

DIAGNÓSTICO AUTOMÁTICO DE FALHAS EM MANCAIS DE MÁQUINAS ROTATIVAS

AUTOMATIC DIAGNOSIS OF FAULTS IN ROTARY MACHINE BEARINGS

Dionisio Henrique Carvalho de Sá Só MARTINSⁱ
Thiago de Moura PREGOⁱⁱ
Amaro Azevedo de LIMAⁱⁱⁱ

RESUMO

Este artigo apresenta um método para diagnosticar falhas em máquinas rotativas através da análise de sinais de vibração a fim de propor uma nova metodologia de manutenção para as impressoras do tipo *offset* da Divisão Gráfica da Universidade Federal do Rio de Janeiro (UFRJ). Para tanto, o trabalho faz a classificação de três tipos de classes diferentes: sinais com defeito no mancal afastado do motor, sinais com defeito no mancal próximo ao motor e sinais normais. Além disso, também é feita a classificação dos tipos de defeitos que ocorrem nos mancais próximo e afastado do motor: defeito na gaiola, na pista externa e na esfera. O algoritmo usado para fazer a classificação foi o *Random Forest*, que atingiu uma acurácia de 98,15%.

PALAVRAS-CHAVE: Diagnóstico de Falhas; Mancais de Máquinas Rotativas; *Random Forest*.

ⁱ É assistente em administração lotado na Divisão Gráfica da Universidade Federal do Rio de Janeiro (UFRJ). Concluiu o bacharelado em Engenharia de Controle e Automação no Centro Federal de Educação Tecnológica Celso Suckow da Fonseca (CEFET/RJ) em 2013. Concluiu a especialização em Engenharia Mecatrônica na Universidade Católica de Petrópolis em 2016. Concluiu o mestrado em Engenharia Elétrica no CEFET/RJ em 2016. As linhas de pesquisa de interesse são diagnóstico automático de falhas, classificação e instrumentação industrial. *E-mail:* dionisiohenrique@ig.com.br.

ⁱⁱ Atualmente é Professor do curso técnico em Telecomunicações do Centro Federal de Educação Tecnológica Celso Suckow da Fonseca (CEFET/RJ), Professor do Mestrado em Engenharia Elétrica (PPEEL) do CEFET/RJ e Pesquisador da Universidade Federal do Rio de Janeiro (UFRJ). Possui graduação em Engenharia Eletrônica e de Computação pela UFRJ (2007), mestrado em Engenharia Elétrica pela UFRJ (2009) e doutorado em Engenharia Elétrica pela UFRJ (2012). Tem experiência na área de Engenharia Elétrica, com ênfase em Telecomunicações. Atua principalmente nos seguintes temas: Processamento de Voz, Avaliação de Qualidade e Desreverberação. *E-mail:* thiago.prego@cefet-rj.br.

ⁱⁱⁱ É professor na Coordenação de Telecomunicações e na Coordenação de Engenharia de Controle e Automação do Centro Federal de Educação Tecnológica Celso Suckow da Fonseca (CEFET/RJ). Recebeu o título de Engenheiro Eletrônico pela Universidade Federal do Rio de Janeiro (UFRJ), o título de M.Sc. pela COPPE/UFRJ e o título de Ph.D. pelo Instituto Tecnológico de Nagoya no Japão nos anos de 1999, 2001 e 2005, respectivamente. Nos anos de 2005 e 2006, foi aceito e atuou no programa de pós-doutorado do CNPq, e, nos anos de 2007 e 2008, trabalhou como pesquisador em projetos envolvendo a COPPE/UFRJ. Desde 2009, está no CEFET/RJ, atuando como professor na Coordenação de Telecomunicações e na Coordenação de Engenharia de Controle e Automação, ambos no *campus* Nova Iguaçu; e no Programa de Pós-Graduação em Engenharia Elétrica e no Programa de Pós-Graduação em Instrumentação e Óptica Aplicada, ambos no *campus* Maracanã. As linhas de pesquisa de interesse incluem reconhecimento automático de fala, *kernel learning machines*, avaliação de qualidade de fala e reconhecimento de padrões. *E-mail:* amaro.lima@cefet-rj.br.

ABSTRACT

This article introduces a method for fail diagnosis in rotating machines analysing vibrations signals, in order to propose a new maintenance methodology for the offset printers of Graphic Division of Federal University of Rio de Janeiro (UFRJ). This work realizes the classification of three different types of faults: signals with defect in the far from the motor bearing, signals with defect in the near to the motor bearing and normal signals. In addition, also is made the classification of the types of the defects that happen in the near and far from the motor bearings: defects in the cage, in the outer track and in the roller. The algorithm used to make the classification was the Random Forest that reached an accuracy of 98,15%.

KEYWORDS: Fail diagnosis; Rotary Machines Bearings; Random Forest.

1 INTRODUÇÃO

Nas indústrias de produção e manufatura, os custos relativos à manutenção dos equipamentos correspondem à parte dos custos operacionais, logo, a gestão incorreta da manutenção pode provocar grandes prejuízos para a produção e conseqüentemente reduzir a competitividade do produto no mercado (ABREU; SOARES; SOUZA, 2012). Neste sentido, para evitar que aconteçam paradas não previstas no processo produtivo por falta de manutenção adequada, utiliza-se a manutenção preditiva.

Uma das formas para se realizar a manutenção preditiva em mancais de máquinas rotativas é a utilização da análise dos sinais de vibrações. Para que o processo de diagnóstico de falhas seja realizado de forma automática e com rapidez, são usados algoritmos de classificação, com destaque para o algoritmo *Random Forest* (ZAMBRANO, 2014).

O mancal de uma estrutura ou máquina pode ser definido como as superfícies de contato por meio das quais há uma transmissão de carga. Geralmente é necessário que haja um material lubrificante no mancal a fim de reduzir o calor e o atrito provocados pelo movimento relativo das superfícies (NORTON, 2007).

Diante dessa realidade, este trabalho tem a finalidade de estudar problemas em mancais baseado na manutenção preditiva, tendo como objetivo oferecer um tipo de manutenção moderno quanto ao tempo de parada para reparos para as impressoras *Offset* da Divisão Gráfica da Universidade Federal do Rio de Janeiro (UFRJ).

2 TIPOS DE MANUTENÇÃO

A manutenção industrial pode ser dividida em três tipos: manutenção corretiva, manutenção preventiva e manutenção preditiva, conforme definidas nas subseções a seguir. Atualmente, já existe um programa de manutenção corretiva e preventiva na Divisão Gráfica da UFRJ, porém ainda não há um programa de manutenção preditiva implementado.

Os objetivos básicos da manutenção estão atrelados à operação e à produção. Para que a manutenção seja feita de maneira eficaz, eficiente, confiável e com baixo custo é necessário estabelecer os seguintes procedimentos: realizar estudos técnicos e organizacionais de forma a propor melhorias tecnológicas para produção; diminuir o máximo possível o tempo de parada dos equipamentos, seja para manutenção corretiva ou para manutenção preventiva; e assegurar que o equipamento fique operacional e que tenha um atendimento imediato de manutenção descentralizada ou através de um método baseado na confiabilidade (SOUZA, 2011).

2.1 MANUTENÇÃO CORRETIVA

A manutenção corretiva pode ser definida como a atividade de manutenção realizada após a ocorrência de uma pane, tendo como finalidade fazer com que um equipamento volte a realizar as suas funções normais (ABNT, 1994).

Seu objetivo é reparar um defeito no equipamento, visando garantir que a produção seja reiniciada no menor tempo possível, levando em consideração os fatores de segurança e qualidade inerentes ao processo produtivo (ABNT, 1994).

2.2 MANUTENÇÃO PREVENTIVA

A manutenção preventiva tem como finalidade realizar o monitoramento periódico das condições elétricas, eletrônicas e mecânicas dos equipamentos a fim de maximizar a produção e evitar paradas por quebras nos equipamentos (WALTER; SALLES, 2006).

De acordo com a NBR 5462, de 1994 (ABNT, 1994), a manutenção preventiva pode ser definida como aquela realizada em períodos de tempo agendados previamente, ou seguindo critérios anteriormente estabelecidos, tendo o objetivo de diminuir a chance de falha e a deterioração de um dado elemento da máquina.

Esse tipo de manutenção tem como fundamento o conhecimento estatístico da frequência de falhas dos componentes obtidas com o decorrer do tempo e deve ocorrer de forma periódica, levando em consideração a vida útil dos componentes e seus respectivos riscos de falhas.

Pode-se citar como exemplos de atividades da manutenção preventiva sistemática: a inspeção, limpeza, calibração, lubrificação, além das trocas de determinados componentes das máquinas.

Para que a ação de manutenção preventiva venha a ser eficaz, esta deve estar baseada em planos de manutenção elaborados em conjunto pelos setores de produção e manutenção. Estes planos de manutenção devem ser elaborados a partir da análise dos dados históricos de funcionamento do equipamento desde sua instalação.

2.3 MANUTENÇÃO PREDITIVA

A manutenção preditiva é aquela que tem a função de acompanhar os parâmetros de funcionamento da máquina e realizar a previsão de falhas, a fim de que a sua reparação venha a ser feita no momento adequado. Este tipo de manutenção pode ser entendido como uma evolução da manutenção preventiva.

Conforme a NBR 5462, de 1994 (ABNT, 1994), a manutenção preditiva é aquela que tem a finalidade de manter o equipamento sempre em condições normais de operação, através da aplicação de técnicas de análise que usam meios de supervisão ou de amostragem, com o objetivo de diminuir as manutenções corretivas e preventivas.

O estabelecimento de um programa de manutenção preditiva não implica o fim das manutenções corretivas e preventivas. Na verdade, para que se alcance o máximo da eficiência de produção, os três programas de manutenção devem ser bem executados (NEPOMUCENO, 2013).

Dentre as formas de medição e análise, podem ser destacadas: as análises por meio de pressões, ultrassom, termografia e por vibrações

(WALTER; SALLES, 2006). A análise por vibrações é o método escolhido para realizar os experimentos deste artigo.

Para a implantação do programa de manutenção preditiva, é necessário a realização de investimentos para compra de instrumentos de medição, tais como: sensores de pressão, ultrassom, térmicos e sensores de vibrações, dependendo do tipo de aplicação. A princípio, a aquisição destes dispositivos gera a impressão de que este programa de manutenção não é vantajoso, pois os acelerômetros usados como sensores de vibração neste projeto têm custos elevados; no entanto, quando o diagnóstico dos equipamentos é feito corretamente, há redução de custos em manutenção corretiva e também aumento na produção ao diminuir o número de paradas.

Em média, quando são levados em conta os custos de mão de obra, componentes e materiais, a manutenção preditiva é de 15% a 20% mais econômica que a manutenção corretiva (NEPOMUCENO, 2013).


3 CARACTERÍSTICAS DO SISTEMA DE SIMULAÇÃO

É comum a utilização de bancadas de simulação para estudar determinados defeitos que acontecem em máquinas rotativas, uma vez que o custo econômico para implementar uma falha de mancal em uma máquina industrial é alto, além de prejudicar a produção (ZAMBRANO, 2014).

Para realizar os experimentos de inserção de defeitos em mancais, foi usada a bancada experimental *Alignment/Balance Vibration Trainer* (ABVT), produzida pela empresa Spectra Quest Inc. Esta bancada, ilustrada pela Figura 1, é composta por um motor de corrente contínua com potência de 0,25 CV, com variação de velocidade no intervalo de [700, 3780] RPM, com distância de separação dos mancais de 390mm, e as medidas do diâmetro do eixo e de seu comprimento são respectivamente de 16mm e 520mm (ZAMBRANO, 2014).

Os defeitos no mancal afastado do motor e no mancal próximo ao motor são inseridos através da substituição dos mancais normais por mancais com defeitos na gaiola, na esfera ou na pista externa.

Figura 1: Bancada experimental usada nas simulações



Fonte: ZAMBRANO, 2014.

3.1 BASE DE DADOS

A base de dados usada neste experimento tinha a seguinte configuração: 49 sinais normais, 558 sinais de defeitos no mancal próximo ao motor e 513 sinais de defeitos no mancal afastado do motor. Os sinais de vibração usados neste trabalho foram amostrados a uma taxa de 50 kHz.

A classe de sinais do mancal próximo ao motor é composta por 188 sinais com defeito na gaiola, 184 sinais com defeito na pista externa e 186 sinais com defeito na esfera. Já a classe de sinais do mancal afastado do motor é composta por 188 sinais com defeito na gaiola, 188 sinais com defeito na pista externa e 137 sinais com defeito na esfera.

Como a classe de sinais normais apresenta uma quantidade de cenários bem menor que as classes de defeitos no mancal próximo do motor e no mancal afastado do motor, foi usada a estratégia de adicionar ruído branco aos sinais normais originais para aumentar o número de sinais normais de 49 para 343, a fim de evitar grandes erros na classificação, ou seja, um número alto de casos identificados como pertencentes a classes incorretas.

3.2 FREQUÊNCIAS CARACTERÍSTICAS DE FALHAS

As falhas correspondentes aos elementos que constituem o mancal apresentam frequências características distintas. Foram estudadas as falhas na pista externa, na gaiola e na esfera para este trabalho (RANDALL; ANTONI, 2011).

A frequência de passagem das esferas em um ponto da pista externa (F_{PEE}) é dada pela Equação (1):

$$F_{PEE} = \frac{nR_f}{2} \left\{ 1 - \frac{d}{D} \cos\emptyset \right\} \quad (1)$$

A frequência de passagem das esferas em um ponto da pista interna (F_{PEI}) é dada pela Equação (2):

$$F_{PEI} = \frac{nR_f}{2} \left\{ 1 + \frac{d}{D} \cos\emptyset \right\}. \quad (2)$$

A frequência de rotação da gaiola (F_{RG}) é dada pela Equação (3):

$$F_{RG} = \frac{R_f}{2} \left\{ 1 - \frac{d}{D} \cos\emptyset \right\}. \quad (3)$$

A frequência de rotação das esferas (F_{RE}) é dada pela Equação (4):

$$F_{RE} = \frac{D}{2d} \left\{ 1 - \left(\frac{d}{D} \cos\emptyset \right)^2 \right\}, \quad (4)$$

onde n é o número de esferas, d é o diâmetro das esferas, R_f é a velocidade de rotação do eixo, \emptyset é o ângulo de carga em relação ao plano radial e D é a distância entre os centros de duas esferas posicionadas em lados opostos do mancal.

Um mancal de rolamento em condição normal apresenta as frequências descritas acima com pequenas amplitudes no espectro de frequência. No entanto, caso haja algum tipo de defeito no mancal,

aparecerá no espectro uma amplitude acentuada na frequência correspondente a este tipo de defeito.

As frequências representadas pelas equações acima sofrem variações em relação aos valores obtidos por meio de medições, em virtude do efeito de deslizamento das esferas causado principalmente pela variação de aplicação de carga ao mancal.

4 EXTRAÇÃO DE CARACTERÍSTICAS

A extração de características é útil para o reconhecimento de falhas em mancais de máquinas rotativas porque reduz-se a complexidade do problema de aprendizado do algoritmo (MARTINS et al., 2016).

Os sinais de vibração são obtidos por um tacômetro e por acelerômetros piezoelétricos instalados no mancal mais próximo do motor e no mancal mais afastado do motor. Os sinais obtidos são processados com o objetivo de realizar a extração das características que sejam necessárias para distinguir os tipos de falhas.

O vetor de características utilizado nos experimentos 1, 2 e 3 deste trabalho foi composto por 31 características. Para realizar a extração de características foi empregado um algoritmo capaz de calcular a transformada rápida de Fourier, a curtose e a entropia (MARTINS et al., 2016).

A transformada rápida de Fourier é um algoritmo capaz de calcular a transformada discreta de Fourier (TDF) de forma eficiente, diminuindo a quantidade de operações aritméticas a serem executadas. Onde k é o índice de frequência relativo à Ω_0 e $\Omega_0 = \frac{2\pi}{N}$ é a frequência fundamental. Obtêm-se a frequência ω do espectro da TDF, multiplicando $k\Omega_0$. A Equação (5) mostra a equação de cálculo da TDF.

$$X[K] = \frac{1}{N} \sum_{n=-\infty}^{\infty} x[n]e^{-jk\Omega_0n}, \quad (5)$$

onde $X[K]$ representa o sinal no domínio da frequência discreta, $x[n]$ é o sinal no domínio do tempo discreto, n é o número de amostras e N é o período.

A curtose é definida como o momento central de quarta ordem, sendo usada para reconhecer os sinais de vibração impulsivos, pois é robusta em relação à classificação de sinais ruidosos (SAIDI; ALI; FNAIECH, 2014). A Equação (6) representa o cálculo da curtose K .

$$K = \frac{E(x-\mu)^4}{\sigma^4} - 3, \quad (6)$$

onde $E(x - \mu)$ é o valor esperado da variável aleatória x e σ é o desvio padrão.

A entropia pode ser entendida como uma medida capaz de avaliar o grau de imprevisibilidade de uma variável aleatória. A Equação (7) mostra o cálculo da entropia $H(u)$ para uma variável aleatória discreta u .

$$H(u) = \sum_{i=1}^n p_i(u) \log \frac{1}{p_i(u)}, \quad (7)$$

onde $p_i(u)$ é a densidade de probabilidade da variável aleatória discreta u .

Através da transformada rápida de Fourier extraíram-se dezoito características, referentes às amplitudes no espectro de frequência. Para cada sinal vindo dos acelerômetros posicionados nas direções axial, radial e tangencial dos mancais mais próximo e mais distante do motor, foram obtidas três características que correspondem ao valor da amplitude do espectro nas frequências R_f (frequência de rotação do motor), $2R_f$ e $3R_f$ (MARTINS et al., 2016).

Também foi obtida, através da transformada rápida de Fourier do sinal proveniente do tacômetro, a característica que representa a velocidade de rotação do motor.

Para cada um dos sinais vindos dos acelerômetros, foram calculadas a curtose e a entropia, originando doze características, que eram curtose dos sinais de vibração na direção axial, radial e tangencial do mancal próximo; curtose dos sinais de vibração na direção axial, radial e tangencial do

mancal afastado; entropia dos sinais de vibração na direção axial, radial e tangencial do mancal próximo; e entropia dos sinais de vibração na direção axial, radial e tangencial do mancal afastado.

4.1 SEPARAÇÃO DE DADOS

O algoritmo *Random Forest* é um método de classificação supervisionado, ou seja, ele precisa de amostras que tenham suas classes identificadas para que possa ser treinado (BREIMAN, 2001).

O método de separação da base de dados deste trabalho foi a utilização de 70% das amostras para realização do treinamento do algoritmo e 30% das amostras para realização da etapa de teste. Tanto para etapa de treinamento quanto para a etapa de teste, buscou-se separar as amostras considerando uma distribuição regular quanto à velocidade de rotação do motor, isto é, o objetivo foi fazer com que tanto o conjunto de treinamento quanto o de teste tivessem o maior número de velocidades diferentes de rotação do motor a fim de tornar a simulação o mais próximo possível do caso real.

5 DIAGNÓSTICO DE FALHAS

O processo de diagnóstico lida com a detecção e a identificação das falhas. O diagnóstico de falhas em máquinas é um procedimento de mapeamento de informações obtidas no espaço de medidas ou no espaço de características (JARDINE; LIN; BANJEVIC, 2005).

O diagnóstico de falhas também pode ser usado como informação para realizar ajustes no projeto do equipamento a fim de se obter uma melhor eficiência (JARDINE ; LIN; BANJEVIC, 2005).

Para a elaboração deste estudo, foi utilizado o algoritmo *Random Forest* com o objetivo de realizar o diagnóstico de falhas no motor. Este algoritmo é formado por um conjunto de árvores de decisão (BREIMAN, 2001).

A árvore de decisão é uma estrutura muito usada na implementação de sistemas especialistas e em problemas de classificação. As árvores de decisão tomam como entrada uma situação descrita por um conjunto de atributos e retorna uma decisão, que é o valor predito para o valor de entrada.

Aqui, o único parâmetro de ajuste do algoritmo foi o número de árvores para compor o algoritmo. Variou-se o número de árvores de um a cem, a fim de encontrar o menor número de árvores que alcançasse a maior média de acerto relativo intraclasse, que corresponde à soma dos valores percentuais das acurácias dividida pelo número de classes.

Uma vez selecionado esse parâmetro através da etapa de treinamento do algoritmo, posteriormente, executou-se o algoritmo no conjunto-teste para obter o desempenho real do método de classificação.


Para tanto, utilizou-se um computador com velocidade de processamento de 1,48 GHz e com memória RAM 3,58 GB para executar os experimentos. O *software* utilizado para realizar os experimentos foi o *Matlab*.

5.1 EXPERIMENTO 1

O experimento 1 teve como finalidade realizar a classificação das seguintes classes: 153 sinais com defeito no mancal afastado do motor (A1), 167 sinais com defeito no mancal próximo ao motor (A2) e 105 sinais normais (A3).

Com a finalidade de se observar o comportamento do *Random Forest* durante a fase de treinamento deste experimento, foi plotado um gráfico, Figura 2, que relaciona o número de árvores com o percentual de acerto relativo intraclasse de treinamento. O número de árvores é escolhido quando o gráfico atinge o maior valor de acurácia. Através da análise deste gráfico, foi verificado que com oito árvores o algoritmo apresenta 100% de acerto, e a partir deste número de árvores o seu desempenho praticamente se estabiliza.

Figura 2: Acerto relativo intraclasse de treinamento em função do número de árvores para o experimento 1



Fonte: MARTINS, 2016.

Para este experimento, o número de árvores escolhido na etapa de treinamento foi de oito árvores. Uma vez escolhido o número de árvores, este foi implementado no algoritmo para realizar a classificação do conjunto-teste mostrado na Tabela 1, que apresenta o número de classificações corretas *versus* as classificações preditas para cada classe do experimento. A média de acerto relativo intraclasse obtida foi de 98,15%.

Tabela 1: Matriz de resultados para o experimento 1

CLASSE DE SAÍDA	CLASSE ALVO		
	A1	A2	A3
A1	150/153	6/167	0/105
A2	3/153	161/167	0/105
A3	0/153	0/167	105/105
ACERTO	98,04%	96,41%	100%

Fonte: MARTINS, 2016


5.2 EXPERIMENTO 2

O experimento 2 teve como objetivo identificar as seguintes classes: 56 sinais com defeito na gaiola do mancal afastado do motor (B1), 56 sinais com

defeito na pista externa do mancal afastado do motor (B2) e 41 sinais com defeito na esfera do mancal afastado do motor (B3).

Para verificar o comportamento do *Random Forest* na fase de treinamento do experimento 2, plotou-se um gráfico, Figura 3, que relaciona o número de árvores com o percentual de acerto relativo intraclasse de treinamento. Por meio da análise deste gráfico, é verificado que, com cinco árvores, o algoritmo apresenta 100% de acerto, e a partir deste número de árvores o seu desempenho praticamente se estabiliza.

Figura 3: Acerto relativo intraclasse de treinamento em função do número de árvores para o experimento 2



Fonte: MARTINS, 2016

No experimento 2, o número de árvores escolhido na etapa de treinamento foi de cinco árvores. Tendo escolhido o número ótimo de árvores, este foi implementado no algoritmo para realizar a classificação do conjunto-teste mostrado na Tabela 2, que apresenta o número de classificações corretas *versus* as classificações previstas para cada classe do experimento. A média de acerto relativo intraclasse obtida foi de 94,80%.

Tabela 2: Matriz de resultados para o experimento 2

CLASSE DE SAÍDA	CLASSE ALVO		
	B1	B2	B3
B1	53/56	3/56	1/41
B2	3/56	53/56	1/41
B3	0/56	0/56	39/41
ACERTO	94,64%	94,64%	95,12%

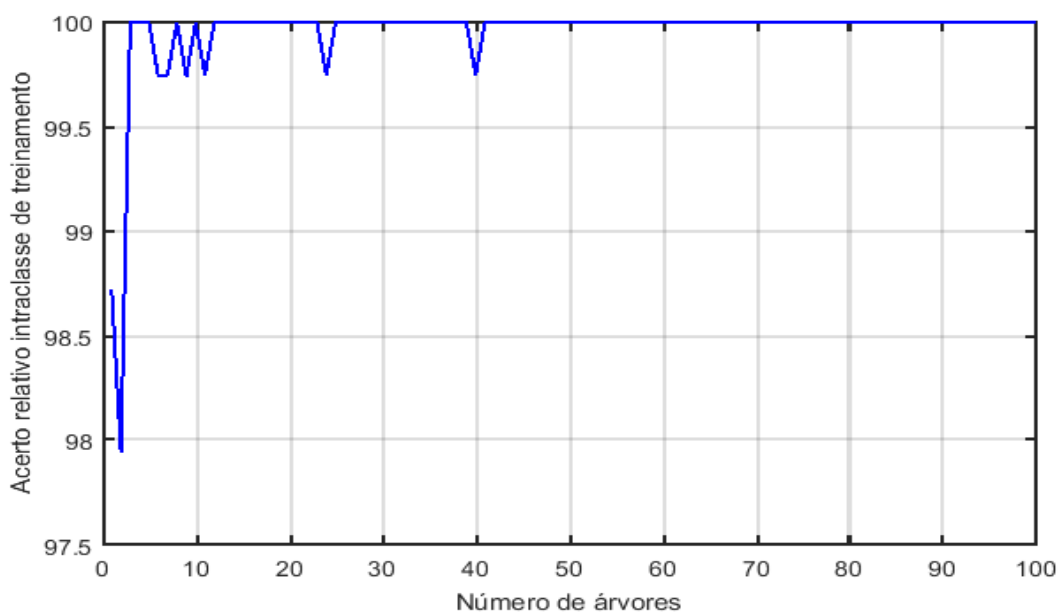
Fonte: MARTINS, 2016

5.3 EXPERIMENTO 3

O experimento 3 teve como objetivo identificar as seguintes classes: 56 sinais com defeito na gaiola do mancal próximo ao motor (C1), 55 sinais com defeito na pista externa do mancal próximo ao motor (C2) e 56 sinais com defeito na esfera do mancal próximo ao motor (C3).

Para verificar o comportamento do *Random Forest* na fase de treinamento do experimento 3, foi plotado um gráfico, Figura 4, que relaciona o número de árvores com o percentual de acerto relativo intraclasse de treinamento. Analisando este gráfico, foi verificado que, com cinco árvores, o algoritmo apresenta 100% de acerto, e a partir deste número de árvores o seu desempenho praticamente se estabiliza.

Figura 4: Acerto relativo intraclasse de treinamento em função do número de árvores para o experimento 3



Fonte: MARTINS, 2016.

No experimento 3, o número de árvores escolhido na etapa de treinamento foi de cinco árvores. Tendo escolhido o número ótimo de árvores, este foi implementado no algoritmo para realizar a classificação do conjunto teste mostrado na Tabela 3, que apresenta o número de classificações corretas *versus* as classificações preditas para cada classe do experimento. A média de acerto relativo intraclasse obtida foi de 100%.

Tabela 3: Matriz de resultados para o experimento 3

CLASSE DE SAÍDA	CLASSE ALVO		
	C1	C2	C3
C1	56/56	0/55	0/56
C2	0/56	55/55	0/56
C3	0/56	0/55	56/56
ACERTO	100%	100%	100%

Fonte: MARTINS, 2016.

6 IMPRESSORAS OFFSET DA DIVISÃO GRÁFICA DA UFRJ

Nas últimas duas décadas, a Divisão Gráfica da UFRJ não tem recebido investimentos para realizar a compra de novas máquinas para Seção de *Offset*.

Atualmente, a Divisão possui cinco impressoras do tipo *Offset* com mais de 25 anos de uso (a Figura 5 apresenta a foto de uma das impressoras). Por isso, devido ao longo tempo de utilização, é necessário que haja um programa de manutenção efetivo para que estas máquinas continuem funcionando adequadamente.

Figura 5: Impressora Offset Catu 660 bicolor



Fonte: GRÁFICA, 2016.

Essas máquinas são capazes de imprimir trabalhos gráficos que atendem a toda comunidade universitária, tais como: formulários, certificados, pastas, cartazes e *folders*. Estas impressoras também são indicadas para produção de impressos com alta tiragem, normalmente, acima de 1000 unidades.

O processo de impressão *offset* utiliza um tipo de tinta pastosa e gordurosa juntamente com uma solução de molhagem composta por água e aditivos. A utilização da solução de molhagem e desse tipo de tinta é necessária para que haja a distinção entre o grafismo, área que contém imagem, e o contragrafismo, área que não apresenta imagem.

A área que contém o grafismo tem afinidade com a gordura e rejeita a solução de molhagem, fazendo com que a tinta seja absorvida. Já a área do contragrafismo tem afinidade com solução de molhagem e rejeita a gordura, fazendo com que a tinta não seja absorvida por essa região (SENAI, 2014).

No momento de elaboração deste trabalho, a Divisão Gráfica tem um contrato de manutenção corretiva e preventiva para as suas máquinas, porém, ainda não possui um programa de manutenção preditiva.

Para implementação do programa de manutenção preditiva, seria necessário o investimento na compra de sensores como acelerômetros e tacômetros, além da compra de um *hardware* microprocessado que implementasse o algoritmo de reconhecimento de falhas em mancais. Para

que isso fosse viável, seria necessária a abertura de um termo de referência para compra destes itens, além da realização de um novo contrato com uma empresa de manutenção para que esta pudesse gerenciar os dados obtidos por este sistema.

7 CONCLUSÕES

Após a apresentação de um método para diagnóstico de falhas em máquinas rotativas através da análise de sinais de vibração, o presente trabalho apresentou a classificação de três tipos de classes diferentes (sinais com defeito no mancal afastado do motor, sinais com defeito no mancal próximo ao motor e sinais normais) e três tipos de defeitos que ocorrem nos mancais próximo e afastado do motor (defeito na gaiola, na pista externa e na esfera).

A partir dos experimentos realizados, observou-se que, no experimento 1, o método alcançou 98,15% de acerto para identificação do tipo de mancal defeituoso.

Já no experimento 2, o método alcançou 94,80% de acerto para o diagnóstico dos tipos de defeitos no mancal afastado do motor. Reconhecendo-se a ocorrência de uma falha no mancal invertido, a probabilidade de identificação do tipo de falha ocorrido superou 92%.

Por fim, no experimento 3, o algoritmo alcançou 100% de acerto para diagnosticar os tipos de defeitos no mancal próximo do motor. Sabendo que uma falha ocorreu no mancal invertido, a probabilidade de conhecer o tipo de falha ocorrido superou 96%.

Com os resultados obtidos nos três experimentos, concluiu-se que o *Random Forest* é eficiente para fazer o diagnóstico de falhas em mancais de máquinas rotativas. Sendo assim, entende-se ser viável propor a implantação deste novo tipo de manutenção para descobrir falhas em mancais defeituosos nas máquinas da Divisão Gráfica da UFRJ, bem como em setores de outras instituições que utilizem o mesmo tipo de maquinário aqui analisado.

Sugestões para trabalhos futuros sobre este assunto incluem a realização de uma classificação da severidade das classes e a observação, no vetor de características utilizado, de quais características são mais relevantes para efetuar a distinção das classes.

REFERÊNCIAS

ABNT – ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 5462**: confiabilidade e manutenibilidade. Rio de Janeiro, 1994.

ABREU, A. M.; SOARES, I. M.; SOUZA, S. T. O. Termografia em manutenção preditiva: conceitos e aplicabilidades em máquinas e equipamentos industriais. **Revista de Divulgação do Projeto Universidade Petrobras e IF Fluminense**, v. 2, n. 1, p. 89-94, nov. 2012.

BREIMAN, L. Random forests. **Machine Learning**, v. 45, p. 5-32, out. 2001.

GRÁFICA UFRJ. **Máquinas da gráfica**. Disponível em: <<http://www.grafica.ufrj.br/index.php/maquinas>>. Acesso em: 11 ago. 2016.

JARDINE, A. K. S.; LIN, D.; BANJEVIC, D. A review on machinery diagnostics and prognostics implementing condition-based maintenance. **Mechanical Systems and Signal Processing**, v. 20, p. 1483-1510, nov. 2005.

MARTINS, D. H. C. de S. S.; VIANA, D. P.; PREGO, T. de M.; LIMA, A. A. de; LÓPEZ, R. Z.; NETTO, S. L. Diagnóstico de falhas em máquinas rotativas utilizando *random forest*. **Anais do XXXIV Simpósio Brasileiro de Telecomunicações (SBrT)**, set. 2016.

NEPOMUCENO, L. X. **Técnicas de manutenção preditiva**: volume 1. 6. ed. São Paulo: Blucher, 2013.

NORTON, R. L. **Projeto de máquinas**: uma abordagem integrada. 2. ed. Porto Alegre: Bookman, 2007.

RANDALL, R. B.; ANTONI, J. Rolling element bearing diagnostics: a tutorial. **Mechanical Systems and Signal Processing**, v. 25, p. 485-520, 2011.

SAIDI, L.; ALI, J. B.; FNAIECH, F. The use of spectral kurtosis as a trend parameter for bearing faults diagnosis. **Sciences and Techniques of Automatic Control and Computer Engineering (STA)**. 15th International Conference, p. 394-399, dez. 2014.

SENAI, **Impressora offset**: máquina alimentada a folha. São Paulo: SENAI-SP, 2014.

SOUZA, V. C. D. **Organização e gerência da manutenção**: planejamento, programação e controle de manutenção. 4. ed. São Paulo: All Print Editora, 2011.

WALTER, C. L.; SALLES, A. A. Manutenção preditiva, o caminho para a excelência: uma vantagem competitiva. In: **XIII SIMPEP**, Bauru, SP, Brasil, 06 a 08 nov. 2006.

ZAMBRANO, R. L. **Classificação automática de defeitos em máquinas rotativas**. Projeto Final de Graduação – Universidade Federal do Rio de Janeiro. Rio de Janeiro, Brasil, 2014.