

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA

Relatório Final
Trabalho de Graduação II

**Análise de Componentes Independentes (ICA)
na Detecção Automática de Falhas em
Motores Elétricos de Indução**

Autor: Leonardo Dias Pagotto

Orientador: Prof. Dr. André Ricardo Fioravanti

Campinas, 12 de Junho de 2015

UNIVERSIDADE ESTADUAL DE CAMPINAS

FACULDADE DE ENGENHARIA MECÂNICA

Relatório Final
Trabalho de Graduação II

Análise de Componentes Independentes (ICA) na Detecção Automática de Falhas em Motores Elétricos de Indução

Autor: Leonardo Dias Pagotto

Orientador: Prof. Dr. André Ricardo Fioravanti

Curso: Engenharia de Controle e Automação

Trabalho de Graduação apresentado à Comissão de Graduação da Faculdade de Engenharia Mecânica, como requisito para a obtenção do título de Engenheiro de Automação e Controle.

Campinas, 2015

S.P. – Brasil

Índice

Resumo	1
Lista de Figuras.....	2
Lista de Tabelas	2
Capítulo 1.....	3
Introdução	3
Capítulo 2.....	5
Revisão Bibliográfica.....	5
2.1 Fluxograma do processo de análise de vibração.....	8
2.2 Análise Espectral de Sinais.....	9
2.3 Descrição da DFT	12
2.4 Janelamento.....	14
2.5 Identificação de Modelos de Falhas em Motores	16
2.6 Análise de Componentes Independentes (ICA).....	18
2.7 Princípios da Análise de Componentes Independentes	19
2.8 ICA em Problemas Subdimensionados – Análise de Componentes Esparsos	20
Capítulo 3.....	24
Procedimento Experimental.....	24
Capítulo 4.....	30
Resultados e Discussões	30
Capítulo 5.....	46
Conclusões	46
Referências Bibliográficas.....	47

Resumo

PAGOTTO, Leonardo Dias, *Análise de Componentes Independentes (ICA) na Detecção Automática de Falhas em Motores Elétricos de Indução*, Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, Trabalho de Conclusão de Curso, (2015).

A detecção antecipada de falhas em equipamentos é uma das maiores preocupações na indústria. Muitas técnicas foram desenvolvidas para a detecção de falhas em máquinas rotativas. A análise de vibração no domínio da frequência é a técnica mais usada uma vez que praticamente todas as falhas em motores estão relacionadas à mudança em sua dinâmica. Os dados obtidos foram coletados pelo dispositivo para aquisição de aceleração tri-axial de motores elétricos desenvolvidos na disciplina de Trabalho de Graduação I, base para aplicação da teoria de separação cega de fontes através do método conhecido como Análise de Componentes Independentes (ICA). A comparação entre o número de fontes de diversos motores foi utilizada para validar a quantidade de componentes na frequência e a respectiva correlação com falhas em motores elétricos.

Palavras Chave: Análise de Vibração, Detecção de Falhas, Análise de Componentes Independentes

Lista de Figuras

Figura 1. Falhas comuns e suas causas em motores de indução	5
Figura 2. Possível falha do motor relacionada à frequência de vibração	7
Figura 3. Condição de operação do equipamento e vida útil.....	7
Figura 4. Etapas do monitoramento por análise de vibração	8
Figura 5. Etapas da análise espectral	10
Figura 6. Resolução do espectro na frequência	11
Figura 7. Resposta em frequência da resposta ao impulso.....	13
Figura 8. Janela retangular, Hamming e Blackman	15
Figura 9. Espectro qualitativo de vibração para falhas típicas em motores	17
Figura 10. Motor de indução com rotor de gaiola de esquilo.....	26
Figura 11. Local de instalação dos motores utilizados	28
Figura 12. Comparação entre janelas para o motor 2	30
Figura 13. Comparação entre janelas para o motor 3	31
Figura 14. Influência do numero de pontos da DFT no espectro	32
Figura 15. Efeito da diminuição do tamanho da janela no espectro.....	33
Figura 16. DFT dos sinais originais dos acelerômetros no motor 1	34
Figura 17. Perfil de clusters em gráfico semi-log para r_3 do motor 1.....	35
Figura 18. DFT dos sinais filtrados dos acelerômetros nas três dimensões.....	35
Figura 19. Sinal original da aceleração radial e respectivo espectrograma	36
Figura 20. DFT dos sinais originais dos acelerômetros do motor 2	36
Figura 21. Perfil de clusters em gráfico semi-log para r_1 do motor 2.....	37
Figura 22. DFT dos sinais filtrados dos acelerômetros nas três dimensões.....	38
Figura 23. Sinal original da aceleração radial e respectivo espectrograma	38
Figura 24. DFT dos sinais originais dos acelerômetros do motor 3	39
Figura 25. Perfil de clusters em gráfico semi-log para r_3 do motor 3.....	40
Figura 26. DFT dos sinais filtrados dos acelerômetros nas três dimensões.....	40
Figura 27. Sinal original da aceleração axial e respectivo espectrograma	41
Figura 28. DFT dos sinais originais dos acelerômetros do motor 4	41
Figura 29. Perfil de clusters em gráfico semi-log para r_2 do motor 4.....	42
Figura 30. DFT dos sinais filtrados dos acelerômetros nas três dimensões.....	43
Figura 31. Sinal original da aceleração axial e respectivo espectrograma	43

Lista de Tabelas

Tabela 1. Melhor função de janelamento por aplicação	15
Tabela 2. Resumo dos principais recursos do Arduino Uno R3.....	24
Tabela 3. Resumo dos principais recursos do MMA7361	25
Tabela 4. Especificações dos motores utilizados	27

Capítulo 1

Introdução

A detecção antecipada de falhas em equipamentos industriais é uma grande preocupação da indústria, sendo necessária para garantir a disponibilidade dos processos produtivos. É no estágio onde os equipamentos começam a apresentar suas primeiras falhas que é mais fácil consertá-lo, beneficiando assim a indústria com menores custos e tempos de manutenção.

Motores de indução são grandemente empregados graças à sua robustez, baixo custo, baixa manutenção e alta versatilidade; representando 85% do consumo de energia mundial [2]. Falhas nos motores de indução podem proporcionar interrupções não previstas em linhas de produção, causando consequências severas na qualidade de um produto, segurança e custo. Por essa razão, a detecção antecipada de falhas em motores de indução tem atraído à atenção de diversos pesquisadores nos últimos tempos [3-6].

As técnicas mais populares de detecção de falhas em motores de indução são baseadas na análise da corrente do motor (MCSA – Motor Current Signature Analysis) e na análise de vibração [7] por se tratar de técnicas não invasivas. No entanto, a análise de vibração no domínio da frequência é a técnica mais usada uma vez que praticamente todas as falhas em motores estão relacionadas à mudança em sua dinâmica. Além disso, a análise no domínio da frequência dá maiores informações sobre o estado de um equipamento do que a análise no domínio do tempo.

Técnicos responsáveis pela manutenção preventiva normalmente utilizam analisadores de vibrações dotados de um único canal, monitorando a vibração em uma única dimensão do equipamento; aparelhos que realizam múltiplas medições são caros e são geralmente utilizados em outras aplicações, e ainda assim não são específicos para realizar um monitoramento contínuo no equipamento. Por essa razão, o desenvolvimento de uma instrumentação que realize essa análise de vibração completa no equipamento sem a necessidade de pessoal treinado e com monitoramento contínuo será estudado.

Novos trabalhos têm tratado desse tema introduzindo melhorias com relação aos trabalhos anteriores. Em [8], um analisador de vibração em múltiplos-eixos foi desenvolvido, porém sendo ainda necessária a utilização de um PC para a análise do espectro e exibição do resultado. Em [9] um analisador de vibração baseado na Transformada Rápida de Fourier (FFT - Fast Fourier Transform) capaz de ajustar parâmetros para melhor obtenção do espectro foi introduzido. Em [10] uma nova abordagem é desenvolvida com a utilização de FPGA (Field Programmable Gate Array) para o cálculo do espectro em tempo real sem o uso de um computador graças às altas velocidades de processamento do FPGA.

A aplicação da ICA em detecção de falhas em motores elétricos [19] pode ser interpretada da mesma maneira que na detecção da voz no exemplo clássico da BSS [20]. Um motor elétrico na indústria apresenta vibrações relativas a diversas fontes, podendo ser atribuídas ao solo, carga, rotação do motor, acoplamentos mecânicos ou deficiência no funcionamento. A captação dos sinais provenientes de diferentes fontes pode ser realizada por acelerômetros mecanicamente acoplados a carcaça do motor.

Capítulo 2

Revisão Bibliográfica

O estudo de detecção de falhas em máquinas rotativas é um tema recorrente no meio acadêmico graças a sua grande aplicabilidade no meio industrial, como em mancais ou motores. Basicamente as duas técnicas mais populares de detecção de falhas em motores são feitas monitorando a corrente elétrica do estator ou monitorando a vibração do motor [1]. As falhas comuns em motores, relacionados tanto ao estator quanto ao rotor estão representadas na figura abaixo.



Figura 1. Falhas comuns e suas causas em motores de indução

A técnica de monitoramento por corrente, conhecida também como MCSA, é baseada na corrente circulando no estator para assim relacionar o sinal medido com uma falha específica. Essa técnica pode ter ainda duas variações: uma baseada no estado estacionário; outra baseada na inicialização, ou transiente.

Análise no estado estacionário é apresentada em [11], onde o autor foca o trabalho na detecção de barras quebradas do rotor identificando faixas de frequências características que aparecem no espectro quando o motor apresenta esse tipo de problema. Análise na corrente em estado estacionário pode ainda detectar outros tipos de falhas, como excentricidade do entreferro, problemas no mancal, efeitos de carregamento, entre outras, como em [12]. Análise no transiente também é utilizada para detecção de falhas em motores, onde a transformada discreta pode ser aplicada para detectar barras quebradas do rotor utilizando parâmetros de ponderação.

A técnica MCSA gera bom resultados, porém como todas as formas de detecção de falhas requerem instrumentação e algoritmo específico para gerar um diagnóstico automático correto. Por outro lado, a análise de vibração pode ser usada como uma técnica geral de detecção de falha, pois praticamente todas as falhas são causadas por mudanças na vibração do motor. Muito embora haja um grande esforço em pesquisa para estabelecer a relação entre a falha de um motor e sua vibração.

Em [13], a análise de vibração é aplicada para a detecção de diferentes falhas utilizando a FFT como ferramenta matemática. Outra aplicação é mostrada em [14], onde ambos os espectros de corrente e vibração são utilizados para detectar barras de rotores quebradas em motores sem cargas. Abaixo segue figura com síntese da associação entre a possível falha e sua correspondente frequência de vibração, com base na velocidade de rotação do motor.

Esse monitoramento baseado em vibração tem se tornado nos últimos anos uma técnica significativamente popular, graças a sua versatilidade e habilidade em detectar de maneira eficaz as menores mudanças no modo de operação do um equipamento que poderia eventualmente levar a uma parada. A análise de vibração foi considerada nos últimos estudos como a técnica de monitoramento com capacidade de oferecer a maior vida útil ao equipamento [18].

Frequency	Possible Failure
1 x RPM	Unbalance, looseness, misalignment of gear or pulley, resonance, electrical problems, alternative forces
2 x RPM	Mechanical offset, misalignment, alternative forces, resonance
3 x RPM	Misalignment, axial mechanical breath
< 1 x RPM	Slip, oil whirl
Supply frequency	Electrical problems
RPM harmonics	Broken bars, Damaged gears, aerodynamic forces, hydraulic forces, mechanical set, alternative forces

Figura 2. Possível falha do motor relacionada à frequência de vibração

A aquisição adequada dos dados de vibrações é de imenso valor ao tentar diagnosticar pequenas mudanças relativas à operação normal do equipamento, que pode ser devido à manutenção incorreta no equipamento, problemas operacionais, de desenvolvimento ou instalação, ou ainda envelhecimento. A figura abaixo mostra uma comparação entre o tempo estimado para a falha no equipamento com relação às técnicas mais convencionais de monitoramento.

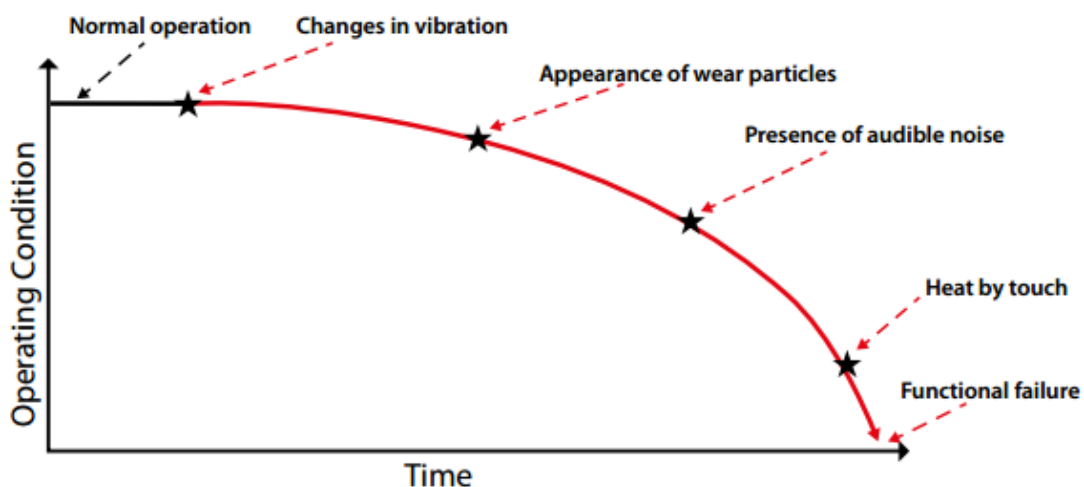


Figura 3. Condição de operação do equipamento e vida útil

2.1 Fluxograma do processo de análise de vibração

O monitoramento pela análise de vibração utiliza técnicas para a determinação do estado real de operação dos equipamentos, assim manutenções preventivas podem ser realizadas no equipamento com base nas vibrações que ele apresenta e que estejam fora de condições normais. As atividades principais podem ser esquematizadas como na figura abaixo.

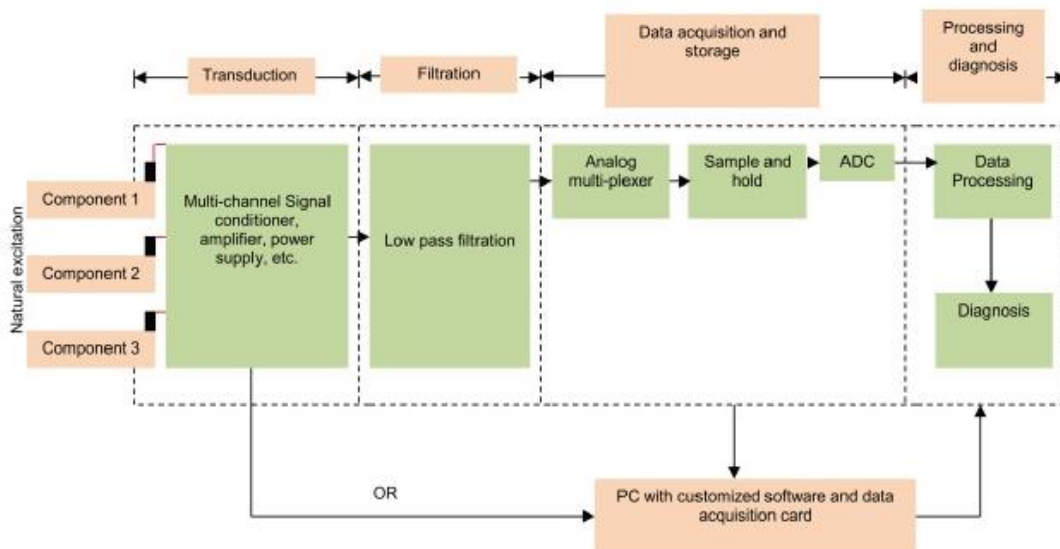


Figura 4. Etapas do monitoramento por análise de vibração

Os dados de vibrações dos equipamentos são normalmente adquiridos através de transdutores (de aceleração, velocidade ou posição), que convertem a vibração medida num sinal apropriado, normalmente voltagem. Outro ponto importante na seleção do parâmetro de medição é a frequência de interesse. Independentemente do caso, entretanto, um sinal relativamente grande é necessário para obter uma boa relação sinal-ruído, que é a razão da amplificação e condicionamento do sinal.

Ruídos podem aparecer das conexões elétricas dos próprios transdutores ou de outras fontes de interferência de sinais diferentes da medida, como por exemplo, equipamentos adjacentes. A utilização de um filtro passa baixa ou anti-aliasing (projetado para eliminar frequências maiores que a metade da frequência de amostragem) é altamente recomendável, de maneira a evitar o aparecimento de altas frequências nas regiões de baixas frequências.

A conhecida regra da mão direita propõe que sensores de deslocamento sejam usados para baixas frequências, sensores de velocidade para médias frequências e sensores de aceleração para altas frequências. Isso porque quanto maior a rigidez do princípio de funcionamento do sensor, maior é sua frequência natural de operação, a razão de acelerômetros serem muito estáveis nas regiões de altas frequências. Sensores de velocidades, por outro lado, possuem grandes massas e baixa rigidez e uma frequência natural mais baixa, e por esse motivo tem mais estabilidade para frequências abaixo de sua frequência natural.

Outro ponto essencial durante a aquisição de dados de vibração é que o grau de repetitividade conseguido com os sensores de vibração é altamente dependente da maneira que ele é montado no equipamento (acoplado, adesivo, imã ou com a mão), especialmente quando lidamos com falhas em altas frequências como nos rolamentos. Isso implica que o intervalo de linearidade do sensor diminui proporcionalmente à rigidez da montagem, motivo pelo qual a repetitividade diminuirá de sensores acoplados mecanicamente ao equipamento comparado a aqueles fixados a mão.

Uma vez os complexos dados de vibração (caracterizado por vários componentes de frequências com diferentes amplitudes, devido a diferentes forças geradas por cada componente da montagem) são coletados, eles podem ser processados utilizando análises no domínio do tempo, da frequência ou tempo-frequência. A etapa final do processo de análise de vibração é o diagnóstico do problema, onde diferentes características obtidas dos dados de vibração processados são combinadas para prever falhas (desalinhamento, desgaste do eixo, folga, rachaduras) assim como componentes defeituosos.

2.2 Análise Espectral de Sinais

É muito comum existir uma informação codificada em forma de ondas senoidais em um sinal, ocorrendo na forma natural deste ou naqueles criados por humanos. Na dinâmica universal diversos mecanismos assumem movimentos oscilantes e a forma do sinal no tempo normalmente esconde informações preciosas sobre esse sinal. Essas informações chave são melhores interpretadas no domínio da frequência, determinados por amplitude,

frequência e fase. Nesse contexto a transformada de Fourier é extremamente utilizada para extrair essas características do sinal.

Ao analisamos um sinal a primeira ação é simplesmente observá-lo. Na figura abaixo (a) vemos uma quantidade grande de ruídos e poucas informações à primeira vista. Multiplicando esse sinal por outro na forma de uma curva suave, nesse caso a janela de Hamming (b), obtemos um sinal onde as amostras próximas aos extremos tem redução em sua amplitude (c).

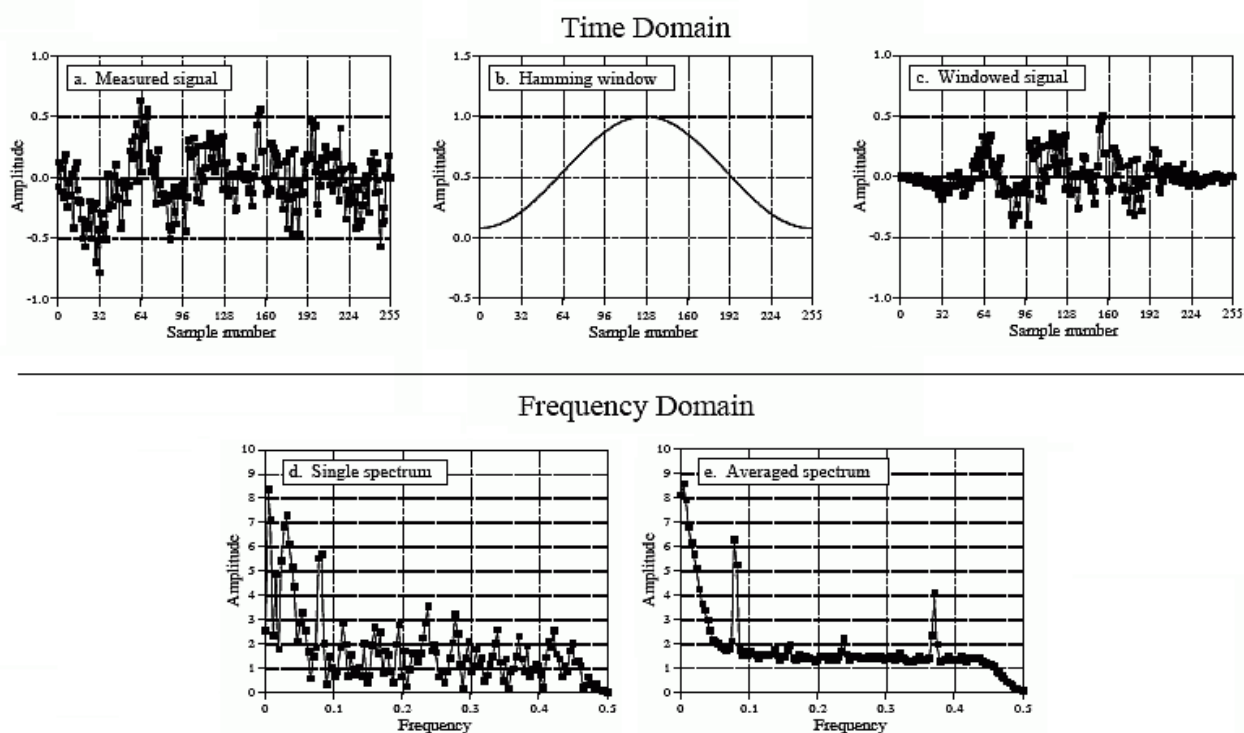


Figura 5. Etapas da análise espectral

Aplicando a transformada de Fourier para um sinal digital, obtemos assim o espectro em frequência e amplitude do sinal (d). Mesmo após esse processamento, o resultado ainda encontra-se cheio de ruídos. Isso acontece quando não há pontos suficientes no sinal original de forma a obter uma curva com um comportamento melhor definido. A utilização de mais pontos na DFT (Discrete Fourier Transform) não causa alterações já que quanto maior o número de amostras no espectro a informação é diluída pelo mesmo fator. Quanto maior o número de pontos na DFT melhor a resolução na frequência para um mesmo nível de ruído.

A utilização de mais pontos no sinal original é uma forma de contornar esse problema sem aumentar o número de pontos do espectro na frequência. Isso pode ser feito segmentando o sinal de entrada e cada um desses segmentos sendo multiplicados por janelas específicas, obtendo uma DFT desse segmento. O espectro em frequência resultante é então uma média desses espectros (e). Assim o ruído presente no sinal original é claramente atenuado e permite que suas características principais sejam analisadas tendo somente a magnitude da amplitude rateada no resultado. O ruído é assim diminuído na mesma proporção que a raiz quadrada do número de segmentos.

Outra forma de atenuar esse ruído espectral é a utilização de um filtro passa-baixa digital com o custo da diminuição da resolução. Todavia para obtenção de um espectro com menor ruído e melhor resolução uma boa solução é adquirir mais dados do sinal de entrada. Com mais pontos (melhor resolução) e maior números de segmentos do sinal (menor ruído) obtemos um sinal de saída mais limpo e fácil de ser analisado.

Há ainda dois fatos que determinam a resolução em frequência, dada pelo quão próximo dois picos podem ser distinguidos sem se fundirem. O primeiro é o comprimento da DFT: o espectro produzido por um sinal de tamanho N consiste em $N/2+1$ amostras igualmente espaçadas entre o zero e metade da frequência de amostragem. Para separar esse dois picos, a resolução na frequência deve ser menor que a distância entre esses dois picos. Na figura abaixo, a DFT de 512 pontos é suficiente para separar os picos no sinal, enquanto que uma DFT de 128 pontos não.

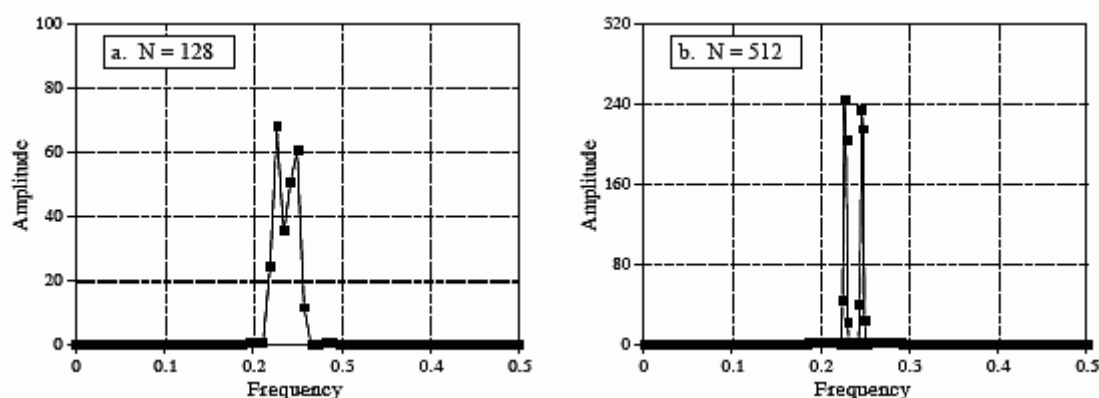


Figura 6. Resolução do espectro na frequência

Outro fator que limita a resolução é o tamanho do sinal da entrada. Em um segmento de sinal curto, a forma de onda pode ter a forma de somente uma onda senoidal. Quanto mais próximas às frequências, mais longo o segmento deve ser para concluir que mais de uma frequência está presente. Quando obtemos um sinal curto e adicionamos zeros não mudamos a forma do espectro, mas obtemos mais amostras na frequência e uma leve melhora na identificação de picos próximos.

2.3 Descrição da DFT

Sistemas são analisados no domínio do tempo usando convolução. Uma análise similar pode ser feita no domínio da frequência. Usando a transformada de Fourier, todo sinal pode ser representado como um conjunto de senos, cada um com uma amplitude e defasagem específica. Da mesma forma, a DFT pode ser usada para representar cada sinal de saída da mesma maneira. Isso significa que qualquer sistema linear pode ser completamente descrito como uma mudança nas amplitudes e fases de senos do sinal. Essa informação é a resposta em frequência do sistema. A relação entre a resposta ao impulso e resposta em frequência é um fundamento do processamento de sinal: a resposta em frequência de um sistema é a transformada de Fourier da resposta ao impulso dele.

A figura abaixo mostra a utilização da DFT para converter a resposta ao impulso de um sistema na sua resposta em frequência. Em (a) temos a resposta em frequência do sistema, que não mostra muita informação sobre a forma que o sistema comporta. Com a aplicação da DFT dessa resposta ao impulso obtemos a resposta em frequência do sistema (b). Assim fica mais evidente que o sistema passa frequências entre 0.2 e 0.3 e rejeita todas as outras, também conhecido como filtro passa-banda.

Essa resposta em frequência apresenta baixa resolução uma vez que o número de amostras definindo esse espectro é baixo. Essa situação pode ser melhorada adicionando zeros à resposta ao impulso antes de aplicar a DFT (c). Assim o espectro obtido depois da utilização desse artifício resulta em um espectro com maior resolução(d), o que pode ser feito aumentando a quantidade de zeros infinitamente e resultando em um sinal praticamente contínuo.

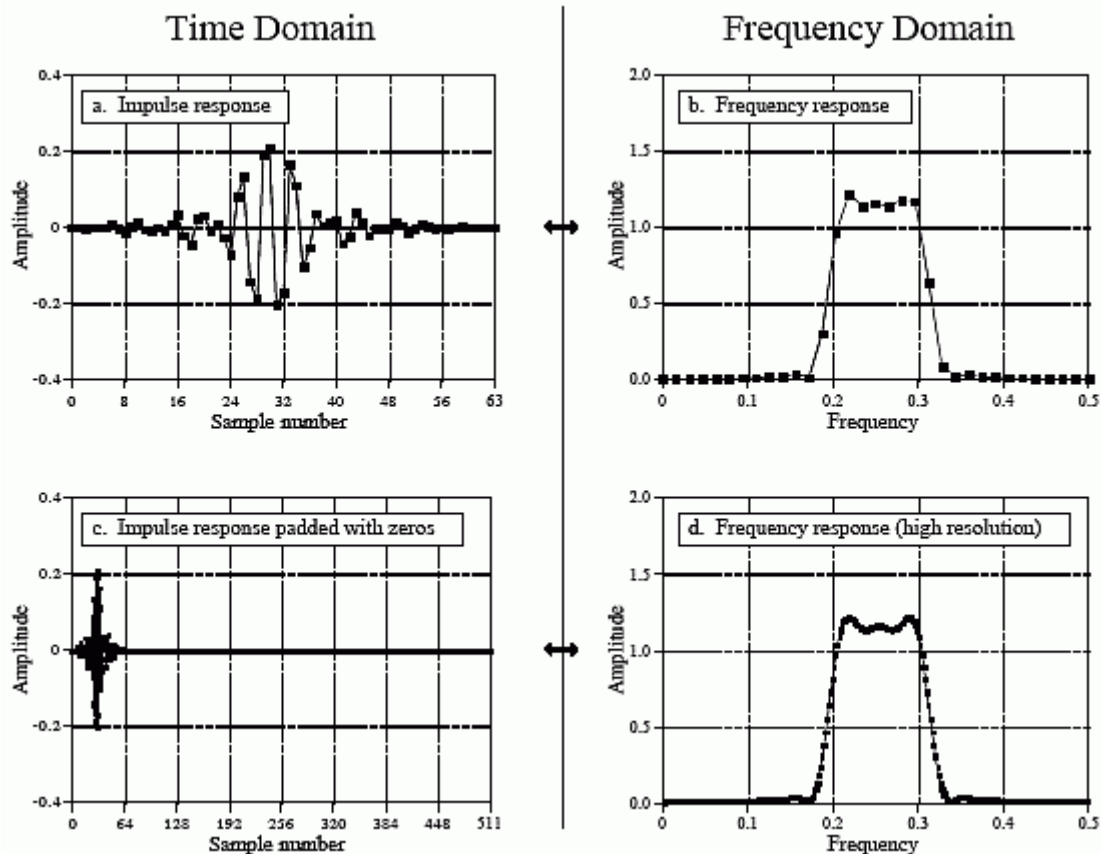


Figura 7. Resposta em frequência da resposta ao impulso

Há ainda de se considerar outro membro da família da transformada de Fourier, a Transformada de Fourier a Tempo Discreto (DTFT). Dado um sinal de N amostras no tempo, ao aplicar a DFT produzimos um sinal de $N/2 + 1$ amostras no domínio da frequência, pois a DFT considera que o sinal no domínio do tempo é infinitamente longo e periódico. Preenchendo o sinal no domínio do tempo com zeros, o espectro resultante possui maior resolução, deixando a frequência de amostragem cada vez menor.

Se levarmos esse caso ao extremo, preenchendo esse sinal com um número infinito de zeros no domínio do tempo, encontramos duas situações. Como o sinal no tempo tem um período infinitamente longo, o sinal torna-se aperiódico. Além disso, o sinal no domínio da frequência tem espaços infinitesimais entre as amostras, ou seja, tornou-se um sinal contínuo. A DTFT é uma técnica que transforma um sinal discreto aperiódico em um sinal contínuo no domínio da frequência. Em termos matemáticos, a resposta em frequência de um sistema é a DTFT da resposta ao impulso dele. Uma vez que esse sinal é contínuo e não pode ser processado no computador, a DFT é utilizada calculando-se uma taxa de amostragem para encontrar a correta resposta em frequência.

2.4 Janelamento

Quando um pico em um espectro é representado por um único ponto, ele mostra a frequência exata existente no sinal. Se um pico é visto em entre várias frequências do sinal, pode ter ocorrido o aparecimento de vazamento no pico. A solução para esse problema é multiplicar o sinal por uma janela antes de aplicar a DFT. O sinal é assim modificado em três aspectos: o formato do pico é favoravelmente mais parecido; o vazamento é consideravelmente reduzido; e a resolução do espectro é reduzida fazendo que os picos sejam mais largos, sendo um ponto negativo. Assim, no jargão do DSP, a janela é um compromisso entre melhor resolução (largura do pico) e leakage espectral (amplitude dos vazamentos).

O janelamento é basicamente uma técnica utilizada para moldar o formato de uma porção de sinal medida no tempo para minimizar os efeitos dos extremos que resulta em leakage espectral no espectro da DFT. Ao tomarmos um sinal senoidal discreto infinitamente longo com frequência de amostragem pequena, o espectro do sinal será um pico infinitamente estreito e todas as outras frequências sendo zero. Porém vale ressaltar que nem esse sinal e nem seu espectro podem ser processados em um computador, por ter natureza infinita. Para contornar essa situação, modificamos esse sinal de duas maneiras que distorcem o sinal.

Primeiramente truncamos a informação no sinal multiplicando por uma janela. Por exemplo, a multiplicação por uma janela retangular de tamanho N permite manter valores corretos para os N pontos, com todas as outras amostras no sinal infinitamente longo sendo definidas como zero. A janela de Hamming por sua vez molda o sinal de uma forma específica dentre desses N pontos, e define os valores extremos desse intervalo como sendo zero. O sinal é ainda considerado infinitamente longo, mas somente uma quantidade finita de amostras tem valores diferentes de zero.




Figura 8. Janela retangular, Hamming e Blackman

Quando dois sinais no domínio do tempo são multiplicados, o sinal correspondente na frequência é a convolução entre eles. Uma vez que o espectro original é um pico na forma da função delta, o espectro do sinal janelado é o espectro da janela na região do pico. Essas janelas degradam o espectro do sinal alargando o seu pico e adicionando um vazamento no sinal. Esse é um resultado inevitável uma vez que somente uma porção do sinal original é utilizada. Acima podemos ver a relação entre três janelas: a blackman possui o maior lóbulo principal (ruim), mas as menores amplitudes nos lóbulos secundários (bom); a janela retangular tem o menor lóbulo principal (bom), porém os maiores lóbulos secundários (ruim); a hamming está entre ambas. A melhor função de janelamento deve ser escolhida com base na aplicação, como mostrado na tabela abaixo.

Tabela 1. Melhor função de janelamento por aplicação

Window	Best for these Signal Types	Frequency Resolution	Spectral Leakage	Amplitude Accuracy
Rectangular	Transient	Best	Poor	Good
Barlett	Random	Good	Fair	Fair
Blackman	Random or mixed	Poor	Best	Good
Flat top	Sinusoids	Poor	Good	Best
Hanning	Random	Good	Good	Fair
Hamming	Random	Good	Fair	Fair
Kaiser-Bessel	Random	Fair	Good	Good
None (boxcar)	Transient & Synchronous	Best	Poor	Poor
Tukey	Random	Good	Poor	Poor
Welch	Random	Good	Good	Fair

A segunda forma de modificar o sinal de forma a ser representado em um computador é selecionar N pontos do sinal. Esses N pontos devem conter todos os valores não zeros dados pela janela, mas podem também incluir um número de zeros, que é como o efeito de amostrar o espectro em frequência do sinal contínuo. Se N for escolhido como maior que a largura da janela, as amostras no domínio da frequência serão próximas o bastante para que os picos do espectro contínuo sejam preservados nesse espectro discreto. Se N for do mesmo tamanho que a largura da janela, o número menor de amostras no espectro resultante pode originar em picos irregulares, dependendo de onde as frequências do sinal estão localizadas.

2.5 Identificação de Modelos de Falhas em Motores

Para a realização do diagnóstico de motores com falhas ou sem falhas são adotados modelos como referência. A análise de vibrações no domínio da frequência utiliza parâmetros do espectro do sinal como forma de reconhecer esses padrões. Alguns estudos na literatura apresentam a relação entre defeitos e características de vibração em máquinas elétricas [16-17].

O espectro do sinal durante operação normal (*unfault*) de um motor é caracterizado por uma harmônica na frequência de rotação do motor, F_w (figura abaixo), seguida de um número de harmônicas cuja amplitude é geralmente menor que um terço da amplitude de F_w . Se uma redução é presente no sistema, no mínimo três harmônicas principais devem aparecer: uma na frequência de rotação do eixo de baixa velocidade, uma na frequência de rotação do eixo de alta velocidade e outra na frequência do mecanismo de redução. Além disso, outras harmônicas estão presentes no espectro do sinal de um motor sem falhas por causa de vibrações existentes na estrutura onde o motor está localizado.

Todo tipo de falha mecânica causa uma alteração específica no espectro de um motor com relação a um motor sem falhas. Um eixo desbalanceado (*unbalance*) gera uma vibração radial considerável em F_w , e essa amplitude depende da rigidez na direção da análise. O efeito no espectro é um grande aumento na amplitude na frequência de F_w .

Uma vibração radial na frequência igual a duas vezes F_w é o principal efeito do desalinhamento (*misalignment*). Nesse caso, amplitude na frequência $2F_w$ normalmente

excede 75% da amplitude em F_w , e até mesmo 150% no caso de dano maior. Outro sintoma de desalinhamento é uma componente axial de grande amplitude de vibração.

Uma folga mecânica (*looseness*) no suporte, na base ou no mancal é caracterizada por um grande número de harmônicas, e sobretudo de sub-harmônicas, no espectro dependendo do ponto e direção de análise. Outros tipos de folgas envolvem o suporte do motor como um todo, nesse caso, o efeito é simplesmente o aumento da amplitude na frequência F_w .

Uma classe de problemas considera a redução (*gear*) quando em operação. Esse componente gera um amplo espectro que compreende desde frequência abaixo de F_w até múltiplos da frequência do mecanismo de redução. Essa frequência é geralmente rodeada por outros harmônicos de menor amplitude localizados em ambos os lados. Problemas na redução como desgaste, desalinhamento e folgas causam alteração no número e na amplitude dessas harmônicas.




Figura 9. Espectro qualitativo de vibração para falhas típicas em motores

Um defeito no rolamento (*bearing*) gera a aparição de amplitudes nos espectros que dependem de parâmetros geométricos do rolamento e da velocidade de rotação. Essas frequências são relativas à frequência de operação, frequências de passagem do anel interno e externo (IBPF e OBPF), frequência de rotação das esferas e a frequência da pista. Por exemplo, um único defeito na pista do anel externo causa uma vibração impulsiva a cada vez que uma esfera passa pelo defeito.

A análise das características de vibração em motores permite a identificação de parâmetros para modelos lógicos e numéricos. Para motores elétricos de indução, o

numero de harmônicas de F_w , a amplitude das cinco primeiras, a razão de amplitude entre a segunda harmônica ($2F_w$) e a fundamental (F_w), e a soma de todas as harmônicas podem ser considerados como parâmetros para um modelo. Algumas frequências características ($0.5 F_w$, $1.5 F_w$, $2.5 F_w$, OBPF, IBPF) são consideradas como parâmetros lógicos [13].

Obviamente os valores para modelos com falhas e sem falhas devem ser estimados com base em dados de medições reais. Essa exigência é claramente evidenciada por significativas diferenças entre um espectro real sem falha e um teórico. Isso representa um problema perturbador, uma vez que a maioria das falhas são irreversíveis ou impossíveis de serem produzidas durante períodos de operação de motores elétricos.

De maneira a contornar esse problema, alguns pesquisadores têm adotado procedimentos baseados na simulação de falhas. Uma maneira é utilizar geradores de forma de ondas modificando aquisições reais de motores sem falhas. Dessa maneira é possível adicionar harmônicas nos sinais de forma a obter um espectro de um motor com falhas. O uso de um gerador de ondas permite que a falha seja induzida a qualquer instante de operação do equipamento, e assim podemos realizar testes para motores com falhas ou sem falhas.

2.6 Análise de Componentes Independentes (ICA)

A Análise de Componentes Independentes (ICA) é um dos tópicos mais relevantes da teoria moderna de processamento não supervisionado de sinais [19]. Um dos motivos para o interesse em ICA é a sua capacidade de aplicação e baixa complexidade para realização de separação cega de fontes ou BSS (Blind Source Separation).

O exemplo clássico de separação cega de fontes é conhecido como Cocktail Party Problem, que consiste na separação de n sinais de voz misturados e gravados por m microfones dispostos em diferentes pontos de uma sala. Cada sinal gravado representa a soma ponderada nos n sinais de voz associados a cada pessoa em uma sala. Podemos representar essa estrutura pelas seguintes equações lineares abaixo

$$\begin{aligned}
x_1(t) &= a_{11}s_1 + a_{12}s_2 + \dots + a_{1n}s_n \\
x_2(t) &= a_{21}s_1 + a_{22}s_2 + \dots + a_{2n}s_n \\
&\vdots \\
x_m(t) &= a_{m1}s_1 + a_{m2}s_2 + \dots + a_{mn}s_n
\end{aligned}$$

onde os parâmetros espaciais a_{ij} variam conforme as distâncias dos sensores até as fontes. A ideia de ICA surge como uma proposta de estimação de sinais originais da voz s_1, s_2, \dots, s_n por meio apenas dos sinais de mistura x_1, x_2, \dots, x_m .

A abordagem de ICA para esse tipo de problema se baseia no uso de propriedades estatísticas dos sinais das fontes para estimar os pesos a_{ij} . Para a utilização desta técnica de separação, basta que sejam válidas as hipóteses de independência e distribuição não gaussiana dos sinais s_1, s_2, \dots, s_n . Dessa forma o uso do método de ICA pode ser útil para uma série de aplicações envolvendo o processamento e análise de sinais.

2.7 Princípios da Análise de Componentes Independentes

A observação de m misturas lineares de n componentes independentes é dada por

$$x_j = a_{j1}s_1 + a_{j2}s_2 + \dots + a_{jn}s_n \quad j \in 1, 2, \dots, M$$

Para a modelagem do método de ICA, assume-se que cada mistura x_j e cada componente independente s_i seja uma variável aleatória de média zero. Quando a última proposição não for verdadeira uma alternativa imediata é a centralização forçada das variáveis aleatórias x_j em torno de zero por meio da extração do valor da média dos valores de cada amostra. Usando a notação matricial, esse modelo pode ser definido matematicamente por

$$x = As$$

onde A corresponde a matriz com os elementos de mistura a_{ij} , s o vetor de componentes independentes s_1, s_2, \dots, s_n e x o vetor de misturas. Nesta seção assumiremos que a matriz desconhecida de mistura seja quadrada, ou seja, que o número de sensores seja

igual ao número de fontes independentes, $n=m$. Uma vez estimada a matriz A , torna-se possível computar a matriz inversa, W , por meio da qual se estimam as componentes independentes tal que

$$s = Wx$$

Em [19] é apresentado em detalhes os conceitos de independência e descorrelação de sinais. Os métodos de ICA restringem à estimativa de descorrelação das componentes independentes, uma vez que isso reduz enormemente o número de parâmetro livres, simplificando a resolução do problema.

Para verificar o princípio básico de ICA, define-se a mudança de variável $y = b^T x$, onde $x = As$ e, portanto, $y = b^T As$. Pode-se obter, ainda, a variável auxiliar $w^T = b^T A$ e, sendo assim, temos $y = w^T s$. Baseado nas duas formas de representação de y , temos $b^T x = w^T s$. Tomando b^T como o vetor que maximiza a não-gaussianidade de $b^T x$, deseja-se que o correspondente vetor w^T do sistema de coordenadas transformado seja, necessariamente, um vetor com apenas um único elemento não-nulo. Isso implica $b^T x = w^T s$ resultando em apenas um componente independente. A otimização de uma superfície de não gaussianidade no espaço de n dimensões do vetor w apresentará $2n$ máximos locais, dois para cada componente independente, correspondente aos sinais s_i e $-s_i$. Para encontrar todos os sinais independentes, portanto, é preciso encontrar todos esses máximos locais.

Para que seja possível a abordagem do problema de separação de fontes baseada em algum critério de não-gaussianidade é preciso estabelecer uma medida quantitativa da gaussianidade propriamente dita. Algumas funções utilizadas com esse propósito são descritas em [19]. No presente trabalho será utilizada a função negentropia como uma medida de gaussianidade.

2.8 ICA em Problemas Subdimensionados – Análise de Componentes Esparsos

A estimação do número de fontes de um sistema motor com base nos perfis de sinais de vibração mecânica é um cenário onde o número de fontes é maior do que o número de sensores presentes em cada eixo. Assim temos os sinais das misturas

subparametrizadas e, portanto, num primeiro momento não seria possível resolver o problema de separação apenas pela hipótese de independência dos sinais da fonte.

Uma possibilidade para solucionar esse tipo de problema seria considerar a hipótese de que os sinais envolvidos apresentem, além da independência, certo grau de esparsidade [21]. Esse perfil esparso poderia ocorrer tanto no domínio do tempo quanto para qualquer outro domínio que seja resultado de uma transformação linear, como o domínio da frequência. Desta maneira garante-se também a preservação da característica de independência dos sinais. Neste trabalho será usada a abordagem mais comum para obtenção de uma representação esparsa. Trata-se da transformada STFT (Short-Time Fourier Transform).

Na hipótese de que o número de fontes em cada eixo seja maior que 1 tem-se que o número de subespaços gerados pelas misturas é menor que o número de subespaços gerados pelas fontes. Trata-se, portanto, de um problema subparametrizado. O fato de serem sinais esparsos indica que os dados observados estarão concentrados em torno de certo número k de subespaços.

A ideia central deste método é encontrar os k subespaços de maior concentração utilizando-os, posteriormente, para estimar o número e determinar as direções dos vetores coluna da matriz de mistura. A partir da hipótese de esparsidade, pode-se arbitrar que o número de fontes ativas num mesmo instante de tempo t seja limitado a 1. Neste caso específico, temos 3 misturas e N fontes a serem estimadas. A matriz de mistura é dada por

$$\begin{pmatrix} a_{1,1} & a_{1,2} & \dots & a_{1,n} \\ a_{2,1} & a_{2,2} & \dots & a_{2,n} \\ a_{3,1} & a_{3,2} & \dots & a_{3,n} \end{pmatrix}$$

Os sinais da mistura, no domínio da frequência são definidos de tal modo que

$$\begin{cases} X_1(t, f) = \sum_{i=1}^N a_{1i} S_i(t, f) \\ X_2(t, f) = \sum_{i=1}^N a_{2i} S_i(t, f) \\ X_3(t, f) = \sum_{i=1}^N a_{3i} S_i(t, f) \end{cases}$$

É possível criar, portanto, razões r_k para cada par $X_i(t, f)$, $X_j(t, f)$ de forma que

$$\begin{aligned} r_1 &= \frac{X_1(t, f)}{X_2(t, f)} = \frac{a_{1,1}S_1 + a_{1,2}S_2 + \dots + a_{1,n}S_n}{a_{2,1}S_1 + a_{2,2}S_2 + \dots + a_{2,N}S_N} \\ r_2 &= \frac{X_1(t, f)}{X_3(t, f)} = \frac{a_{1,1}S_1 + a_{1,2}S_2 + \dots + a_{1,n}S_n}{a_{3,1}S_1 + a_{3,2}S_2 + \dots + a_{3,N}S_N} \\ r_3 &= \frac{X_2(t, f)}{X_3(t, f)} = \frac{a_{2,1}S_1 + a_{2,2}S_2 + \dots + a_{2,n}S_n}{a_{3,1}S_1 + a_{3,2}S_2 + \dots + a_{3,N}S_N} \end{aligned}$$

Assumindo que para cada instante t apenas uma fonte estará ativa, cada razão r_k entre os coeficientes das colunas da matriz de mistura indicará N_k ângulos distintos.

Com os dados de r_k , a proposta de estimação do número de fontes consiste na clusterização aplicada aos valores de cada razão k . Deste modo, pode-se obter o número de fontes a partir do número ótimo de clusters obtidos.

O algoritmo de clusterização utilizado neste trabalho foi o *k-means*. Este método assume que o valor do número de clusters k é conhecido. No entanto, se este valor não estiver determinado, é possível utilizar como critério a evolução da função custo J_k , associada a soma das distâncias de cada ponto de um cluster a seus respectivos centros. Parte-se da premissa de que J_k apresentará uma variação pequena quando o número proposto de clusters for maior do que o necessário. Em outras palavras, nestas condições o acréscimo de um cluster no algoritmo não trará um decréscimo significativo na função custo.

A solução adotada para determinar o último acréscimo significativo de clusters do ponto de vista da função custo é dada pelas equações abaixo [21], onde cada uma, ou a combinação delas, pode ser mais adequada a cada tipo de problema:

$$I_{Normal}(K) = \frac{J_{k+1} - J_k}{J_k - J_{k-1}}$$

$$I_{Log}(K) = \frac{\log(J_{k+1}) - \log(J_k)}{\log(J_{k+2}) - \log(J_{k+1})}$$

$$I_{Sum}(K) = I_{Normal}(K) + I_{Log}(K)$$

E o número estimado de fontes é dado pelo índice i para o qual o valor em cada $I_u =$ ($u \in \{Normal, Log, Sum\}$) é máximo, ou seja,

$$i_{max} = \arg \max_{i \in \{1, \dots, K_{max}\}} \{I_u(i)\}$$

Capítulo 3

Procedimento Experimental

A análise de vibração em um motor consiste na aquisição de dados de aceleração do motor e no seu posterior processamento para análise espectral. Sendo o objetivo do projeto o desenvolvimento de um analisador de vibração, é necessário fazer a aquisição dos dados de aceleração do motor e sua comunicação com um computador para posterior análise.

Como interface de comunicação entre acelerômetro e computador, utilizaremos um micro controlador baseado na placa Arduino Uno R3, escolhido justamente pela facilidade e rapidez para obtenção das acelerações. Equipado com o microcontrolador ATmega328 de 16 MHz de velocidade de clock, ele possui 6 entradas analógicas e baixo consumo. Demais características podem ser obtidas da tabela abaixo.

Tabela 2. Resumo dos principais recursos do Arduino Uno R3

Microcontroller	ATmega328
Operating Voltage	5V
Input Voltage (recomm.)	7-12V
Input Voltage (limits)	6-20V
Digital I/O Pins	14 (6 provide PWM output)
Analog Input Pins	6
DC Current per I/O Pin	40 mA
DC Current for 3.3V Pin	50 mA
Flash Memory	32 KB - 0.5 KB used by bootloader
SRAM	2 KB
EEPROM	1 KB
Clock Speed	16 MHz

Como a ideia do projeto é desenvolver um sistema de monitoramento contínuo da saúde do motor e para que as medições de acelerações possam ser efetuadas em todos os eixos do motor necessitamos de um acelerômetro tri-axial. O sensor de aceleração da Freescale MMA7361 foi escolhido por haver uma precisão suficiente à aplicação requerida, baixo custo e grande utilização por desenvolvedores. Abaixo, segue tabela com características principais do componente.

Tabela 3. Resumo dos principais recursos do MMA7361

Dimensions	3mm x 5mm x 1mm
Maximum Acceleration	$\pm 5000g$
Operating Voltage	2.2V – 3.6V (linear response)
Supply Voltage	-0.3V – 3.6V
Current Consumption	400 μA
Current Consump. (Sleep)	3 μA
Selectable Sensitivity	$\pm 1.5g, \pm 6g$
Sensitivity	800 mV/g (@ 1.5g) / 206 mV/g (@ 6g)
Turn on Time	0.5 ms
Sampling Frequency	11 kHz

O código inserido no Arduino para a aquisição dos sinais inclui primeiramente uma calibração, onde é definido um referencial sem a presença de movimentação. Em seguida, de modo a garantir que a leitura seja sempre feita no tempo desejado, foi criada uma rotina de interrupção de acordo com o timer1 do Arduino, chamada de acordo com um período pré-determinado, representando a frequência de aquisição do sinal.

Utilizando as três portas analógicas para recebimento dos três sinais de acelerações do MMA7361, e configurando o Arduino para enviar os dados pela serial do computador, podemos obter os valores de acelerações instantâneos nos três eixos. O software Matlab é utilizado para realizar a leitura dos dados enviados via porta serial bem como para a análise espectral.

Para a coleta de dados, foi determinado um intervalo de tempo variável em segundos de captação do sinal, a uma taxa de 2.75 microssegundos. Essa configuração permite a obtenção de um intervalo de 0 Hz a aproximadamente 180 Hz na frequência. Considerando uma rotação nominal de um motor sendo próximo à 1800 RPM, temos a harmônica principal próximo aos 30 Hz, sendo assim suficiente para detectar harmônicos submúltiplos dessa frequência (60, 90, 120 Hz...) e em um intervalo superior de análise suficiente.

Os dados são representados em 10 bits, ou seja, de 0 a 1023 em decimal. Dessa forma podemos calcular a aceleração instantânea quando a sensibilidade é de 800 mV ($\pm 1.5g$) pela relação, onde a *Acel* indica a aceleração instantânea e *Leitura* é o dado do sensor (em decimal):

$$Acel = \left[3,3 * \left(\frac{Leitura}{1024} - 0,5 \right) \right] / 800 \text{ mV/g} \quad (\text{m/s}^2)$$




Figura 10. Motor de indução com rotor de gaiola de esquilo

Foram realizadas as aquisições das acelerações em diversos motores de indução trifásicos WEG com rotor de gaiola, como da figura acima, em plena carga e em regime permanente. O acoplamento do sensor ao motor foi feito magneticamente, sempre

respeitando a posição dos sensores para que os valores das devidas acelerações fossem captados nas direções corretas.

O procedimento para a realização da medição das acelerações foi seguido de maneira metódica. Inicialmente foi feita a calibração do sensor em um local plano e com a ausência de vibrações. Em seguida o acelerômetro foi posicionado de forma que o eixo x meça a aceleração no sentido do eixo do rotor (axial), o eixo z meça a aceleração na vertical (direção da aceleração gravitacional) e o eixo y na direção horizontal (radial), completando o sistema de coordenadas. Na maioria das aquisições, a primeira componente da frequência pôde ser desprezada devido às variações de baixa frequência inerentes ao ensaio.

Abaixo estão as imagens das instalações dos motores utilizados para a realização da aquisição de dados para a realização da análise de vibração. Na tabela a seguir estão as especificações básicas de cada motor de indução de gaiola de esquilo conforme fabricante WEG.

Tabela 4. Especificações dos motores utilizados

Motor	Potência (HP)	RPM nominal	Peso (kg)
1	25.0	1760	125
2	7.5	3500	43
3	5.0	1735	35
4	7.5	3500	43

Para a estimação do número de fontes e separação dos sinais pelo método de ICA utilizaremos como base os algoritmos desenvolvidos em [19]. Para a validação do algoritmo de estimação de fontes foram efetuadas simulações onde o número de fontes já era conhecido a priori. A mistura de sinais de áudio para o caso de 3, 4, 5 e 6 fontes independentes foi realizada e validada com a função custo, estimando a distância euclidiana em cada agrupamento de cluster. A função custo decai significativamente até um valor $K_{ótimo}$, reduzindo seu decréscimo a uma taxa bem mais lenta após este valor.

Verificada a solução para um caso conhecido, iniciou-se então o experimento com dados de solução desconhecida, provenientes dos sinais adquiridos pelos acelerômetros dos motores. A estratégia de estimação do número de fontes foi aplicada apenas para a situação de funcionamento nominal do motor. As aquisições dos sinais de vibração para as falhas usualmente relatadas na literatura ainda não foram testadas.




Figura 11. Local de instalação dos motores utilizados

Em [19], simulações para rotações em velocidades nominais de motores sem falhas indicaram a convergência de número de fontes para cada perfil de vibração $r_1 = 6$, $r_2 = 2$ e $r_3 = 3$ fontes. A porcentagem de convergência ficou próxima de 70% para as simulações realizadas.

Espera-se encontrar perfis de sinais com diferentes números de fontes para cada perfil de vibração encontrado. Para o caso de desalinhamento de carga, espera-se encontrar um range do número de fontes (essa variação pode ocorrer conforme o “grau de desalinhamento” na configuração do sistema testado).

Capítulo 4

Resultados e Discussões

Conforme a literatura orienta, o janelamento é uma técnica essencial para a correta interpretação dos dados no domínio da frequência. Foram simulados diversos tipos de janelas para os sinais das acelerações desse trabalho, os resultados foram comparados na figura abaixo em termos da densidade espectral de potência (DSP).




Figura 12. Comparação entre janelas para o motor 2

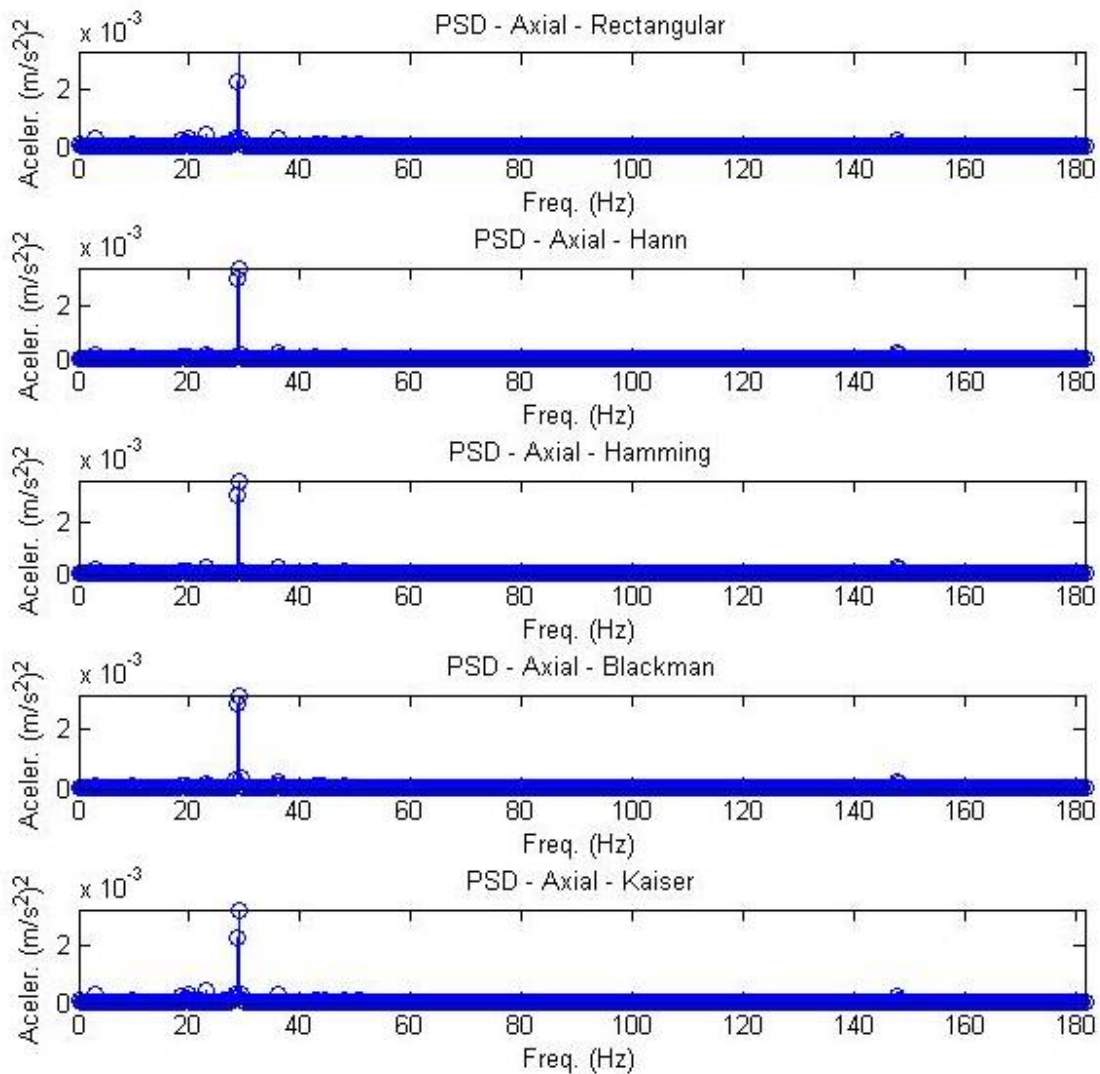


Figura 13. Comparação entre janelas para o motor 3

Tanto a comparação para o motor 2 ou para o motor 3 no eixo axial tanto quanto para os outros canais do acelerômetro vemos resultados muito parecidos do espectro para todos os tipos de janelas. Entretanto para maior precisão em amplitude, menor ruído e menor leakage espectral, as janelas de Hamming e Kaiser são as que proporcionam melhor desempenho para essa aplicação.

Outra forma de verificar o desempenho do processamento do sinal é analisar a quantidade de pontos utilizada na DFT. Esse parâmetro pode ser ajustado de forma obter o espectro mais contínuo possível, porém ao custo de um processamento computacional maior. Na figura abaixo variamos a quantidade de pontos da DFT e vemos a diferença na resolução entre os casos extremos. É interessante notar que dependendo da precisão da

análise, o aumento do número de pontos não influencia fortemente na precisão em amplitude do sinal, e assim o um valor intermediário ótimo é o mais plausível de ser utilizado.

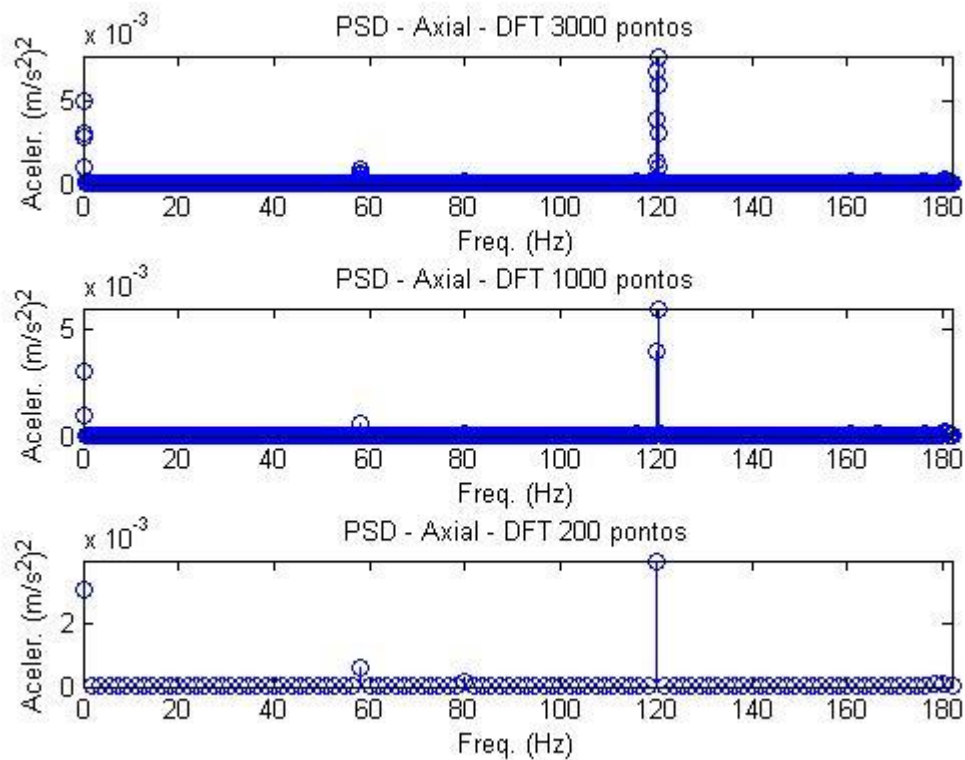


Figura 14. Influência do número de pontos da DFT no espectro

A quantidade de pontos utilizada na janela é muito importante para a obtenção de um sinal sem leakage. Assim o tamanho da janela deve ser escolhido de forma a garantir o menor vazamento possível. Ao diminuir o número de pontos da janela, aumentamos o leakage espectral e distorcemos o espectro de forma que a análise em amplitude e resolução fica comprometida, como na figura abaixo.

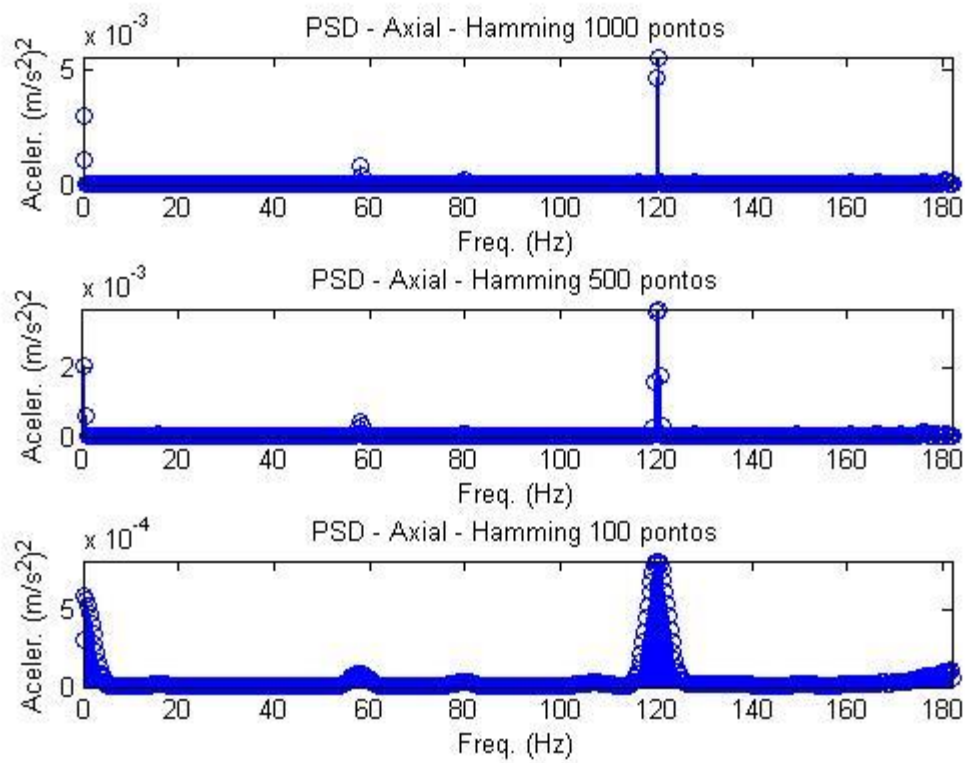


Figura 15. Efeito da diminuição do tamanho da janela no espectro

Para realizar a análise em frequência dos sinais obtidos foram feitas diversas aquisições com diferentes períodos de captação do sinal dos sensores para os motores listados. Abaixo as figuras relativas à aquisição no motor 1.




Figura 16. DFT dos sinais originais dos acelerômetros no motor 1

No sinal original obtido pela DFT constatamos a existência de uma grande quantidade de ruídos acima de 80 Hz. Mesmo com a utilização de um filtro Hamming, ainda vemos componentes com amplitudes importantes nessas frequências. Como a velocidade de rotação é de 1760 RPM, notamos a existência de um pico próximo de 30 Hz no espectro radial, porém sem múltiplos dessa frequência. A aparição da frequência de 100 Hz em todos os espectros pode ser decorrente de vibrações de fontes vinculadas mecanicamente ao motor. O espectrograma mostra frequências constantes mesmo com a variação do tempo.

Conforme nas simulações realizadas para motores sem falhas em rotação nominal no eixo yz, o número estimado de fontes segue conforme o encontrado na literatura, onde o número de fontes é igual a 3 para r_3 .




Figura 17. Perfil de clusters em gráfico semi-log para r_3 do motor 1




Figura 18. DFT dos sinais filtrados dos acelerômetros nas três dimensões




Figura 19. Sinal original da aceleração radial e respectivo espectrograma

As aquisições e dados relativos ao motor 2 são mostrados abaixo.

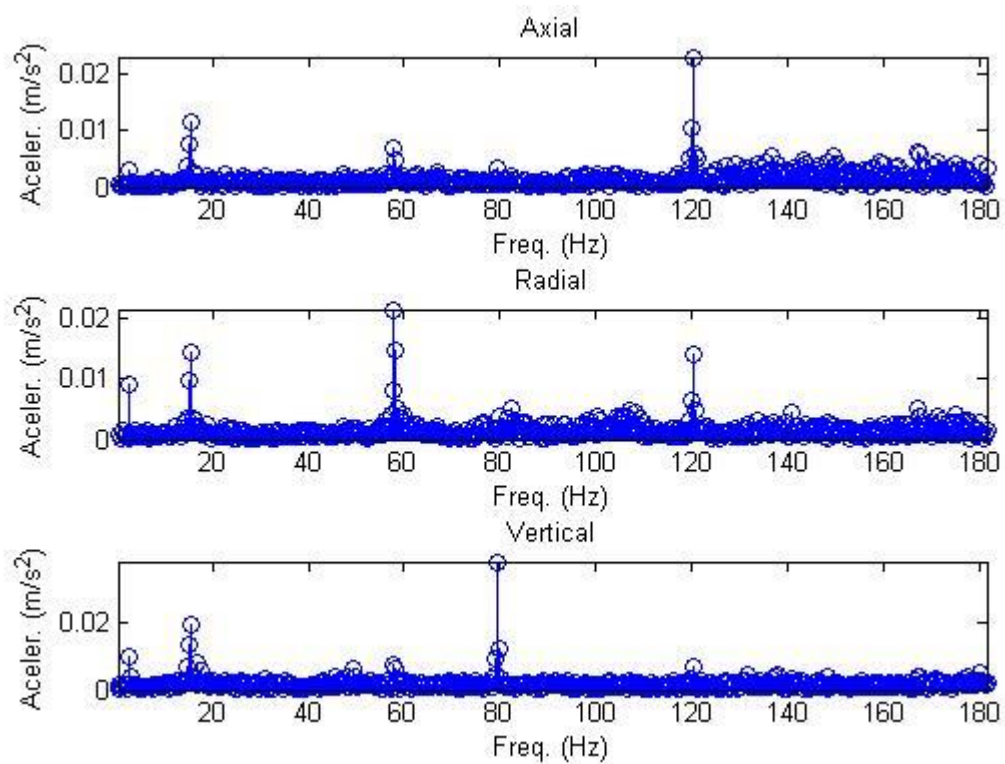


Figura 20. DFT dos sinais originais dos acelerômetros do motor 2

Analisando a DFT do sinal original vemos uma menor quantidade de ruídos se compararmos ao motor 1. Com a aplicação do filtro as amplitudes relativas aos ruídos são praticamente eliminadas, mostrando nesse caso a eficácia da utilização de filtros e janelas em processamento de sinais. Com velocidade de rotação de 3500 RPM, notamos a existência de um pico próximo a 60 Hz nos espectros, além de múltiplos dessa frequência a 120 Hz, tanto axial quanto radial. Isso pode indicar a existência de um sensível desalinhamento no motor, pois mesmo sendo baixas as amplitudes, o espectro encaixa-se no padrão desse tipo de falha. O espectrograma radial segue o mesmo padrão de não haver variação na frequência conforme o tempo.

Baseado nas simulações realizadas para motores sem falhas em rotação nominal no eixo xy , o número estimado de fontes deve ser ligeiramente maior no motor 2 considerando os traços de desalinhamento na DFT. A simulação indicou um número de fontes igual ou maior a 7 para a relação de vibração radial r_1 , em 70% das simulações.

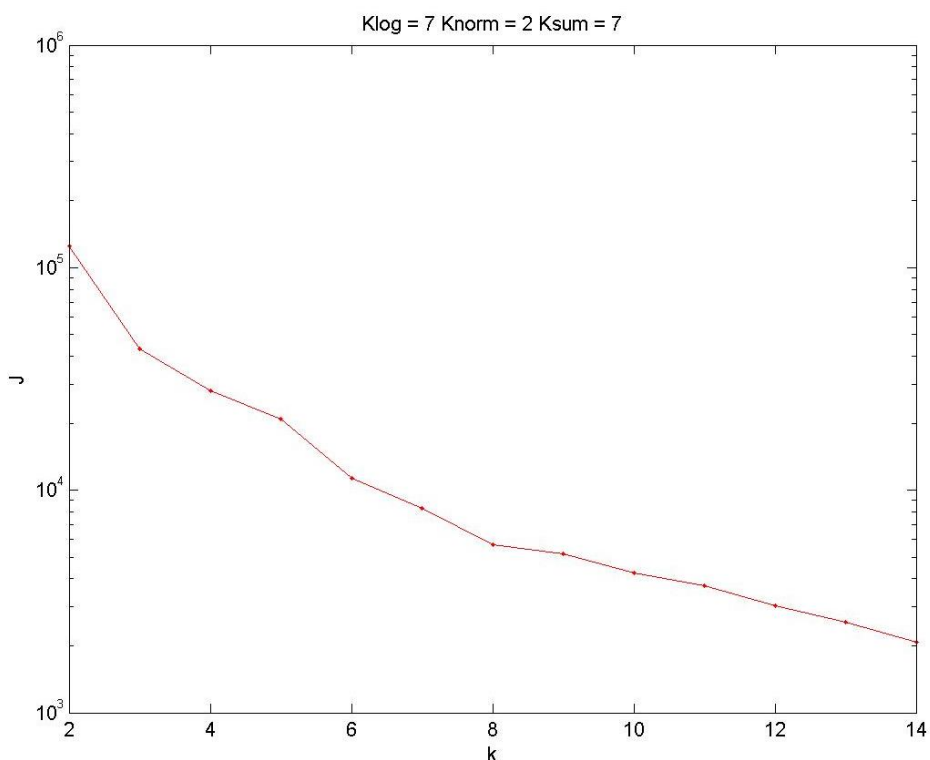


Figura 21. Perfil de clusters em gráfico semi-log para r_1 do motor 2




Figura 22. DFT dos sinais filtrados dos acelerômetros nas três dimensões




Figura 23. Sinal original da aceleração radial e respectivo espectrograma

As aquisições e dados relativos ao motor 3 são mostrados abaixo.




Figura 24. DFT dos sinais originais dos acelerômetros do motor 3

A aplicação do filtro foi essencial para a obtenção de um espectro mais limpo e para a eliminação de ruídos. Com velocidade de rotação de 1735 RPM no motor, notamos a existência de um pico próximo a 30 Hz nos espectros, porém sem múltiplos dessa frequência no sinal. É interessante notar a amplitude nos espectros obtidos, sendo menores nos motores 2 e 3 comparadas ao motor 1. A amplitude é um parâmetro determinante na detecção de falhas em motores. O espectrograma segue o mesmo padrão dos outros motores.

Nas simulações realizadas para motores sem falhas em rotação nominal no eixo yz , a literatura indica um número estimado de fontes próximo de 3. A simulação forneceu o número de fontes igual a 2 para a relação de vibração radial r_3 . Essa diferença pode estar relacionada a baixa amplitude de vibração nesse motor.




Figura 25. Perfil de clusters em gráfico semi-log para r_3 do motor 3

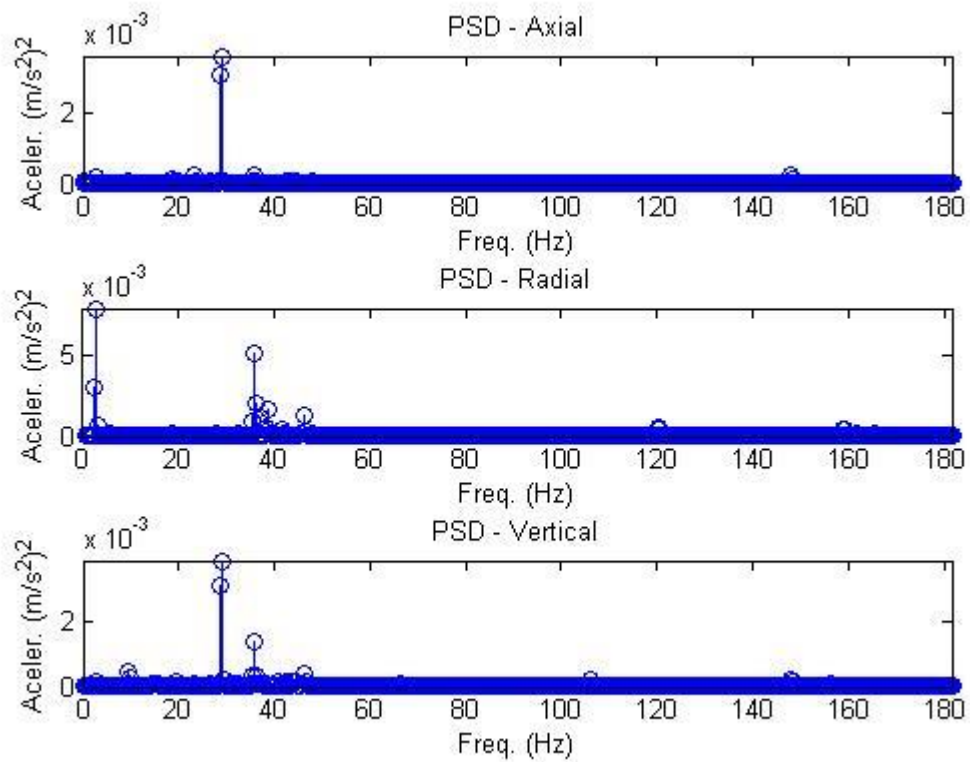


Figura 26. DFT dos sinais filtrados dos acelerômetros nas três dimensões

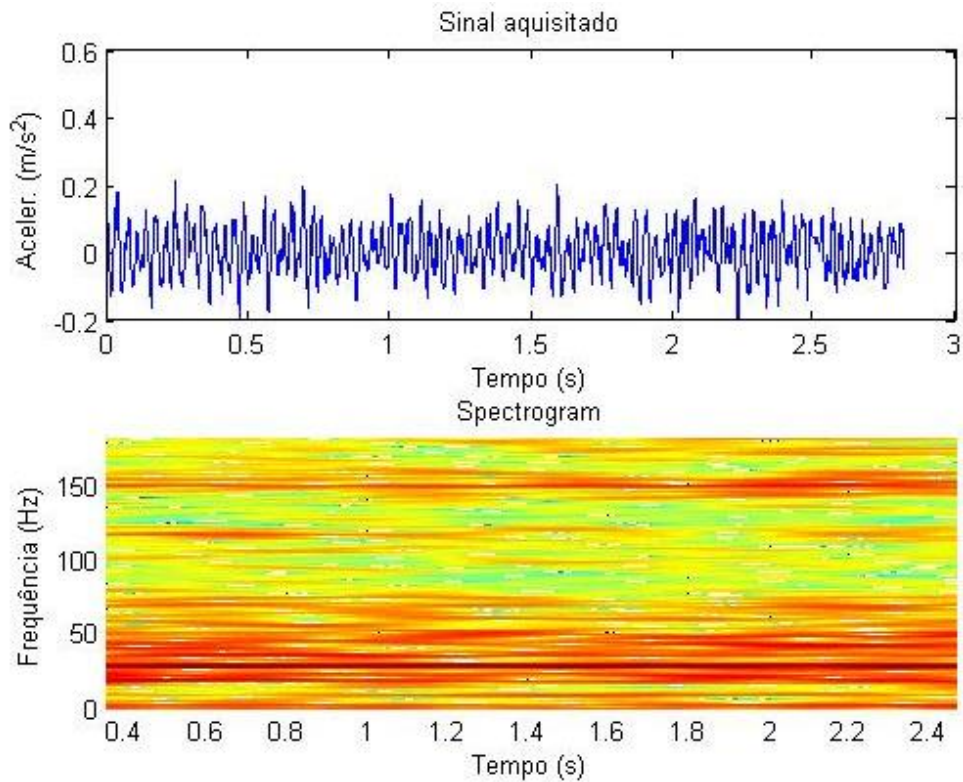


Figura 27. Sinal original da aceleração axial e respectivo espectrograma

As aquisições e dados relativos ao motor 4 são mostrados abaixo.




Figura 28. DFT dos sinais originais dos acelerômetros do motor 4

De forma geral, a utilização do filtro Hamming para essa aplicação gera resultados satisfatórios para a eliminação de ruídos. Tendo as mesmas especificações do motor 2, notamos a existência de um pico próximo a 60 Hz nos espectros, porém nesse caso com submúltiplos dessa frequência no espectro. Ao compararmos as amplitudes das acelerações nos motores 2 e 4, vemos que esse ultimo apresenta amplitudes maiores, e a aparição de submúltiplos da frequência principal ainda que de baixa amplitude pode indicar pequena folga mecânica no motor. O espectrograma segue o mesmo padrão dos outros motores.

Em simulações realizadas para motores sem falhas em rotação nominal no eixo xy, a literatura indica um número estimado de fontes próximo a 2, ou seja, o mesmo número de fontes para a relação de vibração radial r_2 no motor 4.




Figura 29. Perfil de clusters em gráfico semi-log para r_2 do motor 4

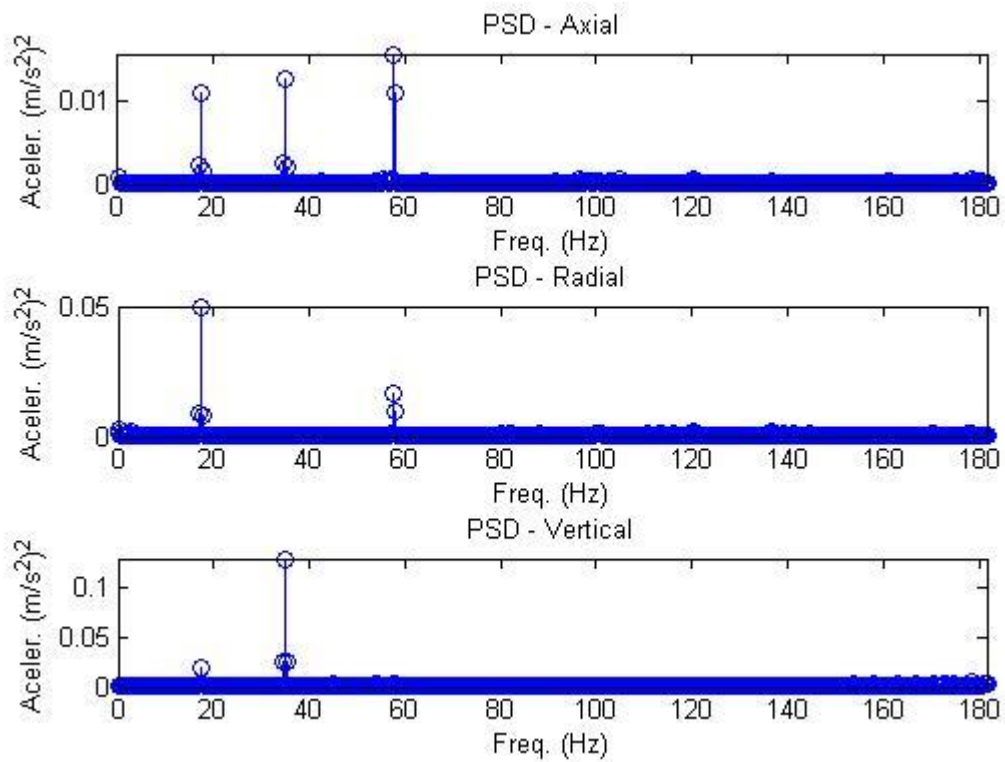


Figura 30. DFT dos sinais filtrados dos acelerômetros nas três dimensões




Figura 31. Sinal original da aceleração axial e respectivo espectrograma

Podemos destacar que os resultados concentraram-se na análise dos sinais obtidos, bem como na própria aquisição do sinal. Nesse sentido foi priorizada a obtenção de um sinal em que o posterior processamento seja favorável para a detecção de falhas. Nesse contexto a obtenção de um espectro em frequência fiel as vibrações que ocorrem em um sistema real é extremamente importante. Por isso baixo nível de ruídos, alta resolução em frequência e amplitude são parâmetros chave do projeto.

Para a aquisição das acelerações reais devemos desenvolver o projeto procurando o melhor compromisso entre menor leakage espectral, ausência de aliasing, menor nível de ruídos, melhor resolução na frequência, maior precisão na amplitude e menor esforço computacional de processamento. Como a obtenção de todos esses parâmetros é conflitante, a escolha de valores ótimos é uma saída para esse problema.

É possível notar a existência de uma componente localizada em baixa frequência nos espectros, bem como muitas vezes frequências entre as harmônicas principais e ainda outras em altas frequências. De forma geral, o acoplamento do motor com outros mecanismos gera a aparição de diferentes frequências no sinal, basicamente causado por vibrações no solo, reduções, mancais, cargas e interferências eletromagnéticas no acelerômetro.

Considerando todas essas interferências externas, notamos a aparição da frequência de rotação do motor em todos os espectros, mostrando coerência com a prática. Além disso, o nível de ruído encontrado não influenciou na análise dos espectros, garantido basicamente pelo filtro passa-baixa interno ao acelerômetro. De acordo com os espectrogramas encontrados, as frequências nos sinais permanecem constantes conforme o tempo.

A detecção de falhas foi baseada no número de fontes estimadas pelo algoritmo de ICA baseado em um motor elétrico de bancada experimental, isolado de vibrações externas e em rotação nominal. Essa estratégia foi adotada uma vez que ao analisar o sinal de um motor em plena carga em produção, notamos diversas componentes adicionais provenientes de múltiplas fontes conectadas ao conjunto mecânico.

Esse fato aumenta a complexidade do problema, pois não é evidente enunciar a natureza das componentes de frequência relacionadas exclusivamente ao motor. Baseando-se na estimativa do número de fontes de um motor de bancada experimental isolado, podemos comparar a quantidade de componentes provenientes dos algoritmos de estimação de fontes em um motor em produção, e constatar um maior número de fontes para a maioria dos casos, principalmente onde há um indício de falha.

Capítulo 5

Conclusões

O objetivo inicial do trabalho foi desenvolver um dispositivo para captação de vibrações em motores elétricos de indução. Em seguida, projetar filtros e janelas em Matlab para a obtenção de um espectro conciso e passível de análise. Resultados coerentes foram encontrados inclusive permitindo o início da análise em frequência dos espectros dos motores e encontrando relações com o padrão de possíveis falhas.

A análise de componentes independentes possibilitou a comparação do número de fontes estimadas entre diferentes aplicações em diversos motores reais. A quantidade de fontes em motores industriais mostra a presença de componentes adicionais se comparadas a motores em bancadas experimentais. Esse resultado, mesmo sem precisar a natureza da falha, oferece um respaldo para detecção em frequência via algoritmo de reconhecimento de padrões de falhas para outros trabalhos.

Para a consolidação do método de ICA para detecção de falhas em motores elétricos, tal algoritmo deve experimentar uma quantidade vasta de experimentos em motores reais com e sem falhas para a validação da detecção não só de falha, como também de sua respectiva natureza.

Referências Bibliográficas

- [1] Contreras-Medina, L. M., Romero-Troncoso, R. J., Cabal-Yepez, E., Rangel-Magdaleno, J. J., Millan-Almaraz, J. R. *FPGA-Based Multiple-Channel Vibration Analyzer for Industrial Applications in Inductino Motor Failure Detection*. IEEE Trans. Instrum. Meas., 2010, vol. 59, no. 1.
- [2] Garcia-Ramirez, A. G., Osornio-Rios, R. A., Granados-Lieberman, D., Garcia-Perez, A., Romero-Troncoso, R. J. *Smart Sensor for Online Detection of Multiple-Combined Faults in VSD-Fed Induction Motors*. Sensors 2012, 12, 11989-12005.
- [3] Bellini, A., Filipetti, F., Tassoni, C., Capolino, G. A. *Advances in Diagnostic Techniques for Induction Machines*. IEEE Trans. Ind. Electron., 2008, 55, 4109-4126.
- [4] Tallam, R. M., Lee, S. B., Stone, G. C., Kliman, G. B., Yoo, J., Habetler, T. G., Harley, R. G. *A Survey Methods for Detection of Stator Related Faults in Induction Machines*. IEEE Trans. Ind. Appl., 2007, 43, 920-933.
- [5] Nandi, S., Toliyat, H. A., Li, X. *Condition Monitoring and Fault Diagnosis of Electrical Motors – A Review*. IEEE Trans. Energy Convers., 2005, 20, 719-729.
- [6] Cusido, J., Romeral, L., Ortega, J. A., Garcia, A., Riba, J. *Signal Injection as a Fault Detection Technique*. Sensors 2011, 11, 3356-3380.
- [7] Ilonen, J., Kamarainen, J., Lindh, T., Ahola, T., Kalvianen, H., Partanen, J. *Diagnosis Tool for Motor Condition Monitoring*. IEEE Trans. Instrum. Meas., 2005, vol. 47, no. 4, 963-971.
- [8] Ansari, S. A., Baig, R. *A PC-baised Vibration Analyser for Condition Monitoring of Process Machinery*. IEEE Trans. Intrum. Meas., 1998, vol. 47, no. 2, 378-383.
- [9] Betta, G., D'Apuzzo, M., Ligouri, C., Pietrosanto, A. *An Intelligent FFT-Analyser*. IEEE Trans. Instrum. Meas., 2001, vol. 50, no. 3, 825-832.
- [10] Vite-Frias, J. A., Romero-Troncoso, R. J., Ordaz-Moreno, A. *VHDL Core for 1024-point Radix-4 FFT Computation*. Proc. Int. Conf. ReCon-Fig, 2005, Puebla, Mexico, p. 24.
- [11] Ayhan, B., Chow, M., Song, M. *Multiple Signature Processing-based Fault Detection Schemes for Broken Rotor Bar in Induction Motors*. IEEE Trans. Energy Convers., 2005, vol. 20, no. 2, 336-343.
- [12] Benbouzid, M. E. H. *A Review of Induction Motors Signature Analysis as Medium for Faults Detection*. IEEE Trans. Ind. Electron., 2000, vol. 47, no. 5, 984-992.

- [13] Betta, G., Ligouri, C., Paolillo, A., Pietrosanto, A. *A DSP-based FFT Analyzer for the Fault Diagnosis of Rotation Machine Based on Vibration Analysis*. IEEE Trans. Instrum. Meas., 2002, vol. 51, no. 6, 1316-1322.
- [14] Rangel-Magdaleno, J. J., Romero-Troncoso, R. J., Contreras-Medina, L. M., Garcia-Perez, A. *FPGA Implementation of a Novel Algorithm for On-line Bar Breakage Detection on Induction Motors*. Proc. IMTC, 2008, Canada, 720-725.
- [15] LDS-Group, *Understanding FFT Windows*. Application Note ANO14, <http://www.physik.uni-wuerzburg.de/~praktiku/Anleitung/Fremde/ANO14.pdf>.
- [16] Mitchell, J. S., *Introduction to Machinery Analysis and Monitoring*, 2nd ed. Tulsa, OK, Pennwell, 1993.
- [17] Munoz, R. A., Nahmias, C. G., *Mechanical vibration of three-phase induction motors fed by nonsinusoidal currents*, Proc. Int. Power Electrocn. Congr., 1994, 166-172.
- [18] Yunusa-Kaltungo, A., Sinha, J. K., *Vibration Monitoring: A Case Study*, Maintenance & Asset Management, 2014, vol. 29, no. 1, 43-48.
- [19] Olivatto, V. B., *Análise de Componentes Esparsos para Sinais de Vibração Mecânica*, Faculdade de Engenharia Elétrica e Computação, Unicamp, (2014).
- [20] Attus Romis, R. F., Von Zuben, F. J., *Tópico 10 – Análise de componentes independentes (ICA)*, 26 Fev 2010, 30 p, Notas de Aula.
- [21] Nadalin, E. Z., *Contribuições ao problema de separação cega de fontes, com ênfase no estudo de sinais esparsos*, Tese de Doutorado, Faculdade de Engenharia Elétrica e de Computação, Unicamp, 2011.