S. **Análise dinâmica de uma viga engastada excitada por uma fonte não ideal**. 2009. 114 f. Tese (Doutorado em Engenharia Mecânica) - Universidade de São Paulo, São Carlos, 2009.
- BACCARANI, L. M. R. et al. SVM practical industrial application for mechanical faults diagnostic. **Expert Systems with Application**, New York, v. 38, n. 6, p. 6980-6984, Mar. 2011.
- BAYRAM, D.; SEKER, S. Wavelet based neuro-detector for low frequencies of vibration signals in electric motors. **Applied Soft Computing**, New York, v. 13, n. 5, p. 2683-2691, May 2013.
- BENMOUSSAT, M.S. et al. Automatic metal parts inspection: use of thermographic images and anomaly detection algorithms. **Infrared Physics & Technology**, Exeter, v. 61, p. 68-80, Nov. 2013.
- BERTSEKAS, D. P. **Dynamic programming and optimal control**. Belmont: Athenas Scientific, 1997.2 v.
- BURGES, C. J. C. A tutorial on support vector machines for pattern recognition. **Data Mining and Knowledge Discovery**, New York, v. 2, n. 2, p. 121-167, 1998.

CHANAVEL, T. **Statistical signal processing: modeling and estimation**. London: Springer, 2002.331 p.

CHEN, Y. L. et al. Denoising of mechanical vibration signals using quantum-inspired adaptive wavelet shrinkage. **Shock and Vibration**, New York, v. 2014, p. 1-7, 2014.

COMPARE, M.; ZIO, E. Predictive maintenance by risk sensitive particle filtering. **IEEE Transactions on Reliability**, New York, v. 63, n. 1, p. 134-143, Mar. 2014.

CUNHA, R. C. **Análise do estado de conservação de um redutor de velocidade através da técnica de partículas de desgastes no óleo lubrificante auxiliada pela análise de vibrações**. 2005. 163 p. Dissertação (Mestrado em Engenharia Mecânica) - Faculdade de Engenharia de Ilha Solteira, Ilha Solteira, 2005.

DEOKAR, A.A.V.; WAKCHAURE, B.V.D. Experimental investigation of crack detection in cantilever beam using natural frequency as basic criterion. In: INTERNATIONAL CONFERENCE ON CURRENT TRENDS IN TECHNOLOGY, 2011, Ahmedabad. **Proceedings...** Ahmedabad: Institute of Technology, Nirma University, 2011. 1 CD-ROM.

DO, V. T.; CHONG, U. P. Signal model-based fault detection and diagnosis for induction motors using features of vibration signal in two-dimension domain. **Journal of Mechanical Engineering**, London, v. 57, n. 9, p. 655-666, 2011.

DOWLING, N. E. **Mechanical behavior of materials: engineering methods for deformation, fracture, and fatigue**. 2nded. New Jersey: Prentice Hall, 1999.773p.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern classification**. New York: Wiley-Interscience, 2000.680 p.

ERKAYA, S. Analysis of a vibration characteristics of an experimental mechanical system using neural networks. **Journal of Vibration and Control**, Thousand Oaks, v. 18, n. 13, p. 2059-2072, Nov. 2012.

FAN, Y.S.; ZHENG, G.T. Research of high-resolution vibration signal detection technique and application to mechanical fault diagnosis. **Mechanical Systems and Signal Processing**, London, v. 21, n. 2, p. 678-687, Feb. 2007.

FANG, X.; LUO, H.; TANG, J. Structural damage detection using neural network with learning rate improvement. **Computers and Structures**, Elmsford, v. 83, n. 25, p. 2150-2161, Sept. 2005.

FARRAR, C.R.; WORDEN, K. **Structural health monitoring: a machine learning perspective**. Chichester: J. Wiley, 2013. 631 p.

FENG, G. H.; PAN, Y. L. Establishing a cost-effective sensing system and signal processing method to diagnose preload levels of ball screws. **Mechanical Systems and Signal Processing**, London, v. 28, p. 78-88, Apr. 2012.

FERREIRA, D. D. **Classificação automática de distúrbios elétricos ligados à qualidade de energia**. 2007. 132 f. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal de Juiz de Fora, Juiz de Fora, 2007.

FERREIRA, D. D. et al. Exploiting higher-order statistics information for power quality monitoring. **Power Quality**, New York, v. 1, p. 345-362, Apr. 2011.

FERREIRA, D. D. et al. Sistema automático de detecção e classificação de distúrbios elétricos em qualidade de energia elétrica. **Revista Controle & Automação**, Campinas, v. 20, n. 1, p. 53-62, 2009.

FERREIRA JÚNIOR, L. de G. **Análise de vibração nas hastes de colhedora de café**. 2014. 63 f. Dissertação (Mestrado em Engenharia Agrícola) - Universidade Federal de Lavras, Lavras, 2014.

GARCIA, D.; TRENDAFILOVA, I. A multivariate data analysis approach towards vibration analysis and vibration-based damage assessment: application for delamination detection in a composite beam. **Journal of Sound and Vibration**, London, v. 333, n. 25, p. 7036-7050, Dec. 2014.

GELMAN, L. The new higher order spectral techniques for non-linearity monitoring of structures and machinery. In: INTERNATIONAL CONFERENCE OF THE SLOVENIAN SOCIETY FOR NON-DESTRUCTIVE TESTING, 21., 2013, Portorož. **Proceedings...**Portorož: Cranfield University, 2013. 1 CD-ROM.

GEORGOULAS, G. et al. Bearing fault detection based on hybrid ensemble detector and empirical mode decomposition. **Mechanical Systems and Signal Processing**, London, v. 41, n. 1/2, p. 510-525, Dec. 2013.

GILLICH, G. R.; PRAISACH, Z. I. Damage-patterns based method to locate discontinuities in beams. **Health Monitoring of Structural and Biological Systems**, Bellingham, v. 8695, p. 11-14, Apr. 2013.

GIUNTA, G. et al. Free vibration analysis of composite beams via refined theories. **Composites: Part B**, Kidlington, v. 44, n. 1, p. 540-552, Jan. 2013.

HADJILEONTIADIS, L. J.; DOUKA, E.; TROCHIDIS, A. Crack detection in beams using kurtosis. **Computers and Structures**, Elmsford, v. 83, n. 12/13, p. 909-919, May 2005.

HASSAM, M. A. et al. **Analysis of nonlinear vibration-interaction using higher order spectra to diagnose aerospace system faults**. Columbia: University of South Carolina, 2012.8 p.

HAYKIN, S. **Neural networks and learning machines**. 3rded. Ontario: Prentice Hall, 2008.936 p.

HIBBELER, R.C. **Resistência dos materiais**. 3. ed. Rio de Janeiro: LTC, 1997.688 p.

HUDA, A.S.; TAIB, S. Application of infrared thermography for predictive/preventive maintenance of thermal defect in electrical equipment. **Applied Thermal Engineering**, Oxford, v. 61, n. 2, p. 220-227, Nov. 2013.

JARDINE, A. K. S.; LIN, D.; BANJEVIC, D. A review on machinery diagnostics implementing condition-based maintenance. **Mechanical Systems and Signal Processing**, London, v. 20, n. 7, p. 1483-1510, Oct. 2006.

JASSIM, Z.A. et al. A review on the vibration analysis for a damage occurrence of a cantilever beam. **Engineering Failure Analysis**, Oxford, v. 31, p. 442-461, July 2013.

KALLIGEROS, S. S. Predictive maintenance of hydraulic lifts through lubricating oil analysis. **Machines**, Basel, v. 2, n. 1, p. 1-12, Jan. 2014.

KARDEC, A.; NASCIF, J.; BARONI, T. **Gestão estratégica e técnicas preditivas**. Rio de Janeiro: Qualitymark, 2002. 160 p.

KIM, H. E. et al. Bearing fault prognosis based on health state probability estimation. **Expert Systems with Application**, New York, v. 39, n. 5, p. 5200-5213, Apr. 2012.

KOTHAMASU, R. **Intelligent condition based maintenance: a soft computing approach to system diagnosis and prognosis**. 2005. 100 p. Thesis (Doctoral in Industrial Engineering)- University of Cincinnati, Cincinnati, 2005.

LABIB, A.; KENNEDY, D.; FEATHERSTON, C. Free vibration analysis of beams and frames with multiple cracks for damage detection. **Journal of Sound and Vibration**, London, v. 333, n. 20, p. 4991-5003, Sept. 2014.

LEO, M. et al. Identification of defective areas in composite materials by bivariate EMD analysis of ultrasound. **IEEE Transactions on Instrumentation and Measurement**, New York, v. 61, n. 1, p. 221-232, Jan. 2012.

LI, N. et al. Mechanical fault diagnosis based on redundant second generation wavelet packet transform, neighborhood rough and support vector machine. **Mechanical Systems and Signal Processing**, London, v. 28, p. 608-621, Apr. 2012.

LIAO, W.; WANG, Y. Data-driven machinery prognostics approach using in a predictive maintenance model. **Journal of Computers**, Taiwan, v. 8, n. 1, p. 225-231, Jan. 2013.

LIU, S. et al. Diagnosis of structural cracks using wavelet transform and neural networks. **NDT&E International**, London, v. 54, p. 9-18, Mar. 2013.

LIU, Z. et al. Multi-fault classification based on wavelet SVM with PCO algorithm to analyze vibration signals from rolling elements bearing. **Neurocomputing**, New York, v. 99, n. 1, p. 399-410, Jan. 2013.

MAECK, J. **Damage assessment of civil engineering structures by vibration monitoring**. 2003. 209 p. Thesis (Ph.D. in Civil Engineering) – Universite it Leuven, Leuven, 2003.

MÁRQUEZ, F. P. G. et al. Condition monitoring of wind turbines: techniques and methods. **Renewable Energy**, Oxford, v. 46, p. 169-178, Oct. 2012.

MATUCK, G. R. **Processamento de sinais de voz padrões comportamentais por redes neurais artificiais**. São José dos Campos: INPE, 2005. 56 p.

MCINERNY, S.A.; DAI, Y. Basic vibration signal processing for bearing fault detection. **IEEE Transactions on Education**, New York, v. 46, n. 1, p. 149-156, Feb. 2003.

MELO, M. **Arco-verde identificação de falhas em sistemas rotativos empregando técnicas não lineares**. 2008. 120 p. Dissertação (Mestrado em Engenharia Mecânica) - Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2008.

MENDEL, J. M. Tutorial on higher-order statistics (spectra) in signal processing and system theory: theoretical results and some applications. **Proceedings of the IEEE**, New York, v. 79, n. 3, p. 278-305, 1991.

MERCER, J. Functions of positive and negative type, and their connection with the theory of integral equations. **Transactions of the London Philosophical Society**, London, v. 209, p. 415-446, 1909.

MITRA, S. K. **Digital signal processing: a computer-based approach**. Kolkata: McGraw-Hill, 1998.940 p.

MOHAMMED, A.A. et al. Crack detection in a rotationshaft using neural networks and PSDcharacterization. **Meccanica**, Torino, v. 49, n. 2, p. 255-266, Feb. 2014.

MOHAMMED, O. D. et al. Vibration signals analysis for gear fault diagnosis with various crack progression scenarios. **Mechanical Systems and Signal Processing**, London, v. 41, n. 1/2, p. 176-195, Dec. 2013.

NICHTERWITZ, M. P. **Estudo comparativo entre métodos de valor de pico (PEAKVUE) e da demodulação de sinais de vibração (Envelope) na previsão de falhas em rolamentos**. 2013. 19 p. Monografia (Graduação em Engenharia Mecânica) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2013.

NIKIAS, C. L.; MENDEL, J. M. Signal processing with higher-order spectra. **IEEE Signal Processing Magazine**, New York, v. 10, n. 3, p. 10-37, July 1993.

NIKIAS, C. L.; PETROPULU, A. P. **Higher-order spectra analysis: a nonlinear signal processing framework**. Englewood Cliffs: Prentice Hall, 1993.537 p.

NOGUERIA, C. N. et al. **Manutenção Produtiva Total (TPM)**. Belo Horizonte: UniBH, 2012.197 p.

OLTEAN, M. et al. Compression methods for mechanical vibration signals: application to the plane engines. **Mechanical Systems and Signal Processing**, London, v. 41, n. 1/2, p. 313-327, Dec. 2013.

PATIL, D.P.; MAITI, S.K. Experimental verification of a method of detection of multiple cracks in beams based on frequency measurements. **Journal of Sound and Vibration**, London, v. 281, n. 1/2, p. 439-451, Mar. 2005.

PENNY, J. E.T.; FRISWELL, M. I.; INMAN, D. J. Approximate frequency analysis in structural dynamics. **Mechanical Systems and Signal Processing**, London, v. 27, p. 370-378, Feb. 2012.

PEREIRA, M. H. A. **Desenvolvimento de planos e estudos de manutenção**. Porto: Bosh Car Multimédia, 2012.91 p.

RAJ, V. P.; NATARAJAN, K.; GIRIKUMAR, T.G. Induction motor fault detection and diagnosis by vibration analysis using MEMS accelerometer:emerging trends in communication, control, signal processing & computing applications (C2SPCA).In: INTERNATIONAL CONFERENCE ON IEEE, 2013, Bangalore.**Proceedings...** Bangalore: IEEE, 2013. p. 1-6.

RAMIRES SOBRINHO, R. **Método para proteção dos dados contra falhas de comunicação em redes de sensores sem fios**. 2007. 326 f. Tese (Doutorado em Engenharia Naval e Oceânica) - Universidade de São Paulo, São Paulo, 2007.

RAO, B.K.N.; PAI, P. S.; NAGABHUSHANA, T.N. Failure diagnosis and prognosis of rolling: element bearings using Artificial Neural Networks: a critical overview. **Journal of Physics: Conference Series**, Bristol, v. 364, n. 1, p. 12023, 2012.

RAO, S. S. **Vibrações mecânicas**. São Paulo: Pearson Prentice Hall, 2008.448 p.

RIBEIRO, M. V. et al. Detection of disturbances in voltage signals for power quality analysis using HOS. **EURASIP Journal on Applied Signal Processing**, Heidelberg, v. 2007, p. 1-13, 2007. Special issue.

RIEDMILLER, M.; BRAUN, H. A direct adaptive method for faster backpropagation learning: the rprop algorithm.In: IEEE INTERNATIONAL

CONFERENCE ON NEURAL NETWORKS, 1993, San Francisco.
Proceedings... San Francisco: IEEE, 1993. p. 586-591.

RIZOS, P. F.; ASPRAGATHOS, N. Identification of crack location and magnitude in a cantilever beam from the vibration modes. **Journal of Sound and Vibration**, London, v. 138, n. 3, p. 381-388, May 1990.

ROSALES, M. B.; FILIPICH, C. P.; BUEZAZ, F. S. Crack detection in beam-like structures. **Engineering Structures**, Guildford, v. 31, n. 10, p. 2257-2264, Oct. 2009.

ROSENBLANTT, F. **Principles of neurodynamics**. New York: Spartan Books, 1962. 616 p.

RUIZ-GONZALEZ, R. et al. 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**, New York, v. 14, n. 11, p. 20713-20735, Nov. 2014.

SAID, L.; ALI, J.B.; FNAIECH, F. Application of higher order spectral features and support vector machines for bearing faults classification. **ISA Transactions**, Pittsburgh, v. 54, p. 193-206, Jan. 2014.

SAID, L. et al. Diagnosis of broken-bars fault in induction machines using higher order spectral analysis. **ISA Transactions**, Pittsburgh, v. 52, n. 1, p. 140-148, Jan. 2013.

SALAT, R.; OSOWSKI, S. Accurate fault location in the power transmission line using support vector machine approach. **IEEE Transaction on Power System**, New York, v. 19, n. 2, p. 979-986, May 2004.

SATPAL, S. B. et al. Structural health monitoring of a cantilever beam using support vector machine. **International Journal of Advanced Structural Engineering**, New York, v. 5, n. 2, p. 1-7, 2013.

SCHOLKOPF, B. et al. Estimating the support of a high-dimensional distribution. **Neural Computation**, Cambridge, v. 13, n. 7, p. 1443-1471, 2001.

SEIFERT, K.; CAMACHO, O. **Implementing positioning algorithms using accelerometers**: Freescale semiconductor application note AN3397. Austin: Freescale, 2007. Disponível em: <<http://www.freescale.com>>. Acesso em: 10 out. 2014.

SHIKARI, B. **Automation in condition-based maintenance using vibration analysis**. Bhopal: Maulana Azad National Institute of Technology, 2006.121 p.

SHOJAEE, S. et al. Free vibration analysis of thin plates by using a NURBS-based isogeometric approach. **Finite Elements in Analysis and Design**, Amsterdam, v. 61, p. 23-34, Nov. 2012.

SINHA, A. **Vibration of mechanical systems**. New York: Cambridge University, 2010.250 p.

SU, H.; CHONG, K. T.; KUMAR, R. R. Vibration signal analysis for electrical fault detection of induction machine using neural networks. **Neural Computing and Applications Journal**, London, v. 20, n. 2, p. 183-194, Jan. 2011.

THINH, T. I.; NGUYEN, M. C. Dynamic stiffness matrix of continuous element for vibration of thick cross-ply laminated composite cylindrical shells. **Composite Structures**, Oxford, v. 98, p. 93-102, Apr. 2013.

VAKIL-BAGHMISHEH, M. T. et al. Crack detection in beam-like structures using genetic algorithms. **Applied Soft Computing**, New York, v. 8, n. 2, p. 1150-1160, Mar. 2008.

VAPNIK, V. N. **The nature of statistical learning theory**. New York: Springer-Verlag, 1995.314 p.

VAPNIK, V. N. **Statistical learning theory**. New York: J. Wiley, 1998.768 p.

VIOLA, E.; TORNABENE, F.; FANTUZZI, N. General higher-order shear deformation theories for the free vibration analysis of completely doubly-curved laminated shells and panels. **Composite Structures**, Oxford, v. 95, p. 639-666, Jan. 2013.

WANG, C. C.; KANG, Y. Feature extraction techniques of non-stationary signals for fault diagnosis in machinery systems. **Journal of Signal and Information Processing**, London, v. 3, n. 1, p. 16-25, Feb. 2012.

WANG, J. A rough set approach of mechanical fault diagnosis for five-plunger pump. **Advances in Mechanical Engineering**, Cairo, v. 2013, p. 1-11, Apr. 2013.

WANG, J.; CHENG, C.; ZHAO, S. De-noising method for mechanical vibration signals based on EMD. In: IITA INTERNATIONAL CONFERENCE ON GEOSCIENCE AND REMOTE SENSING, 2., 2010, Qingdao. **Proceedings...**Qingdao: IITA, 2010. p. 411-413.

XENOS, H. G. **Gerenciando a manutenção produtiva**. Nova Lima: INDG, 2004. 302 p.

XIANG, J. et al. Detect damages in conical shells using curvature mode shape and wavelet finite element method. **International Journal of Mechanical Sciences**, Elmsford, v. 66, p. 83-93, Jan. 2013.

YAN, B. et al. Beam structure damage identification based on BP neural network and support vector machine. **Mathematical Problems in Engineering**, Cairo, v. 2014, p. 1-8, Jan. 2014.

YANG, X.F.; SWAMIDAS, A.S.J.; SESHADRI, R. Crack identification in vibration beams using the energy method. **Journal of Sound and Vibration**, London, v. 244, n. 2, p. 339-357, 2001.

YUAN, Y.; JIANG, X.; LIU, X. Predictive maintenance of shield tunnels. **Tunnelling and Underground Space Technology**, Oxford, v. 38, p. 69-86, Sept. 2013.

ZHOU, Z. **Vibration based damage detection of simple bridge superstructures**. 2006. 378 p. Thesis (Ph.D. in Philosophy) - University of Saskatchewan, Saskatoon, 2006.

ANEXO

ANEXO A - Algoritmo do Arduino para o Controle do Sistema

Algoritmo para o controle do sensor e da fonte de distúrbio pelo Arduino:

```
#include <AcceleroMMA7361.h>

AcceleroMMA7361 accelero;
int x;
int y;
int z;

int const potenciometro = 5; //pino analógico onde o potenciômetro está
conectado.
int const transistor = 9; //pino digital onde o TIP120 está conectado.

int const ledVerde = 2; //pino digital que o led verde está conectado.
int const ledAmarelo = 3; //pino digital que o led amarelo está conectado.
int const ledVermelho = 4; //pino digital que o led vermelho está
conectado.

int valPotenciometro = 0; //armazenará o valor lido no potenciômetro.

//função setup é executada uma vez quando o arduino é ligado.
void setup() {
  pinMode(transistor, OUTPUT); //definindo o pino digital 9 como de
saída.

  //definindo pinos dos leds como de saída
  pinMode(ledVerde, OUTPUT);
  pinMode(ledAmarelo, OUTPUT);
  pinMode(ledVermelho, OUTPUT);

  Serial.begin(9600);
  accelero.begin(13, 12, 11, 10, A0, A1, A2);
  accelero.setAREFVoltage(5); //sets the AREF voltage to 3.3V
  accelero.setSensitivity(HIGH); //sets the sensitivity to +/-6G
  accelero.calibrate();
}
```


//Função loop é executada repetidamente, enquanto o arduino estiver ligado.

```
void loop() {
  //lendo o valor do potenciômetro (0 até 1023) e dividindo por 4 para obter um
```

```
  //valor entre 0 e 255 que são valores adequados para a base do TIP120.
  valPotenciometro = analogRead(potenciometro) / 4;
```

```
  //atribuindo o valor lido no potenciômetro a base do TIP120.
  analogWrite(transistor, valPotenciometro);
```

```
  //acendendo e pagando leds conforme posição do potenciômetro
  controlarLeds();
```

```
  x = accelero.getXAccel();
  y = accelero.getYAccel();
  z = accelero.getZAccel();
  Serial.print("\nx: ");
  Serial.print(x);
  Serial.print(" \ty: ");
  Serial.print(y);
  Serial.print(" \tz: ");
  Serial.print(z);
  Serial.print("\tG*10^-2");
  delay(0.005); //make it readable
}
```

```
void controlarLeds() {
```

//Led verde - acendendo ou apagando conforme posição do potenciômetro.

```
  if (valPotenciometro >= 40) {
    digitalWrite(ledVerde, HIGH);
  } else {
    digitalWrite(ledVerde, LOW);
  }
}
```

//Led amarelo - acendendo ou apagando conforme posição do potenciômetro.

```
  if (valPotenciometro >= 125) {
    digitalWrite(ledAmarelo, HIGH);
  } else {
    digitalWrite(ledAmarelo, LOW);
  }
}
```

```
    }  
  
    //Led vermelho - acendendo ou apagando, conforme posição do  
potenciômetro.  
    if (valPotenciometro >= 210) {  
        digitalWrite(ledVermelho, HIGH);  
    } else {  
        digitalWrite(ledVermelho, LOW);  
    }  
}
```