

PROPOSTA E IMPLEMENTAÇÃO DE UM SISTEMA NÃO-INVASIVO UTILIZANDO SINAIS SONOROS PARA DETECÇÃO DE FALHAS EM MOTORES DE INDUÇÃO TRIFÁSICO

HERMAN LUCAS DOS SANTOS*, WAGNER ENDO*, PAULO ROGÉRIO SCALASSARA*, ALESSANDRO GOEDEL*

** Universidade Tecnológica Federal do Paraná
Campus Cornélio Procópio
Cornélio Procópio, Paraná, Brasil*

Emails: herman@alunos.utfpr.edu.br, wendo@utfpr.edu.br, prscalassara@utfpr.edu.br, agoedel@utfpr.edu.br

Abstract— Electric machines has been target of many techniques for fault detection and prognostics research. Although it has been widely consolidated, many methods rely on sensors that, to be installed, it's needed to stop the motor function, which implies in losses for the production in industrial scenary. Another option is the instalation of theses sensors right when the machine is sized and installed, which demands planning. In this work, is presented a research about the setup for cosntructing a non-invasve system to be implemented for diagnosis and prognostic of faults in electric machines based on acoustic signals recorded by a microphone. The results presented here shows the differences in frequency spectra from health motor, electrical unbalance, two broken rotor bar and outer race corrosion bearing. The authors concludes that is possible to diagnose electric motors fault using sound signals.

Keywords— Fault Diagnosis in Machines, Signal Processing, Electrical Unbalance, Broken Rotor Bars, Acoustic Signals, Fourier Analysis.

Resumo— Máquinas elétricas são alvos de pesquisa sobre várias técnicas quando envolve a detecção e prognóstico de falhas. Apesar de amplamente consolidados, muitos métodos dependem de sensores que necessitam parada no funcionamento do motor para que possam ser instalados, o que acarreta em prejuízos em cenários industriais. Outra opção é a instalação destes sensores assim que a máquina é dimensionada e instalada, o que exige planejamento. Neste trabalho é apresentado um estudo de *setup* para a construção de um sistema não-invasivo a ser implementado para diagnóstico e prognóstico de falhas em máquinas elétricas utilizando sinais sonoros captados por um microfone. Os resultados mostram as diferenças no espectro de frequências entre motor saudável, com desbalanço elétrico, duas barras de rotor quebrado e corrosão nas pistas externas de rolamento. Os autores concluem a possibilidade de utilização de sinais sonoros para o diagnóstico de falhas em motores elétricos.

Palavras-chave— Diagnóstico de Falhas em Motores, Processamento de Sinais, Desbalanço Elétrico, Barras de Rotor Quebradas, Sinais Acústico, Análise de Fourier.

1 Introdução

Motores de Indução Trifásicos (MIT) são um alicerce da indústria moderna (Almeida, 2006), sendo amplamente utilizado devido ao seu custo ser menor em relação à outros métodos de conversão de energia em torque. Estes motores tem uma boa eficiência, entre 85 e 97% . Estas máquinas também possuem robustez, sendo as preferidas em ambientes abrasivos.

As situações adversas em que os MIT podem se encontrar, como um ambiente industrial, sobrecarga em seu eixo ou simplesmente a deterioração em seus componentes que ocorrem com o tempo, fazem com que hajam falhas em seu funcionamento. Esta condição faz com que o motor opere de forma irregular, comprometendo sua eficiência.

O diagnóstico de falhas pode ser feito de diversas formas. Através dos sinais emitidos pelos motores aplicam-se técnicas de análise de sinais e inteligências artificiais que envolvem a Transformada de Fourier (McFadden and Toozhy, 2000; Mechefske and Mathew, 1992), Transformada de

Hilbert-Huang (Rai and Mohanty, 2007), Redes Neurais Artificiais (RNA) combinadas (Huang et al., 2007), RNA com Wavelets (Wang and Vachtsevanos, 2001) e Máquinas de Vetores de Suporte (SVM) (Yang et al., 2007), por exemplo.

Todas estas técnicas são dependentes de um sinal provido pela máquina. Os sinais mais encontrados na literatura são: correntes e tensões, vibração, emissão acústica e detritos de óleo, demonstrado na revisão de Lee et al. (2014). Encontram-se também sistemas que utilizam-se de mais de um tipo de sinal emitido (Esfahani et al., 2014).

Neste trabalho é apresentada a proposta de um *setup* experimental para aquisição de dados sonoros a fim de avaliar a condição de um motor, generalizar e classificar possíveis falhas. Serão utilizados os sinais acústicos das máquinas captados através de microfones e análise para detecção de falhas.

Na Seção 2 são conceituados os princípios de aquisição de sinais e das técnicas a serem empregadas. A Seção 3 apresentada os materiais e métodos a serem utilizados na bancada para realização

dos ensaios. Os resultados obtidos na captação e processamento dos dados experimentais são mostrados na Seção 4. Por fim, a Seção 5 traz os comentários dos autores acerca dos resultados.

2 Estudo de técnicas de aquisição e processamento dos sinais de falha em MIT

A aquisição de dados deve obedecer algumas regras para que não haja ambiguidades nos sinais nem mascaramento de frequências de interesse. Nesta seção serão introduzidas as bases teóricas acerca de aquisição e análise de sinais. Duas técnicas são conceituadas: Transformada de Fourier e Autocorrelação. Com estas técnicas pretende-se analisar as diferenças entre os sinais no tempo e frequência.

2.1 Aquisição e processamento dos sinais

Uma aplicação de aquisição digital de dados é constituído pelo sistema a ser estudado e os seguintes componentes; (a) um sensor, que irá transformar a grandeza medida em um sinal de tensão, (b) uma unidade de aquisição, que compõe-se de um conversor analógico-digital (A/D), que fará a conversão do sinal de tensão para um sinal digital, e de unidades de condicionamentos primários do sinal e (c) a unidade de processamento, que pode ser um computador, microcontrolador, ou qualquer unidade passível de processamento de sinais digitais.

Os sinais acústicos emitidos pelas máquinas a serem estudadas possuem duas grandezas primordiais: amplitude e frequência. A princípio, a amplitude será dependente da distância entre o microfone (sensor) e a fonte de sinal e sua potência de emissão. A frequência é a velocidade com que as ondas sonoras se propagam pelo meio, dada de acordo com as características de construção dos materiais, velocidade de rotação do motor e condições físicas e elétricas do mesmo.

A amplitude é o próprio nível AC do sinal, que é lido no microfone no domínio do tempo e ajustado por meio de um ganho na unidade de aquisição, a fim de evitar saturação e, consequentemente, uma distorção no sinal. A frequência é onde está a maior parte de interesse, que deve obedecer ao critério de Nyquist (Proakis and Manolakis, 1996), Eq (1).

$$f_s \geq 2B \quad (1)$$

onde f_s é a frequência de amostragem do sinal e B é a maior frequência de interesse encontrada.

Sabe-se que, no espectro audível, encontra-se frequências 20 a 20 kHz. Portanto, esta será a frequência de interesse para aplicar no teorema de Nyquist. Logo, a frequência de aquisição deve maior que 40 kHz. Para análise das componentes

do sinal, o espectro de frequência é obtido por meio da Transformada Rápida de Fourier (FFT).

2.1.1 Transformada Rápida de Fourier

A FFT é um algoritmo para a computação da Transformada de Fourier (FT), Eq (2), para sinais discretizados. Este algoritmo retorna as componentes de frequência do sinal analisado (Manolakis et al., 2005). Mais informações sobre a FT pode ser encontrada na referência citada.

$$X_c(F) = \int_{-\infty}^{\infty} x_c(t)e^{-j2\pi Ft} dt \quad (2)$$

Utilizando a FFT tem-se uma otimização do processo de cálculo aplicado à sinais discretizados, particionando o sinal em transformadas discretas menores. A Figura 1 ilustra uma FFT de 8 pontos feita em 3 estágios.




Figura 1: Exemplo de Transformada de Fourier em 3 estágios. A saída terá n estágios para um sinal de 2^n pontos.

Multiplica-se os pontos de forma a extrair as componentes de frequência do sinal. A complexidade computacional aumenta conforme o número de pontos presentes e recomenda-se utilização de pontos na ordem de 2^n .

Este é a base do algoritmo implementado nos softwares que fazem análise de sinais. Para o trabalho proposto será utilizado pós-processamento em MATLAB, que implementa uma versão própria da FFT.

2.1.2 Autocorrelação

A autocorrelação de um sinal (r_x , Eq. (3)), ou a correlação cruzada do sinal consigo mesmo, representa as características temporais de um sinal. A medida da autocorrelação é importante para detecção da periodicidade do sinal e seu valor inicial, ou seja, o ponto $r_x(0)$, define a sua potência. Esta é a propriedade que será analisada, além do comportamento da função de correlação. Mais informações sobre esta função podem ser encontradas em (Manolakis et al., 2005), (Oppenheim et al., 1998) e (Proakis, 2001).




Figura 2: Padrões de captações conhecidos de microfones, sendo (a) cardioide, (b) supecardioide, (c) hipercardioide, (d) omnidirecional, (e) Figura-8 e (f) *shotgun*

$$R_{yy}(l) = \sum_{n=-\infty}^{\infty} x[n]x[n-l] \quad (3)$$

onde R_{yy} é a função de autocorrelação, l são os *lags*, atrasos, do sinal e $x[n]$ o sinal sendo analisado.

2.2 Falhas em motores elétricos

Motores elétricos podem apresentar falhas de diversas origens, como rolamentos, rotores e curto circuitos no estator. Estas falhas fazem com que os motores percam rendimento, acarretando um aumento de o custo e eficiência, prejudicando o processo que o mesmo realiza. Portanto, em âmbito industrial, é importante que os motores encontrem-se saudáveis e que suas condições sejam monitoradas para que haja agendamento das

manutenções.

Prognósticos e manutenção da saúde (PHM) tem sido utilizado para estender a vida longa de máquinas elétricas através de manutenção correta e monitoramento do estado dos componentes (Lee et al., 2014). Portanto, através da emissão acústica de um MIT busca-se classificar o estado atual da máquina utilizando as componentes de frequência.

(Delgado-Arredondo et al., 2017) comprova que falhas de rolamento, barras de rotores quebradas e desbalanço mecânico podem ser encontradas por vibração e emissão acústica. (Germen et al., 2014) adiciona a falha de curto circuito em rolamento do estator. (Campbell and Arce, 2016) conceitua a falha de desbalanço elétrico por meio da vibração do motor.

3 Proposta e implementação do *setup* experimental para aquisição e classificação dos sinais

A revisão bibliográfica viabilizou que é possível encontrar os problemas de falhas utilizando um método não-invasivo baseado apenas na propagação acústica dos motores. Estuda-se então os componentes deste sistema, desde o transdutor até o processador, assim como um produto viável. Esta seção é dividida entre os componentes que farão parte do sistema de aquisição.

3.1 Transdutor/Microfone

Em qualquer aplicação de processamento de sinais é importante que o transdutor utilizado possua a maior fidelidade possível, ou seja, com a menor sobreposição de espectro possível. Isto é uma dificuldade quando considera-se microfones, que comumente não são utilizados como sensores de som, mas em aplicações de música, onde deve-se realçar algumas frequências.

Outro ponto importante é a direção de chegada do sinal de interesse. Em aplicações multissensores os transdutores devem ser omnidirecionais (Manolakis et al., 2005). Captação direcionada dos sinais geram ambiguidades da saída quanto a inferência de localização de chegada.

Em questão mercadológica os microfones mais comuns de se encontrar são os de característica dinâmico, geralmente de captação cardioide e níveis de sensibilidade baixos, e os condensadores, estes com construção mais sensível e maior sensibilidade a nuances de áudio, que os tornam mais próximo do ideal para a aplicação em processamento de sinais.

Outra variável nos microfones é o tipo de captação. Existem cinco classificações diferentes. (a) Cardioide, (b) supercardioide, (c) hipercardioide, (d) omnidirecional, (e) Figura-8 e (f) *Shotgun*. Estas captações diferem-se entre si pelas regiões em que monitoram os sinais. A Figura 2 ilustra cada um dos padrões.

Pressupõe-se que não se conhece a falha do motor e suas características a ser analisada em primeira instância. Portanto, um microfone que rejeita sinais de acordo com o ângulo de chegada não é uma opção atraente, podendo uma pressão acústica emitida por outra parte do motor sobrepor o sinal de interesse. Portanto, escolhe-se um microfone com captação omnidirecional.

3.2 Composição da bancada de ensaios de aquisição de sinais de áudio

A bancada de ensaio é composta por um MIT com 1 CV de potência, rotação nominal em 1730 RPM composto por 4 polos. A alimentação é trifásica por rede de 220/380V - 60 Hz. Acoplado ao eixo do motor há um gerador de corrente contínua

com 2 kW de potência, alimentado por 250 V em campo e em armadura. A Figura 3 mostra como foi disposta a bancada.




Figura 3: Bancada de ensaios utilizada para captação das emissões acústicas de motores. Constam na bancada os transdutores DBX RTA e YOGA HT81, um MIT, um motor CC e a interface Focusrite SOLO.

O motor CC simular a carga no eixo do motor, podendo ser variada em diferentes valores de torque. Os microfones captam os sinais para análise, que são digitalizados pela interface de áudio e gravados no computador. O diagrama dos experimentos é dado segundo a Figura 4.




Figura 4: Diagrama do experimento proposto. O sinal acústico emitido pela máquina elétrica é captada por um microfone e então digitalizado em uma interface ligada a uma unidade de processamento. A cada experimento são gravados 30 segundos de áudio, importados em MATLAB e extraídas características (FFT e correlação cruzada). São analisados estes sinais e então feito um novo experimento, com uma nova configuração.

As configurações mencionadas na Figura 4 são as diferentes cargas a que o motor será sujeito, variando de a vazio (0,4 Nm) à sobrecarga (4,5

Nm), mudanças na configuração de alimentação, com desbalanço entre as fases e troca do rotor para um com barras quebradas. A seguir são realizados e avaliados dos dados dos testes.

4 Resultados e Discussões

Para viabilizar a aplicação do sistema proposto, são analisadas as diferenças entre os sinais de motores em três condições: com o motor saudável, alimentado na rede por 127 V (tensão nominal), com desbalanços elétricos e com duas barras de rotor quebradas.

O posicionamento dos microfones é os mesmos para as 3 situações, como na Figura 3. Os dois microfones possuem características de captação parecidas, porém com sensibilidades diferentes, o que é compensado na interface de aquisição, e construções diferentes. Para a aplicação com mais de um sensor, é necessário verificar qual melhor se adequará.

Primeiramente, é calculada a autocorrelação dos sinais. O principal retirado desta função é a energia do sinal, mensurada pela intensidade da função em seu ponto $n = 0$. O resultado obtido é exposto na Figura 5




Figura 5: Funções de autocorrelação dos sinais de motor completamente saudável, com falha elétrica e falha mecânica, respectivamente. Observa-se uma diferença abrupta na periodicidade do sinal com falha mecânica em relação aos demais, assim como sua energia.

4.1 Motor saudável

O primeiro teste é feito com o motor saudável. São gravados, simultaneamente, 30 segundos de áudio em cada microfone com o motor exposto a uma carga de 4 Nm, que é sua carga nominal. São analisados os gráficos de cada microfone para concluir qual melhor se adequa à aplicação. Escolhido o microfone, são omitidos próximos resultados o

desclassificado para a aplicação do que possui resposta inferior. A Figura 6 mostra os sinais dos microfones para o motor saudável.




Figura 6: Sinais de MIT saudável mecanicamente e alimentado pela rede sem desbalanço gravados simultaneamente. Acima, o sinal captado pelo microfone DBX RTA. Abaixo, pelo YOGA HT81.

Percebe-se que os padrões de comportamento do mesmo sinal, captado ao mesmo tempo, pelos dois transdutores distintos, são visivelmente diferentes. Analisando os mesmos sinais de forma auditiva, a diferença é sutil, sendo difícil de prever a condição por este meio. Pode-se aferir que há divergências nas respostas dos transdutores para o mesmo sinal. Portanto, uma análise em frequência, utilizando a FFT, pode ser útil. A Figura 7 mostra a FFT feita com os pontos obtidos em 30 segundos de áudio.




Figura 7: Análise em frequência dos sinais mostrados na Figura 6. A análise foi feita com 1.386.242 pontos sob frequência de amostragem em 44,1k. Para melhor visualização, o eixo das coordenadas foi truncado em 1000 Hz

Pode-se observar uma definição muito mais clara dos sinais captados no primeiro microfone., sobretudo na parte baixa, onde há mais definição

da frequência fundamental (aprox. 60 Hz). A medida que se caminha para a parte de frequências mais altas na análise, percebe-se que as harmônicas se misturam cada vez mais. Portanto, as próximas análises serão feitas com o microfone DBX RTA apenas.

4.2 Ensaio com motor em desbalanceamento elétrico

O próximo *setup* analisado foi o do mesmo motor, porém com desbalanceamentos na sua alimentação. O desbalanceamento gerado foi de 2%. A Figura 8 mostra os sinais do motor no tempo e frequência, respectivamente, captados pelo microfone DBX RTA para o motor com desbalanceamento elétrico de 2% a mais em uma das fases.




Figura 8: Gráficos de magnitude em tempo (acima) e frequência (abaixo) do motor com desbalanceamento elétrico (129,5 V) na fase A.

Campbell and Arce (2016) relata em sua experiência que desbalanceamentos elétricos geram vibrações no motor com o dobro da frequência de alimentação. Estas vibrações se propagam nas partes mecânicas no motor, gerando pressão sonora e sendo captado pelo microfone. Comparando as Figuras 7 e 8 observa-se que, nitidamente, a frequência próxima a 120 Hz é mais aparente no caso com desbalanceamento.

4.3 Ensaio com duas barras de rotor quebrado

O motor foi desmontado e o rotor saudável substituído por um com duas barras quebradas. O motor é remontado e os microfones reposicionados da mesma forma que estavam. O comportamento em tempo e frequência pode ser conferido nos gráficos da Figura 9.




Figura 9: Gráficos de magnitude em tempo (acima) e frequência (abaixo) do motor 2 com barras de rotor quebradas.

O espectro de frequência deste sinal é visivelmente diferente dos sinais de motores mecanicamente saudáveis. Não foi encontrada na literatura uma descrição que descrevesse uma diferença tão abrupta. Então é possível concluir que a condição de barras de rotor quebradas é possível de ser detectada por sinais sonoros.

5 Conclusão

O *setup* apresentado foi efetivo para trabalhos futuros envolvendo processamento de sinais acústicos de motores elétricos para diagnósticos e prognósticos de falhas. Os resultados apresentados foram considerados satisfatórios pelos autores pois demonstram que há diferenças claras em potência, na periodicidade e no espectro de frequência em cada caso de estudo, demonstrando que as condições físicas e de alimentação influem diretamente nas emissões acústicas da máquina e podem ser detectadas, confirmando a relação descrita na literatura sobre vibração com emissão acústica.

Referências

- Almeida, A. T. (2006). Energy using product (eup) directive preparatory study, lot 11: motors.
- Campbell, M. and Arce, G. (2016). Effect of motor voltage unbalance on motor vibration: Test and evaluation, *2016 Petroleum and Chemical Industry Technical Conference (PCIC)*, pp. 1–7.
- Delgado-Arredondo, P. A., Morinigo-Sotelo, D., Osornio-Rios, R. A., Avina-Cervantes, J. G., Rostro-Gonzalez, H. and de Jesus Romero-Troncoso, R. (2017). Methodology for fault detection in induction motors via sound and vibration signals, *Mechanical Systems and*

- Signal Processing* **83**(Supplement C): 568 – 589.
- Esfahani, E. T., Wang, S. and Sundararajan, V. (2014). Multisensor wireless system for eccentricity and bearing fault detection in induction motors, *IEEE/ASME Transactions on Mechatronics* **19**(3): 818–826.
- Germen, E., Basaran, M. and Fida, M. (2014). Sound based induction motor fault diagnosis using kohonen self-organizing map, *Mechanical Systems and Signal Processing* **46**(1): 45 – 58.
- Huang, R., Xi, L., Li, X., Liu, C. R., Qiu, H. and Lee, J. (2007). Residual life predictions for ball bearings based on self-organizing map and back propagation neural network methods, *Mechanical Systems and Signal Processing* **21**(1): 193 – 207.
- Lee, J., Wu, F., Zhao, W., Ghaffari, M., Liao, L. and Siegel, D. (2014). Prognostics and health management design for rotary machinery systems?reviews, methodology and applications, *Mechanical Systems and Signal Processing* **42**(1): 314 – 334.
- Manolakis, D. G., Ingle, V. K. and Kogon, S. M. (2005). *Statistical and Adaptive Signal Processing: Spectral Estimation, Signal Modeling, Adaptive Filtering and Array Processing*.
- McFadden, P. and Toozhy, M. (2000). Application of synchronous averaging to vibration monitoring of rolling element bearings, *Mechanical Systems and Signal Processing* **14**(6): 891 – 906.
- Mechefske, C. and Mathew, J. (1992). Fault detection and diagnosis in low speed rolling element bearings part i: The use of parametric spectra, *Mechanical Systems and Signal Processing* **6**(4): 297 – 307.
- Oppenheim, A. V., Schaffer, R. W. and Buck, J. R. (1998). *Discrete-time signal processing*, Vol. 2.
- Proakis, J. (2001). *Communication Systems Engineering*.
- Proakis, J. G. and Manolakis, D. G. (1996). *Digital Signal Processing: Principles, Algorithms, and Applications*, Vol. 3.
- Rai, V. and Mohanty, A. (2007). 3Bearing fault diagnosis using FFT of intrinsic mode functions in Hilbert-Huang transform, *Mechanical Systems and Signal Processing* **21**(6): 2607 – 2615.
- Wang, P. and Vachtsevanos, G. (2001). Fault prognostics using dynamic wavelet neural networks, *Artificial Intelligence for Engineering Design, Analysis and Manufacturing* **15**(4): 349–365.
- Yang, J., Zhang, Y. and Zhu, Y. (2007). Intelligent fault diagnosis of rolling element bearing based on svms and fractal dimension, *Mechanical Systems and Signal Processing* **21**(5): 2012 – 2024.