

ANÁLISE DE VIBRAÇÃO EM TURBOMÁQUINAS USANDO TÉCNICAS DE APRENDIZAGEM DE MÁQUINA¹

Iago Modesto BRANDÃO²

Graduando em Engenharia de Controle e Automação
IFSP/Câmpus São Paulo

Cesar da COSTA³

Pós-doutor em Engenharia Mecânica/UNESP
Docente do Departamento de Elétrica
IFSP/Câmpus São Paulo

RESUMO

Este trabalho propõe um método para diagnosticar falhas em turbomáquinas usando técnicas de aprendizagem de máquina. Neste estudo, um algoritmo de máquina de vetores de suporte (SVM, do inglês: *support vector machine*) é proposto para classificar o diagnóstico de falhas de desbalanceamento rotacional no rotor. Recentemente, as máquinas de vetores de suporte (SVM) tornaram-se um dos métodos de classificação mais populares na tecnologia de análise de vibração. A falha de desbalanceamento do eixo é classificada usando máquinas de vetores de suporte. Os dados experimentais foram obtidos a partir de um modelo de turbomáquina de rotor de eixo rígido e mancais flexíveis, desenvolvido no Campus São Paulo do IFSP – Instituto Federal de São Paulo, configuração experimental para o estudo da análise de vibração. Várias situações de falhas de desbalanceamento foram simuladas, diagnosticadas e classificadas com sucesso.

Palavras-chave: Aprendizagem de Máquina; Diagnóstico de Falhas; Análise de Vibração; Classificação de Falhas.

Introdução

A integração de sistemas mecânicos, digitais e de computadores está em constante crescimento na indústria moderna. Nas turbomáquinas, os rotores sofrem desgaste e fadiga devido ao seu uso contínuo, dificultando seu funcionamento ao longo do tempo. Embora tenham uma estrutura robusta, quaisquer imperfeições, por mínimas

¹ Trabalho resultante de Trabalho resultante do Projeto de Final de Curso, Engenharia de Controle e Automação. Orientador Prof. Dr. Cesar da Costa.

² Endereço eletrônico: i_modesto_br@yahoo.com.br

³ Endereço eletrônico: ccosta@ifsp.edu.br

que sejam, comprometem seu desempenho. Os rotores desse tipo de maquinário movem-se em alta velocidade, exigindo o uso de sensores eletrônicos para extrair informações precisas.

Com o tempo, os componentes mecânicos que compõem as turbomáquinas sofrem desgaste e se tornam mais ineficientes, reduzindo gradualmente a qualidade dos processos que integram. De acordo com Bentley (2002), o estresse mecânico excessivo está associado ao movimento rotacional dos eixos, e altas cargas de torção e cargas radiais culminam em condições severas que levam a uma eventual quebra do rotor.

Técnicas com o objetivo de prever situações com a finalidade de determinar a vida útil de um equipamento ou componente estão cada vez mais presentes no ambiente corporativo-industrial, pois isso significa obter a maior vida útil da turbomáquina, garantindo qualidade, gerando trocas programadas, manutenção de componentes e, conseqüentemente, maior controle financeiro do processo. A manutenção preditiva é uma maneira útil de minimizar o tempo de inatividade da máquina e os custos associados (LUO et al, 2018).

Nos últimos 20 anos, o diagnóstico de falhas em turbomáquinas foi realizado por meio de técnicas tradicionais. Muitas vezes, usando-se essas técnicas tradicionais, falhas de rotor não poderiam ser detectadas sem a presença de um especialista. Recentemente, com a evolução das técnicas de inteligência artificial, as falhas de rotor puderam ser diagnosticadas sem a presença de um especialista, reduzindo os custos de manutenção.

A aprendizagem de máquina (em inglês, *machine learning*) é uma técnica de análise de dados que automatiza a construção de modelos analíticos. É um ramo da inteligência artificial baseado na ideia de que sistemas podem aprender com dados a identificar padrões e tomar decisões com o mínimo de intervenção humana.

Ayhan, Chow e Song (2006) propuseram um trabalho denominado Análise de Discriminantes Múltiplos (MDA, do inglês *Multiple Discriminant Analysis*) e um método de redes neurais artificiais (RNAs) para diagnosticar falhas de barras quebradas do rotor. Aydin, Karakose e Akin (2007) usaram métodos de classificação de máquinas de vetores de suporte (SVM) para detectar falhas de barras no rotor. As correntes de fase e o componente vetorial de Park foram utilizados para extrair os recursos de entrada do algoritmo SVM em seu estudo. Razavi-Far et al (2017) propuseram um estudo focado no desenvolvimento de um sistema de diagnóstico baseado em um

conjunto incremental adaptativo de aprendizagem de máquina. O sistema de diagnóstico consistiu em duas unidades principais para processamento de dados e tomada de decisão.

Martin-Diaz et al (2018) realizaram uma avaliação experimental comparativa de técnicas de aprendizagem de máquina usadas para o diagnóstico de falhas de rotor em motores de indução alimentados por inversor de frequência. As características de falhas são calculadas (nos domínios da frequência e do tempo) a partir da corrente elétrica do estator. Os motores foram alimentados por quatro fontes de alimentação diferentes e carregados em dois níveis. Souza et al (2018) propuseram identificar falha de curto-circuito incipiente em geradores elétricos, e foi possível separar 99,4% das condições normais de falhas usando uma técnica denominada Estatística de Alta Ordem (HOS, inglês *High Order Statistics*) como método de extração de características e classificador bayesiano. Samanta (2004) propôs um estudo para comparar o desempenho da detecção de falhas de engrenagem usando redes neurais artificiais (RNAs) e máquinas de vetores de suporte (SMVs). Os sinais de vibração no domínio do tempo de uma máquina rotativa com engrenagens normais e defeituosas foram processados para extração de características

A contribuição deste trabalho foi o desenvolvimento de um modelo de manutenção preditiva automática para o diagnóstico de falhas incipientes de rotor em turbomáquinas, por meio de um modelo de aprendizagem de máquina, baseado em classificação de vetores de suporte (SVMs), que classifica a existência de uma ou mais condições de desbalanceamento no rotor da máquina.

Fundamentação Teórica

Análise de Vibração

Os fundamentos da análise de vibração podem ser entendidos pelo estudo do modelo simples de amortecimento por mola. De fato, mesmo uma estrutura complexa, como uma carroceria de automóvel, pode ser modelada como uma soma de modelos simples de amortecedor (massa e mola). O modelo é um exemplo de um oscilador harmônico simples. Embora várias técnicas sofisticadas possam ser usadas, dois

métodos usados para exibir sinais de vibração são: a forma de onda no tempo (amplitude versus tempo) e o espectro de frequência (amplitude versus frequência). Com base nas características de um sistema, é possível modelar seu espectro de vibração. Para uma dada máquina rotativa, isso incluiria um pico esperado na frequência rotacional fundamental do eixo e picos síncronos (harmônicos) baseados em componentes adicionais, tais como pás do ventilador e engrenagens (HENAO et al, 2014). A Figura 1 mostra o espectro de frequência de Fourier da análise de vibração de uma máquina rotativa.




Figura 1: Espectro de frequência de Fourier
Fonte: Autores

Extração de Recursos

Uma vez que há um conjunto de dados consolidado representando os sinais de vibração no domínio do tempo, é necessário extrair características desses sinais para o domínio da frequência, a fim de reduzir a complexidade do modelo de classificação desenvolvido. De acordo com Shah e Patel (2016), a extração de recursos pode ser definida como um processo de extração de um novo conjunto de dados de um conjunto de dados inicial.

A transformada de Fourier é, em geral, um algoritmo matemático que realiza as transformações entre as variáveis no domínio do tempo para as variáveis no domínio da frequência. A transformada rápida de Fourier é um algoritmo eficiente para o cálculo da transformada discreta de Fourier (DFT, do inglês *Discrete Fourier Transform*) e sua inversa. A transformada rápida de Fourier (FFT, do inglês *Fast Fourier Transform*) é extremamente importante, uma vez que é possível desenvolver aplicações de

processamento digital de sinais para algoritmos de multiplicação de números inteiros (BLAHUT, 2010).

Seleção de Recursos

Após a extração de recursos, é necessário selecionar esses recursos para verificar se todos os recursos são relevantes e incluí-los, ou excluí-los, do modelo de aprendizagem de máquina a ser desenvolvido. Segundo Kursu e Rudnicki (2010), os dados com muitas variáveis são cada vez mais comuns nos problemas de aprendizagem de máquina. Para extrair informações úteis desses altos volumes de dados, é preciso usar técnicas para reduzir o ruído ou os dados redundantes. Nesta etapa a seleção de recursos desempenha um papel importante. Não apenas ajuda a treinar seu modelo mais rapidamente: reduz sua complexidade, facilita a interpretação e melhora a precisão (LUO et al., 2018). Existem três tipos de métodos de seleção de recursos: (i) Métodos de filtro geralmente são usados como uma etapa de pré-processamento. A seleção de recursos é independente de qualquer algoritmo de aprendizado de máquina. Em vez disso, os recursos são selecionados com base em suas pontuações em vários testes estatísticos para sua correlação com a variável de resultado; (ii) Métodos de empacotamento usam um subconjunto de recursos e treinam um modelo usando-os. Com base nas inferências extraídas do modelo anterior, é decidido adicionar, ou remover, recursos do subconjunto; (iii) Métodos incorporados são algoritmos que possuem seus próprios métodos internos de seleção de recursos.

Máquina de Vetor de Suporte – SVM

O SVM é um algoritmo de aprendizado de máquina supervisionado, ou não, com algoritmos de aprendizagem associados, que analisam os dados e reconhecem padrões, utilizados para classificação e análise de regressão. O SVM pega a solução ótima na condição de um pequeno número de amostras. O algoritmo para o SVM transforma o Conjunto Amostral (SS, do inglês *Sample Space*) no Espaço de Recurso de Alta Dimensão (HDFS, do inglês *High Dimension Feature Space*) pela transformação não-linear (MEYER et al., 2003). Além de realizar uma classificação linear, os SVMs

podem executar com eficiência uma classificação não linear usando o que é chamado de *truque do kernel*, mapeando implicitamente suas entradas em espaços de recursos de alta dimensão. A Figura 2 mostra uma classificação linear entre duas classes 1 e 2. A linha H1 não separa as classes. A linha H2 separa, mas apenas com uma pequena margem. A linha H3 separa-os com a margem máxima. O SVM procura maximizar a distância entre os pontos mais próximos em relação a cada uma das classes (AYDIN et al, 2007).




Figura 2: Classificação linear entre duas classes 1 e 2
Fonte: Autores

Para o espaço n-dimensional, os dados de entrada pertencem à classe 1 ou classe 2 e os rótulos associados são -1 para a classe 1 e +1 para a classe 2. Se os dados de entrada puderem ser separados linearmente, o hiperplano de separação poderá ser representado pela Equação 1. Esta equação encontra uma margem máxima para separar a classe positiva da classe negativa (FUQING et al., 2013).

$$f(X) = w^T x + b \quad (1)$$

Onde:

w é o vetor de peso n-dimensional;

b é um multiplicador escalar ou valor de polarização.

A função de decisão é mostrada na Equação 2.

$$f(x) = \text{sgn}(w^T x + b) \quad (2)$$

Se duas classes podem ser separadas linearmente, o hiperplano que satisfaz a margem máxima entre duas classes é encontrado resolvendo-se a Equação 3. Um exemplo para dados linearmente separáveis é mostrado na Figura 2. Quando os parâmetros SVM são bem ajustados, o desempenho da classificação é aumentado (AYDIN et al., 2007).

$$\left\{ \begin{array}{l} \text{Minimize } \frac{1}{2} \|w\|^2 \\ \text{Subject to } y_i (w_i x_i + b) \geq 0 \end{array} \right\} \quad (3)$$

O treinamento SVM é realizado resolvendo-se o problema de otimização na Equação 4.

$$\left\{ \begin{array}{l} \text{Maximize } L(\alpha) = \sum_{i=1}^k \alpha_i - \frac{1}{2} \sum_{i,j=0}^k \alpha_i \alpha_j y_i y_j k(x_i x_j) \\ \text{Subject to } \sum_{i=1}^k y_i \alpha_i = 0 \\ \alpha_i \geq 0 \quad \text{for } i=1 \dots k \end{array} \right\} \quad (4)$$

Onde:

$k(x_i x_j)$ é a função do *kernel*;

α_i são multiplicadores de Lagrange.

Quando os dados não podem ser separados linearmente, o mapeamento da função do *kernel* muda de acordo com a Equação 5.

$$k(x_i, x_j) = k(x_i, x_j) + \frac{1}{C} \delta_{ij} \quad (5)$$

Onde:

C é o parâmetro de penalização. O valor apropriado deste parâmetro aumenta o desempenho da classificação;

δ_{ij} é o símbolo de Kronecker.

Neste trabalho, a função de *kernel* radial é usada, e essa função é dada na Equação 6.

$$k(x_i, x_j) = \exp(-\|x_i - x_j\|^2 / (2\sigma^2)) \quad (6)$$

Onde:

σ é o parâmetro de *kernel*, o qual afeta a complexidade de distribuição de dados no espaço de recurso.

Procedimento Experimental

Nos experimentos, os dados foram coletados de uma bancada de testes (Figura 3), que representa, em escala reduzida, uma turbomáquina real baseada no modelo de Jeffcott (CARBAJAL-HERNANDEZ, 2016). Seu eixo é representado por um rotor e um disco com vários furos para a simulação de desbalanceamento.




Figura 3: Bancada de testes experimentais
Fonte: Autores

A Figura 4 ilustra o disco e os furos onde as massas de testes (pesos) foram inseridas para simulações de falhas de desbalanceamento.




Figura 4: Perspectiva isométrica doAutore
Fonte: Autores

Onze diferentes tipos de testes foram realizados: (i) um não balanceado - N / B (massa de teste não inserida); (ii) dois balanceados diferentes – BLC1 e BLC2 (massas de teste inseridas em posições diferentes) – e (iii) oito desbalanceados diferentes – UBLC1 a UBLC4 (massas de testes inseridas em posições diferentes) –. Os testes realizados estão listados na Tabela 1.

Tipos de Teste	Descrição
N / B	Não balanceado
BLC1	Balanceado
BLC2	Balanceado
UBLC1	Desbalanceado
UBLC1+	Desbalanceado
UBLC2	Desbalanceado
UBLC2+	Desbalanceado
UBLC3	Desbalanceado
UBLC3+	Desbalanceado
UBLC4	Desbalanceado

UBLC4+	Desbalanceado
--------	---------------

Tabela 1: Testes realizados
Fonte: Autores

A arquitetura do sistema é baseada no fluxo de dados, como mostrado na Figura 5, compreendendo desde a etapa de aquisição de dados no rotor em operação, até a apresentação dos resultados numa Interface Homem Máquina (IHM).

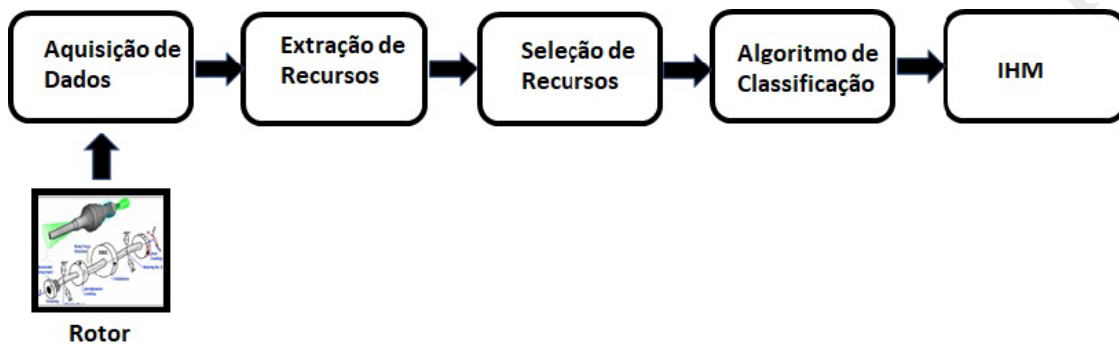


Figura 5: Etapas do algoritmo de aprendizagem de autores
Fonte: Autores

Metodologia e Discussão

Os experimentos consistem em vários módulos de software, que incluem: aquisição de dados, extração de recursos, seleção de recursos, algoritmo de aprendizagem de máquina (SVM), treinamento e apresentação de resultados. A aquisição dos dados de vibração de cada um dos onze testes, como mostrado na Tabela 1, produziu um conjunto de dados correspondente a cada um dos sinais de vibração. Os parâmetros de aquisição para esses testes foram definidos por uma frequência de amostragem de 1KHz e 2000 amostras. A aquisição dos dados da bancada experimental foi realizada de modo que todas as falhas possíveis fossem testadas: (i) não balanceadas, (ii) balanceadas e (iii) desbalanceadas.

Obteve-se 1000 recursos na etapa de extração e usou-se esses recursos como dados de entrada para a etapa de seleção. Obteve-se 60 características confirmadas como importantes para o treinamento do modelo. Depois que o vetor de recursos foi alcançado, vetores de suporte de cada condição foram construídos. A Figura 6 apresenta

o resultado gráfico dos recursos combinados. As amostras de aprendizagem e as amostras de teste para o SVM foram obtidas a partir dos dados experimentais de extração e seleção de recursos em diferentes condições de falha.

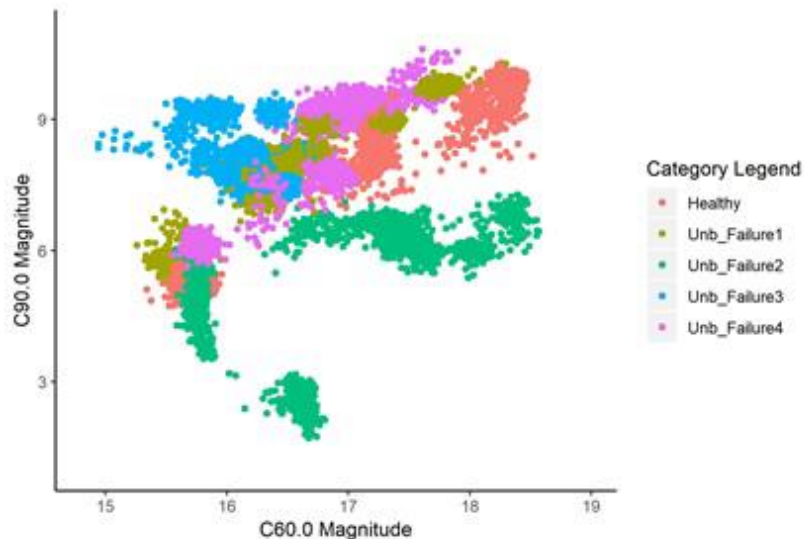


Figura 6: Recursos coconfusão
Fonte: Autores

Os índices derivados de uma matriz denominada matriz de confusão são o parâmetro padrão para avaliar a exatidão da classificação obtida. A matriz de confusão fornece a base para descrever a precisão da classificação e caracterizar os erros, ajudando a refinar a classificação. A partir de uma matriz de confusão podem ser derivadas várias medidas de precisão de classificação, sendo a precisão global uma das mais conhecidas. A matriz de confusão é formada por um arranjo quadrado de números dispostos em linhas e colunas que expressam o número de unidades de amostras de uma categoria relativa inferida por um classificador, ou regra de decisão, em comparação com a categoria atual encontrada no campo. Normalmente, abaixo das colunas, é representado o conjunto de dados de referência, que é comparado com os dados do produto de classificação, que são representados ao longo das linhas. Os principais elementos diagonais indicam o nível de precisão ou concordância entre os dois. Uma vez que o algoritmo SVM foi treinado, a matriz de confusão foi obtida. A Figura 7 apresenta a matriz de confusão obtida para avaliação da exatidão da classificação do sistema desenvolvido.

		True Condition										
		S/F	BLC1	BLC2	DBL1	DBL1+	DBL2	DBL2+	DBL3	DBL3+	DBL4	DBL4+
Predicated Condition	S/F	738	65	8	0	0	0	0	0	0	0	0
	BLC1	55	712	20	0	0	0	0	0	0	0	0
	BLC2	8	24	773	0	0	0	0	0	0	0	0
	DBL1	0	0	0	801	0	0	0	0	0	0	0
	DBL1+	0	0	0	0	651	0	0	0	0	0	0
	DBL2	0	0	0	0	0	801	0	0	0	0	0
	DBL2+	0	0	0	0	0	0	651	0	0	0	0
	DBL3	0	0	0	0	0	0	0	801	0	0	0
	DBL3+	0	0	0	0	0	0	0	0	651	0	0
	DBL4	0	0	0	0	0	0	0	0	0	801	0
	DBL4+	0	0	0	0	0	0	0	0	0	0	651

Figura 7: Matriz de confusão
Fonte: Autores

A Figura 8 mostra a interface homem-máquina (IHM) desenvolvida no software LabView. Ela indica qual evento é mais provável de ocorrer. Por exemplo, a categoria BLC 2 (Balanceada) tem 90% de previsão.

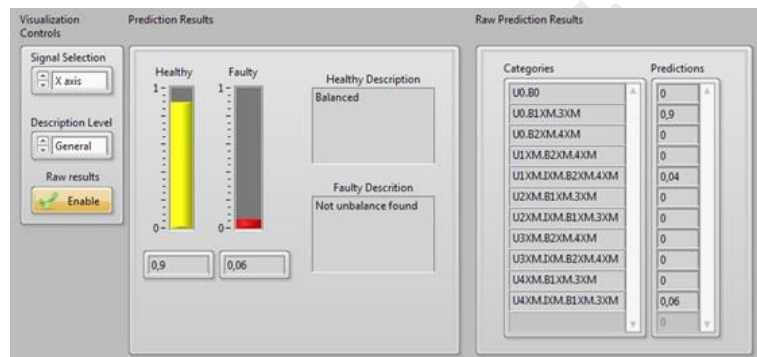


Figura 8: IHM (Interface Homem-Máquina)
Fonte: Autores

Conclusão

Neste trabalho aplicou-se um método de diagnóstico de falhas em turbomáquinas usando as técnicas de aprendizagem de máquina. A falha de desbalanceamento do rotor foi diagnosticada aplicando-se a análise de vibração. O algoritmo SVM foi proposto para a classificação das falhas de desbalanceamento diagnosticadas. Várias situações de falhas de desbalanceamento foram simuladas. Verificou-se que o algoritmo SVM tem um significado prático para a aprendizagem de máquina, no caso de um pequeno número de amostras. A análise de vibrações foi realizada em uma bancada experimental real e os resultados de classificação de diagnóstico de falhas de desbalanceamento foram obtidos com sucesso.

Referências

AYDIN, I.; KARAKOSE, M.; AKIN, E. Artificial immune based support vector machine algorithm for fault diagnosis of induction motors. *In: INTERNATIONAL AEGEAN CONFERENCE ON ELECTRICAL MACHINES AND POWER ELECTRONICS*, 2007, Bodrum. Disponível em: <https://ieeexplore.ieee.org/document/4510505>. Acesso em: 04 jul. 2018.

AYHAN, B.; CHOW, M. Y.; SONG, M. H. Multiple Discriminant Analysis and Neural Network-Based Monolith and Partition Fault-Detection Schemes for Broken Rotor Bar in Induction Motors. **IEEE Transactions on Industrial Electronic**, v. 53, n. 4, p. 1298-1308, 2006. Disponível em: <https://ieeexplore.ieee.org/document/4510505>. Acesso em: 16 mai. 2018.

BENTLY, D. E.; HATCH, C. T.; GRISSOM, B. **Fundamentals of Rotating Machinery Diagnostics**. Minden: Bently Pressurized Bearing Press, 2002.

BLAHUT, R. E. **Fast Algorithms for Signal Processing**. New York: Cambridge University Press, 2010.

CARBAJAL-HERNANDEZ, J. J. et al. Classification of unbalance and misalignment in induction motors using orbital analysis and associative memories. **Neurocomputing**, v. 175, p. 838-850, 2016. Disponível em: <https://www.sciencedirect.com/journal/neurocomputing/vol/175/part/PB>. Acesso em: 28 mai. 2018.

FUQING, Y.; KUMAR, U.; GALAR, D. A comparative study of artificial neural networks and support vector machine for fault diagnosis". **International Journal of Performability Engineering**, v. 9, n. 1, p. 49-60, 2013. Disponível em: <http://www.ijpe-online.com/january-2013-p05-a-comparative-study-of-artificial-neural-networks-and-support-vector-machine-for-faultdiagnosis.html#axzz5kTN9Zjum>. Acesso em: 14 ago. 2018.

HENAO, H., et al. Trends in Fault Diagnosis for Electrical Machines: A Review of Diagnostic Techniques. **IEEE Industrial Electronics Magazine**, v. 8, n.2, p. 31-42, 2014. Disponível em: <https://ieeexplore.ieee.org/xpl/tocresult.jsp?isnumber=6839098&punumber=4154573>. Acesso em: 23 ago. 2018.

KURSA, M. B., RUDNICK, W. R. Feature Selection with the Boruta Package. **Journal of Statistical Software**. v. 36, n. 11, p. 1-13, 2010. Disponível em: <https://www.jstatsoft.org/article/view/v036i11>. Acesso em: 04 set. 2018.

LUO, B. et al. Early Fault Detection of Machine Tools Based on Deep Learning and Dynamic Identification. **IEEE Transactions on Industrial Electronic**, v. 66, n. 1, p.

509-518, 2018. Disponível em: <https://ieeexplore.ieee.org/document/8294247>. Acesso em: 19 set. 2018.

MARTIN-DIAZ, I. et al. An experimental comparative evaluation of machine learning techniques for motor fault diagnosis under various operating conditions. **IEEE Transactions on Industrial Electronic**, v. 54, n. 3, p. 2215-2224, 2018. Disponível em: <https://ieeexplore.ieee.org/document/8281071>. Acesso em: 19 set. 2018.

MEYER, D.; LEISCH, F.; HORNICH, K. The support vector machine under test". **Neurocomputing**, v. 55, n. 1/2, p. 169-186, 2003. Disponível em: <https://www.sciencedirect.com/journal/neurocomputing/vol/55/issue/1>. Acesso em: 05 mar. 2018.

MOLDOVAN, D. et al. Machine learning for sensor-based manufacturing process. *In: IEEE INTERNATIONAL CONFERENCE ON INTELLIGENT COMPUTER COMMUNICATION AND PROCESSING (ICCP)*, 13., 2017, Cluj-Napoca. Disponível em: <https://ieeexplore.ieee.org/document/8116997>. Acesso em: 05 mar. 2018.

RAZAVI-FAR, E.; KINNAERT, M. Incremental design of a decision system for residual evaluation: a wind turbine application. **IFAC Proceedings Volumes**, v.45, n. 20, p. 342-348, 2012. Disponível em: <https://www.sciencedirect.com/journal/ifac-proceedings-volumes/vol/45/issue/20>. Acesso em:

RAZAVI- FAR, R. et al. Adaptive incremental ensemble of extreme learning machines for fault diagnosis in induction motor. *In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS (IJCNN)*, 2017, Anchorage. Disponível em: <https://ieeexplore.ieee.org/document/7966044>. Acesso em: 21 mar. 2018.

SAMANTA, B. Gear fault detection using artificial neural networks and support vector machines with genetic algorithms. **Mechanical Systems and Signal Processing**, v. 18, n. 3, p. 625-644, 2004. Disponível em: <https://www.sciencedirect.com/journal/mechanical-systems-and-signal-processing/vol/18/issue/3>. Acesso em: 28 mar. 2018.

SHAH, F. P.; PATEL, V. A review on feature selection and feature extraction for text classification. *In: INTERNATIONAL CONFERENCE ON WIRELESS COMMUNICATIONS, SIGNAL PROCESSING AND NETWORKING*, 2016, Chennai. Disponível em: <https://ieeexplore.ieee.org/document/7566545>. Acesso em: 06 mar. 2018.

SOUZA, P. H. F. et al. Detection and classification of faults in induction generator applied into wind turbines through a machine learning approach. *In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS (IJCNN)*, 2018, Rio de Janeiro. Disponível em: https://www.researchgate.net/publication/326594864_Detection_and_classification_of_faults_in_induction_generator_applied_in_to_wind_turbines_through_a_machine_learning_approach. Acesso em: 14 mar. 2018.

**VIBRATION ANALYSIS OF ROTARY MACHINES USING MACHINE
LEARNING TECHNIQUES**

ABSTRACT

This study presents a method of diagnosing failures in rotary machines using Machine Learning techniques. In this study, a support vector machine (SVM) algorithm is proposed for fault diagnosis of the rotational unbalance in the rotor. Recently, support vector machines (SVMs) have become one of the most popular classification methods in technique for Vibration Analysis. Axis unbalance fault is classified using support vector machines. The experimental data are taken from a rotary machine model of a rigid-shaft rotor and flexible bearings, experimental setup for the study of vibration analysis. Several situation of unbalance faults were detected successfully.

Keywords: Machine Learning; Fault Diagnosis; Vibration Analysis; Fault Classification.

Envio: março/2019
Aceito para publicação: março/2019