

## Diagnóstico de falhas em redutores mecânicos a partir de dados de acelerômetros e ferramentas de aprendizagem de máquinas

ANDRE L. DIAS<sup>1</sup>, AFONSO C. TURCATO<sup>2</sup>, GUILHERME S. SESTITO<sup>3</sup>, RUI A. M. ARAUJO<sup>4</sup>

<sup>1</sup> Doutor e Mestre em Engenharia Elétrica pela USP, Professor do IFSP Sertãozinho, [andre.dias@ifsp.edu.br](mailto:andre.dias@ifsp.edu.br).

<sup>2</sup> Doutorando em Engenharia Elétrica pela USP, Professor do IFSP Sertãozinho, [afonso.turcato@ifsp.edu.br](mailto:afonso.turcato@ifsp.edu.br).

<sup>3</sup> Doutor e Mestre em Engenharia Elétrica pela USP, Sócio da Toledo&Souza, [guilhermesestito@gmail.com](mailto:guilhermesestito@gmail.com).

<sup>4</sup> Professor do (DEEC) Departamento de Engenharia Elétrica e de Computação da Universidade de Coimbra, [rui@isr.uc.pt](mailto:rui@isr.uc.pt).

Área de conhecimento (Tabela CNPq): 3.04.05.02-5 Automação Eletrônica de Processos Elétricos e Industriais

Apresentado no  
4º Congresso de Pós-Graduação do IFSP  
27 e 28 de novembro de 2019- Sorocaba-SP, Brasil

**RESUMO:** Ferramentas de *condition monitoring* tem sido amplamente empregadas para detecção de falhas em máquinas utilizadas em aplicações industriais. O uso de ferramentas de aprendizagem máquina para extração de informações relevantes de grandes e complexos volumes de dados pode prover sistemas de diagnósticos para detecção prévia de anomalias e a consequente redução dos custos de manutenção. Este trabalho tem por objetivo identificar falhas em redutores mecânicos de velocidade, a partir de dados de acelerômetros. O desempenho do sistema proposto mostra-se satisfatório, destacando-se pela utilização de poucos atributos como entradas para o sistema de diagnóstico.

**PALAVRAS-CHAVE:** *condition monitoring*, aprendizagem de máquinas, redutores mecânicos.

### Diagnosis of mechanical gearbox failures based on accelerometer data and machine learning tools

#### ABSTRACT:

Condition monitoring tools have been widely employed for fault detection in machines used in industrial applications. Using machine learning tools to extract relevant information from large and complex big data could provide diagnostic systems for early anomaly detection, reducing maintenance costs. This work aims to identify failures in gearboxes based on accelerometer information. The performance of the proposed system is satisfactory, standing out the use of few attributes as inputs in diagnostic system.

**KEYWORDS:** *condition monitoring*, machine learning, gearboxes.

### INTRODUÇÃO

Diante da grande quantidade e diversidade de máquinas na indústria de manufatura, torna-se importante a utilização de sistemas de diagnóstico automáticos para o monitoramento, verificação e análise das condições para que foram projetadas. Estes sistemas podem identificar falhas e anomalias na operação, e consequentemente, podem evitar perdas de produção, aumentar a disponibilidade do processo e reduzir custos de manutenção corretiva (DRIF; CARDOSO, 2014; FOURNIER et al., 2015; GHANBARI, 2016).

Este tipo de ferramenta é conhecida como *condition monitoring*, e tem por objetivo a detecção de falhas ou um processo de degradação que tenha apresentado um nível sintomático, provendo indicações de anormalidade antes que uma parada funcional ocorra (VANRAJ et al., 2016).

Neste contexto, muitas estratégias ligadas a inteligência computacional e ferramentas de aprendizagem de máquinas têm sido empregadas para tornar possível a extração de informações relevantes de grandes e complexos volumes de dados gerados pela indústria em seu processo produtivo.

Este trabalho busca identificar falhas na engrenagem de um redutor, a partir de dados de acelerômetros instalados em quatro posições distintas da máquina, por meio de uma metodologia que investiga uma técnica para seleção de atributos e sistemas para reconhecimento de padrões. Dois cenários são investigados, o primeiro com o sistema operando em condição normal ou saudável de operação e o segundo operando em condição anormal, no caso com o redutor apresentando um dente de engrenagem quebrado.

## MATERIAL E MÉTODOS

Os dados utilizados para análise foram de um conjunto de dados de vibração (data set) obtidos a partir de um simulador de diagnósticos de falhas em redutores mecânicos de engrenagens da empresa SpectraQuest. Este banco de dados está disponível na internet através do link <https://openei.org/datasets/dataset/gearbox-fault-diagnosis-data>. A figura 1 apresenta a bancada utilizada na construção do data set.

FIGURA 1. Bancada a qual foi elaborado o data set chamada SpectraQuest's Gearbox Prognostics Simulator (GPS).



O conjunto de dados foi obtido empregando 4 sensores de vibração colocados em quatro direções diferentes. O conjunto de dados foi registrado sob variação de carga de 0 a 90 %. A coleta é realizada em dois cenários distintos: condição de operação saudável e condição com redutor com dente de engrenagem quebrada, a qual se deseja identificar pelo sistema de diagnóstico.

A partir dos dados, as seguintes etapas são desenvolvidas na metodologia proposta para desenvolvimento do sistema de diagnóstico:

### I. Extração de Atributos

A extração de atributos é feita a partir dos sinais de acelerômetros instalados em diferentes posições do redutor. Sinais esses, disponibilizados no banco de dados investigado. As características utilizadas foram baseadas em trabalhos correlatos. Uma vez que elas foram extraídas, formam um vetor que descrevem cada amostra.

A Tabela 1 descreve a totalidade de atributos extraídos dos sinais e suas respectivas equações.

TABELA 1. Lista de atributos extraídos e suas respectivas fórmulas.

Atributo	Descrição	Fórmula
A01-A04	Desvio Padrão	$F_1 = \sqrt{\sum_{i=1}^N \frac{(x_i - \text{média}(x_i))^2}{N - 1}}$
A05-A08	Módulo do maior valor	$F_2 = \max  x_i $
A09-A12	Diferença entre maior e menor valor	$F_3 = \max(x_i) - \min(x_i)$
A13-A16	Entropia	$F_4 = \sum_{i=1}^N \frac{\log(x_i)^2}{N - 1}$
A17-A20	Entropia de Shannon	$F_5 = \sum_{i=1}^N \frac{x_i^2 \log(x_i)^2}{N - 1}$
A21-A24	Kurtosis	$F_6 = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \text{média}(x_i))^4}{\left(\frac{1}{N} \sum_{i=1}^N (x_i - \text{média}(x_i))^2\right)^2}$
A25-A28	Raiz Quadrática Média	$F_7 = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$

## II. Seleção de Atributos

Devido ao grande número de atributos extraídos, o que implica em um grande esforço computacional e *overfitting* dos classificadores, é recomendado que uma técnica de redução de dimensionalidade do problema seja considerada.

Este trabalho utilizou o CFS (*Correlation Based Feature Selection*) que utiliza correlação de Pearson e a heurística mérito para selecionar o conjunto de atributos que possui o maior mérito. Isso implica em atributos altamente correlacionados com a classe e com baixa correlação mútua. Desta maneira, evita-se inserir nos classificadores informações redundantes. Esta estratégia pode ser melhor detalhada em Hall (199).

O valor do mérito pode ser definido conforme Equação 1.

$$MS = \frac{k\bar{r}_{cf}}{\sqrt{k+k(k-1)\bar{r}_{ff}}} \quad (1)$$

Em que  $k$  é o número de atributos selecionados,  $\bar{r}_{cf}$  é o valor médio da correlação entre atributo e classe e  $\bar{r}_{ff}$  é o valor médio da correlação mútua entre atributos.

Quando todos os atributos do conjunto de dados são numéricos, a correlação linear de *Pearson* pode ser empregada (HALL, 1999). O valor da correlação de Pearson pode ser definido conforme Equação 2.

$$r = r_{xy} = \frac{\sum x_i y_i - n\bar{x}\bar{y}}{\sqrt{(\sum x_i^2 - n\bar{x}^2)}\sqrt{(\sum y_i^2 - n\bar{y}^2)}} \quad (2)$$

## III. Sistemas de Inferência (Classificadores)

Classificações para reconhecimento de padrões foram utilizados para a detecção de falha no redutor de velocidade. Este trabalho investigou os algoritmos: kNN (*k-Nearest Neighbor*) apresentado por Aha, Kibler e Albert (1991), RNA (Redes Neurais Artificiais) apresentado inicialmente por McCulloch e Pitts em 1943 e SVM (Support Vector Machine) apresentado por Vapnik (1998).

O classificador kNN é empregado calculando distância euclidiana, investigando valores entre 1e 20 vizinhos. A RNA utilizou modelo Perceptron Multicamadas, com algoritmo de aprendizado Levenberg–Marquardt, investigando duas camadas escondidas com 1 a 20 neurônios. O SVM utilizou margens suaves e função *kernel* tipo gaussiana, empregando otimização destes hiperparâmetros, respectivamente coeficiente de suavização (C) e escala da função Kernell ( $\gamma$ ) entre 0.001 e 1000.

## IV. Análise de Desempenho do Sistema

Para a avaliação dos resultados do sistema diagnóstico gerado a partir desta metodologia alguns indicadores de desempenho foram empregados:

- **Acurácia:** taxa de amostras classificadas corretamente dentre todos os dados analisados, considerando apenas o conjunto de teste;
- **Razão de Falso Positivo:** taxa de amostras saudáveis classificadas como defeituosas;
- **Razão de Falso Negativo:** taxa de amostras defeituosas classificadas como saudáveis;
- **Tempo de execução:** tempo para classificação de uma nova amostra.

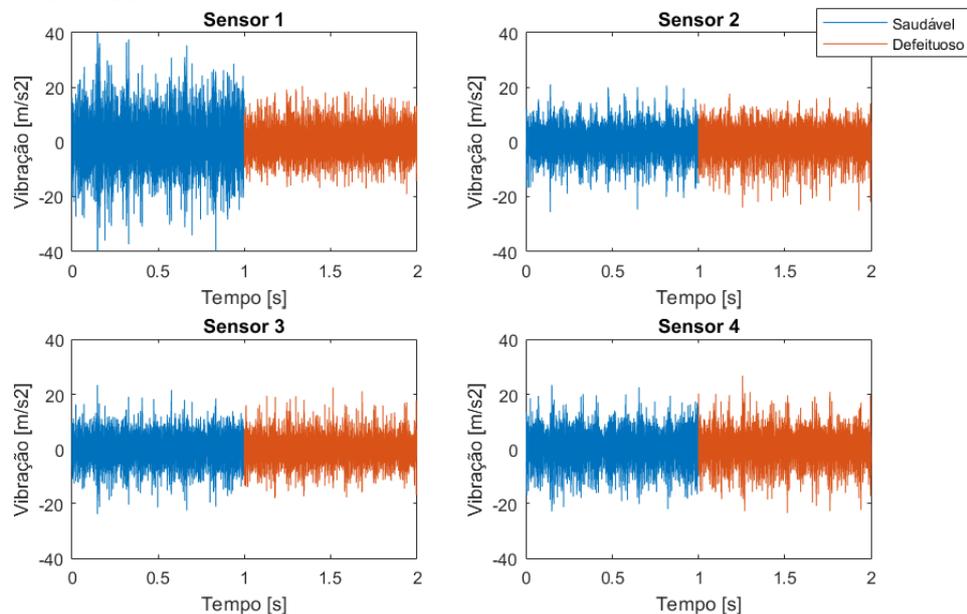
A validação dos resultados obtidos e verificação da capacidade de generalização do sistema foi utilizada a estratégia de validação cruzada para k-partições, conforme apresentado em (SILVA; SPATTI; FLAUZINO, 2010).

O sistema de diagnóstico resultante é composto pela definição dos atributos selecionados, juntamente com o classificador a ser empregado, com hiperparâmetros ajustados de acordo com os dados coletados para seu treinamento.

## RESULTADOS E DISCUSSÃO

A Figura 2 apresenta um exemplo do sinal coletado pelo sensor acelerômetro instalado no corpo do redutor mecânico de velocidade.

FIGURA 2. Sinal de vibração dos sensores instalados na bancada, apresentando sinais de condição saudável e defeituoso.



A partir da extração dos atributos supracitados, gera-se um vetor com as informações da operação da máquina. A Tabela 2 apresenta os resultados dos classificadores.

TABELA 2. Resultados obtidos pelos sistemas de diagnósticos

Atributos	kNN		RNA		SVM	
	Todos	Seleção	Todos	Seleção	Todos	Seleção
Acurácia(%)	99,6(0,3)	92,10(0,6)	99,7(0,20)	93,1(0,9)	99,7(0,20)	92,9(0,8)
RFP(%)	0,6%	39,8	1	35,8	1	41,6
RFN(%)	0,2%	23,4	1	19,6	1,8	15,6
Tempo (ms)	59,9	9,9	12,1	10,6	2,2	8,6
k	16	7	-	-	-	-
n1/n2	-	-	12/7	7/7	-	-
C/γ	-	-	-	-	242,1/4,77	992,6/0,91

Verifica-se pelos resultados que a utilização de todos os atributos, considerando todos os sensores, alcança-se melhores resultados com destaque para RNA e SVM. Porém, quando utilizados atributos selecionados pelo CFS, verifica-se que um único sensor também pode ser capaz de identificar falha no redutor, com desempenho satisfatório, novamente destacando-se os algoritmos RNA e SVM. Em geral verifica-se um menor tempo de execução para o algoritmo SVM, que pode ser considerado, portanto, a melhor alternativa.

## CONCLUSÕES

Os classificadores investigados alcançaram resultados satisfatórios, com destaque para o algoritmo SVM, que além de apresentar altos índices de acurácia, obteve menores valores de tempo de execução. A utilização do algoritmo para redução de atributos foi importante, uma vez que são encontrados resultados satisfatórios utilizando apenas um único sensor, evitando assim custos adicionais para implementação de um sistema de monitoramento da máquina.

## **Agradecimentos**

O prof. Rui Araújo agradece ao Projecto “TOOLING4G - Ferramentas Avançadas para Produção Inteligente” (referência: TOOLING4G/2016/24516) cofinanciado pelo Programa Operacional Competitividade e Internacionalização (COMPETE 2020), Programa Operacional Regional de Lisboa 2014/2020 (LISBOA2020), ortugal 2020 (PT2020), e pela União Europeia através do Fundo Europeu de Desenvolvimento Regional (FEDER).

## **REFERÊNCIAS**

AHA, D. W.; KIBLER, D.; ALBERT, M. K. Instance-based learning algorithms. *Machine Learning*, v. 6, n. 1, p. 37–66, Jan 1991. ISSN 1573-0565. Disponível em: <<https://doi.org/10.1007/BF00153759>>.

DRIF, M.; CARDOSO, A. J. M. Stator fault diagnostics in squirrel cage three-phase induction motor drives using the instantaneous active and reactive power signature analyses. *IEEE Transactions on Industrial Informatics*, v. 10, n. 2, p. 1348–1360, May 2014. ISSN 1551-3203.

FOURNIER, E. et al. Current-based detection of mechanical unbalance in an induction machine using spectral kurtosis with reference. *IEEE Transactions on Industrial Electronics*, v. 62, n. 3, p. 1879–1887, March 2015. ISSN 0278-0046

GHANBARI, T. Autocorrelation function-based technique for stator turn-fault detection of induction motor. *IET Science, Measurement Technology*, v. 10, n. 2, p. 100–110, 2016. ISSN 1751-8822.

HALL, M. A. **Correlation-based Feature Selection for Machine Learning**. april 1999. Tese (Doutorado) — University of Waikato, Waikato, april 1999. Disponível em: <<https://www.cs.waikato.ac.nz>>.

SILVA, I.; SPATTI, D.; FLAUZINO, R. **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas**. [S.l.]: Artliber, 2010. ISBN 9788588098534.

VANRAJ et al. Intelligent predictive maintenance of dynamic systems using condition monitoring and signal processing techniques #x2014; a review. In: 2016 International Conference on Advances in Computing, Communication, Automation (ICACCA) (Spring). [S.l.: s.n.], 2016. p. 1–6.

VAPNIK, V. **Statistical learning theory**. [S.l.]: Wiley, 1998. ISBN 978-0-471-03003-4