

Estudo de parâmetros acústicos na análise de falhas em máquinas elétricas

Alberto Yoshihiro Nakano, Ednei Luiz Miotto e Geovani Bresciani

Resumo— Este trabalho apresenta um estudo da detecção de falhas em máquinas elétricas no contexto de reconhecimento de padrões através de modelos de misturas gaussianas treinadas com parâmetros acústicos característicos, LPC, PLP e MFCC. A falha caracterizada neste trabalho é o rompimento de barras rotóricas em um motor de indução trifásico. Os modelos estatísticos criados com os três tipos de parâmetros apresentam bons resultados na identificação ou não de falhas, porém, modelos baseados em MFCC não apresentaram bom desempenho na identificação do tipo de falha.

Palavras-Chave— Processamento acústico, GMM, LPC, PLP, MFCC, detecção de falhas

Abstract— This work presents a fault detection study in electrical machines in pattern recognition context through Gaussian mixture models trained with LPC, PLP, and MFCC as acoustic features. The fault considered in this work is the broken rotor bars in a three-phase induction motor. Good performance in fault detection was found for any of the three acoustic features, however MFCC as acoustic feature had poor performance in identifying the type of the fault.

Keywords— Acoustic Processing, GMM, LPC, PLP, MFCC, fault detection

I. INTRODUÇÃO

Máquinas elétricas podem apresentar falhas em partes distintas da sua estrutura física devido às adversidades térmicas, ambientais e desgastes mecânicos que podem provocar interrupções ocasionando, por exemplo, perdas financeiras em processos industriais. Atualmente, o desempenho de um sistema de máquinas elétricas ao longo de sua operação pode ser monitorado por técnicas não invasivas, tais como, baseada em análise de corrente [1]–[4], em vibrações na estrutura da máquina [5], [6] e até na atividade sonora produzida pela máquina [7], [8].

Técnicas não invasivas tornaram-se ferramentas importantes para manutenção preditiva (atuação em equipamento, sistema ou local de instalação realizada com base no conhecimento da condição de funcionamento ou desempenho operacional, obtido por meio de parâmetros previamente conhecidos e determinados [1], [2]). Tais técnicas possibilitam o acompanhamento da vida útil e detecção de problemas em dispositivos elétricos de forma mais econômica, sem a necessidade de se interromper o processo produtivo e, principalmente, em situações em que o acesso ao dispositivo é difícil.

Em [7], duas técnicas não invasivas para a detecção de barras quebradas em rotor de motor de indução trifásico (MIT), falha que corresponde a cerca de 10% do total de

falhas quando comparado a outros tipos mais comuns neste dispositivo, foram analisadas. O primeiro método consistiu na Análise de Assinatura Elétrica (ESA - *Electrical Signature Analysis*) [4] e o segundo método consistiu na análise acústica tratada no contexto de reconhecimento de padrões através de modelos de misturas gaussianas (GMM do inglês *Gaussian Mixture Model*) empregando parâmetros acústicos característicos relacionados com modelos de predição linear perceptual (PLP do inglês *Perceptual Linear Prediction*) [9]. No primeiro método, realizado com carga acoplada e corrente nominal, pôde-se verificar a variação das amplitudes das bandas laterais em relação à fundamental conforme a quantidade de barras quebradas era incrementada. No segundo método, realizado sem carga acoplada, os modelos estatísticos assimilaram características do motor através de amostras de áudio de cada situação possibilitando a identificação de falhas. É importante salientar que o monitoramento das condições operacionais de um dispositivo elétrico, para acompanhamento ou detecção de falhas, não se dá simplesmente com a mesmo operando em condição nominal, pois pode acontecer, por exemplo, no controle de qualidade de motores novos recém saídos da linha de produção, que podem apresentar problemas nas barras rotóricas durante o processo de fabricação.

Neste trabalho realiza-se em uma análise mais detalhada da abordagem acústica na detecção de falhas [7] considerando coeficientes da análise de predição linear (LPC - do inglês *Linear Predictive Coding*) [10] e coeficientes Mel-cepstrais (MFCC do inglês *Mel-Frequency Cepstral Coefficients*) [11]. O intuito desta análise é verificar se outros parâmetros já conhecidos e com boa fundamentação teórica podem ser empregados no estudo de detecção de falhas. As falhas abordadas neste trabalho consistem na quebra de um a quatro barras adjacentes no rotor de um MIT a vazio, ou seja, sem carga acoplada explorando a mesma configuração experimental vista em [7]. Uma comparação entre modelos GMM criados com os três parâmetros característicos PLP, LPC e MFCC mostrou que os mesmos são eficientes na identificação ou não da falha, entretanto, os modelos MFCC não são robustos na identificação do tipo de falha estudado nas condições analisadas.

Este trabalho é organizado da seguinte forma: Na Seção II apresentamos o problema da detecção de falhas baseados em método acústico e a abordagem proposta. Na Seção III, apresentamos a modelagem estatística do problema de detecção de falhas, uma descrição breve dos parâmetros acústicos característicos e do decisor empregado. Na Seção IV, apresentaremos a configuração experimental empregada na aquisição e processamento de dados para análise de falhas. Finalmente, nas seções V e VI teremos, respectivamente, a análise de resultados e conclusões.

II. DETECÇÃO DE BARRAS QUEBRADAS POR MÉTODO ACÚSTICO

A detecção de falhas por método acústico consiste, em sua maioria, na análise do espectro em frequência do sinal sonoro gerado pelo equipamento analisado. Em [8] verificou-se que a presença ou não de problemas altera o espectro em frequência do sinal sonoro, possibilitando a detecção de anomalias no funcionamento do equipamento.

Este trabalho baseia-se no fato de que existem variações perceptíveis aos ouvidos humanos dependendo das condições de funcionamento de uma máquina, por exemplo: o som gerado por um motor a vazio é percebido de forma diferente quando comparado ao mesmo operando com uma carga acoplada. Quando um motor apresenta sons não condizentes com os apresentados com o motor em perfeito funcionamento, o motor pode apresentar algum problema. A incorporação do processamento acústico empregado em reconhecimento de fala/locutor na extração de parâmetros acústicos dos sinais gerados pela máquina elétrica pode modelar o efeito acústico percebido pelo ser humano e ser benéfico no problema de identificação de falhas.

III. MODELAGEM ESTATÍSTICA DO PROBLEMA

A presença de falhas é tratada pela modelagem estatística de casos, ou seja, coleta-se amostras de áudio de um MIT em diversas situações de funcionamento e criam-se modelos para cada caso. Os casos tratados englobam o MIT sem barras quebradas e de um a quatro barras adjacentes rompidas, em um total de cinco casos [7]. Uma vez que os modelos são criados o problema de detecção de falhas resume-se em um problema de identificação de padrões. Os modelos estatísticos utilizados neste trabalho são análogos aos baseados em modelos de identificação de locutor [12] que são modelados por GMMs. Um GMM é uma soma ponderada de M densidades componentes e é expressa por

$$P(\mathbf{x}|\lambda) = \sum_{i=1}^M c_i b_i(\mathbf{x}), \quad (1)$$

sendo que \mathbf{x} é um vetor de dados \mathcal{D} -dimensional; $\lambda = \{c_i, \boldsymbol{\mu}_i, \boldsymbol{\Sigma}_i\}$ expressa o modelo paramétrico GMM com peso da mistura c_i , vetor médio $\boldsymbol{\mu}_i$, e matriz de covariância $\boldsymbol{\Sigma}_i$; e

$$b_i(\mathbf{x}) = \mathcal{N}(\mathbf{x}; \boldsymbol{\mu}_i, \boldsymbol{\Sigma}_i) \quad (2)$$

são as densidades componentes, para $i = 1, \dots, M$. Cada densidade é uma função gaussiana dependente de \mathbf{x} .

O peso da mistura é limitado pela relação

$$\sum_{i=1}^M c_i = 1. \quad (3)$$

A dimensão do vetor \mathcal{D} depende do vetor \mathbf{x} e varia com a quantidade de parâmetros característicos empregados.

A. Parâmetros característicos acústicos

Os parâmetros característicos utilizados em reconhecimento de fala/locutor devem descrever as características de um som produzido pelo trato vocal ou processado pelo sistema auditivo humano. O LPC leva em consideração o trato vocal através da análise de predição linear cujos coeficientes modelam as variações existentes no sistema de produção da fala. O PLP, além da análise de predição linear, considera o processamento psicoacústico do sistema auditivo humano através do uso da escala Bark/Mel de percepção, da análise de bandas críticas e da conversão intensidade-sonoridade. O MFCC, assim como o PLP, baseia-se no processamento psicoacústico através do uso da escala Mel de percepção e da representação no domínio log-cepstral [13].

B. Decisor

Seja $P(\mathbf{x}|\lambda(\text{caso}_i))$ os GMMs criados para cada uma das condições do motor consideradas neste estudo, para um sinal sonoro de teste caracterizado por um conjunto de parâmetros característicos \mathbf{x} , assume-se que o modelo que produz a maior verossimilhança aponta para o caso mais provável em que se encontra o motor.

$$\text{caso escolhido} = \arg \max_{\mathbf{x}} (P(\mathbf{x}|\lambda(\text{caso}_i))). \quad (4)$$

IV. AQUISIÇÃO E PROCESSAMENTO DOS DADOS SONOROS

Os dados sonoros foram coletados utilizando-se um gravador digital portátil WS-812 (Olympus) em formato 'wav' com 16 bits de resolução e com frequência de amostragem de 44,1 kHz. Utilizou-se um microfone omnidirecional da fabricante Le Son. A coleta ocorreu ao longo do eixo (A) afastado $d = 5$ cm sem carga acoplada, conforme ilustrado na Figura 1.




Fig. 1. Aquisição de sinais sonoros ao longo do eixo de um MIT.

Os parâmetros característicos LPC, PLP e MFCC foram extraídos utilizando-se o *HTK* [13], uma ferramenta largamente empregada em reconhecimento de fala/locutor. Os dados originais foram inicialmente sub-amostrados a 16 kHz e depois processados admitindo-se quadros de 256 amostras, deslocamento de quadros de 128 amostras e janelamento de Hamming. Para cada parâmetro característico estudado 11 coeficientes foram extraídos. Para o PLP foi adicionada a componente cepstral de ordem zero ($10 + C_0$) e para o LPC ($10 + E$) e MFCC ($10 + E$) foi adicionada a componente de energia (E). Do total de dados disponíveis 44% foram usados para o treinamento dos modelos e 56% para a realização de testes. Os modelos GMMs foram estimados pelo algoritmo EM (*Expectation-Maximization*) com matriz de covariância diagonal.

Para cada parâmetro característico estudado cinco modelos foram treinados: GMM com motor sem barras quebradas e GMMs com motor com um a quatro barras adjacentes

quebradas. Para medir o desempenho do método proposto utiliza-se a taxa de acertos (%) que indica a correspondência entre os dados de teste e os modelos existentes.

V. ANÁLISE DOS RESULTADOS E DISCUSSÕES

As Figuras 2, 3 e 4 ilustram a taxa de acertos em função do aumento do número de componentes gaussianas nos GMMs considerando os parâmetros LPC, PLP e MFCC, respectivamente. Observa-se que a identificação do motor sem falhas se dá com uma taxa de acerto elevada sendo que o modelo com parâmetro PLP se destaca. A identificação do tipo de falha se dá com uma taxa de acerto acima de 80%, para 2 ou mais componentes gaussianas para os parâmetros LPC e PLP. Para o parâmetro MFCC nota-se um baixo desempenho, abaixo de 60%, na identificação do tipo de falha.

Os parâmetros que envolvem a análise de predição linear buscam modelar os efeitos da fonte geradora do sinal assimilando suas características. No caso da fala, os coeficientes da análise de predição linear modelam as variações do trato vocal e, de modo análogo, espera-se que em máquinas ocorra a modelagem das características físicas da mesma. Assume-se que o rompimento de barras provoca uma variação na estrutura do conjunto, rotor e estator, da máquina que é detectado pelos parâmetros LPC e PLP. No caso do parâmetro MFCC que preza pela modelagem psicoacústica, ou seja, o modo que o sinal é processado pelo sistema auditivo humano, o efeito da variação física da estrutura da máquina é parcialmente considerada pois o sistema aponta a ausência ou não de barras rompidas mas tem dificuldades em definir quantas barras estão rompidas.

As Tabelas I, II e III apresentam matrizes de confusão considerando 16 componentes gaussianas para cada parâmetro analisado. As linhas correspondem aos modelos GMM e as colunas as amostras de teste obtidas para cada um dos casos estudados, por exemplo, na Tabela I a matriz mostra que do total de dados disponíveis para o motor normal (motor sem barras rotóricas rompidas), 90,4% são atribuídos ao modelo normal, 0,1% ao modelo com 1 barra quebrada, 9,3% ao modelo com 2 barras quebradas e 0,2% ao modelo com 4 barras quebradas. Para as Tabelas I e II, considerando os parâmetros LPC e PLP, as taxas de acertos indicam que mesmo com os possíveis erros os modelos permitem identificar corretamente o tipo de falha existente. Para a Tabela III, considerando o parâmetro MFCC, nota-se que os erros se distribuem de forma mais uniforme entre os modelos existentes e, portanto, há possibilidade do método falhar como no teste de 4 barras quebradas que identificaram o modelo de 3 barras quebradas.

TABELA I

MATRIZ DE CONFUSÃO PARA PARÂMETRO CARACTERÍSTICO LPC.

		DADOS				
		Normal	1B	2B	3B	4B
Modelos	Normal	90,4%	0,0%	0,6%	0,0%	0,0%
	1B	0,1%	87,1%	2,8%	4,6%	10,1%
	2B	9,3%	1,3%	90,8%	0,5%	2,6%
	3B	0,0%	4,3%	0,2%	90,8%	3,9%
	4B	0,2%	7,3%	5,6%	4,1%	83,4%

TABELA II

MATRIZ DE CONFUSÃO PARA PARÂMETRO CARACTERÍSTICO PLP.

		DADOS				
		Normal	1B	2B	3B	4B
Modelos	Normal	98,7%	0,3%	0,4%	0,0%	0,0%
	1B	0,4%	83,7%	10,4%	1,9%	6,8%
	2B	0,8%	10,3%	86,8%	0,4%	2,5%
	3B	0,0%	0,5%	0,1%	89,9%	4,7%
	4B	0,1%	5,2%	2,3%	7,8%	86,0%




Fig. 2. Identificação de falhas pelo aumento do números de componentes gaussianas considerando parâmetro LPC.

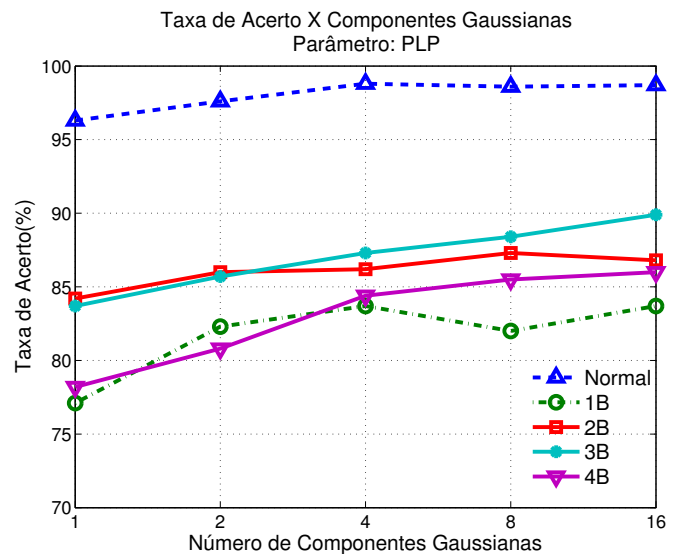


Fig. 3. Identificação de falhas pelo aumento do números de componentes gaussianas considerando parâmetro PLP.




Fig. 4. Identificação de falhas pelo aumento do números de componentes gaussianas considerando parâmetro MFCC.

TABELA III

MATRIZ DE CONFUSÃO PARA PARÂMETRO CARACTERÍSTICO MFCC.

		DADOS				
		Normal	1B	2B	3B	4B
Modelos	Normal	89,6%	0,0%	15,8%	0,0%	0,1%
	1B	0,2%	32,8%	8,9%	25,8%	25,7%
	2B	9,7%	11,2%	50,3%	7,9%	15,4%
	3B	0,0%	29,1%	8,0%	36,1%	30,0%
	4B	0,5%	26,9%	17,0%	30,2%	28,8%

VI. CONCLUSÕES

Este trabalho apresentou um estudo da detecção de falhas em máquinas elétricas no contexto de reconhecimento de padrões através de modelos de misturas gaussianas treinadas com parâmetros acústicos característicos, LPC, PLP e MFCC, comumente empregados em reconhecimento de fala e locutor. A identificação ou não de falhas pode ser verificada usando-se os três parâmetros acústicos característicos estudados, porém, o parâmetro MFCC não apresentou bom desempenho na identificação do tipo de falha, no caso, o número de barras quebradas em um MIT. Acredita-se que o baixo desempenho do parâmetro MFCC deve-se a falta de incorporação das características físicas do motor que seriam modeladas pela análise de predição linear para os parâmetros LPC e PLP.

AGRADECIMENTOS

Agradecemos a Fundação Araucária pelo fomento da bolsa de Iniciação Científica (IC) - Brasil.

REFERÊNCIAS

- [1] T. B. Pierini, C. A. Conceição, L. P. Lopes, A. B. Marques, E. L. Bonaldi, "Manutenção Preditiva de Motores de Indução Trifásicos Através da Análise da Assinatura da Corrente do Estator," in *REGAP, 9º, Encontro de Engenharia Elétrica da Petrobras*, 2007.
- [2] E. L. Bonaldi, L. E. L. Oliveira, T. B. Pierini, T. N. Calisto, C. A. Conceição, L. P. Lopes, A. B. Marques, "Análise e Identificação de Falhas em Motores de Indução em Indústrias Petroquímicas Através da Técnica de Análise da Assinatura Elétrica - ESA," in *VIII Conferência Internacional de Aplicações Industriais - INDUSCON*, 2008.
- [3] J. G. B. Silva, "Aplicação da análise de componentes principais (PCA) no diagnóstico de defeitos em rolamentos através da assinatura elétrica de motores de indução", Dissertação de Mestrado, Universidade Federal de Itajubá - UNIFEI, 2008.
- [4] E. L. Bonaldi, "Diagnóstico Preditivo de Avarias em Motores de Indução Trifásico com MCSA e Teoria de Conjuntos Aproximados", Dissertação de Mestrado, Universidade Federal de Itajubá - UNIFEI, 2006.
- [5] A. Sadoughi, M. Ebrahimi, M. Moalem, S. Sadri, "Intelligent Diagnosis of Broken Bars in Induction Motors Based on New Features in Vibration Spectrum," in *IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives*, pp. 106 - 111, 2007.
- [6] M. Iorgulescu, R. Beloiu, O. M. Popescu, "Rotor bars diagnosis in single phase induction motors based on the vibration and current," in *12th International Conference on Optimization of Electrical and Electronic Equipment*, pp. 364-370, 2010.
- [7] E. L. Miotto, A. Y. Nakano, "Análise de barras quebradas em rotor de motor de indução trifásico por assinatura de corrente elétrica e por processamento psicoacústico," in *MOMAG - 16º SBMO - Simpósio Brasileiro de Micro-ondas e Optoeletrônica; e 11º CBMag - Congresso Brasileiro de Eletromagnetismo*, 2014.
- [8] W. Li, C. K. Mecheske, "Detection of Induction Motor Faults: A Comparison of Stator Current, Vibration and Acoustic Methods," in *Journal of vibration and Control* Vol. 12(2), 165-188, 2006.
- [9] H. Hermansky, "Perceptual linear predictive (PLP) analysis of speech", *Journal of the Acoustical Society of America*, Vol. 87, pp.1738-1752, 1990.
- [10] L. Rabiner, B-H. Juang, *Fundamentals of speech recognition*, Prentice-Hall, New Jersey, 1993.
- [11] S.B. Davis, and P. Mermelstein, "Comparison of Parametric Representations for Monosyllabic Word Recognition in Continuously Spoken Sentences," in *IEEE Transactions on Acoustics, Speech, and Signal Processing*, Vol. 28(4), 357-366, 1980.
- [12] D. A. Reynolds, R. C. Rose, "Robust text-independent speaker identification using gaussian mixture speaker models," in *IEEE Trans. Speech and Audio Processing*, Vol.3(1), pp.72-83, 1995.
- [13] Hidden Markov Model Toolkit (HTK), <http://htk.eng.cam.ac.uk/>, acessado em: 01 maio de 2015.