

## Técnica de diagnóstico de falhas em motores a combustão interna utilizando aprendizagem de máquina

### Fault diagnosis technique in internal combustion engines using machine learning

Edilson Marinho<sup>1</sup>, Antonio Pinto<sup>2</sup>, Cleiton Formiga<sup>1</sup>, Efrain Pantaleón-Matamoros<sup>2</sup>, Carlos Figueroa-Hernández<sup>3,\*</sup>, Sandra O'Farrill-Enrique<sup>3</sup>, Eurico Seabra<sup>4</sup>

<sup>1</sup>Departamento de Engenharia Mecânica, Instituto Federal de Educação, Ciência e Tecnologia de Maranhão, Brasil.

<sup>2</sup>Escola de Ciências e Tecnologia, Universidade Federal do Rio Grande do Norte, Brasil.

<sup>3</sup>Facultad de Ingeniería Mecánica. Universidad Tecnológica de La Habana “José Antonio Echeverría” (CUJAE). Calle 114 No. 11901 entre Ciclovía y Rotonda, Marianao, La Habana, Cuba.

<sup>4</sup>Departamento de Engenharia Mecânica. Escola de Engenharia Universidade do Minho, Portugal.

\*Autor de correspondencia: carlosrfh@tesla.cujae.edu.cu

Este documento posee una [licencia Creative Commons Reconocimiento/No Comercial 4.0 Internacional](https://creativecommons.org/licenses/by-nc/4.0/)



**Recibido:** 20 febrero 2020 **Aceptado:** 2 marzo 2020 **Publicado:** 9 marzo 2020

#### Resumo

O cenário industrial atual aponta o aumento da competitividade industrial, da complexidade de máquinas e equipamentos, dos custos de instalações industriais, produtos de alta demanda acrescido da preocupação com os aspectos de segurança industrial e do meio ambiente. Tal tendência induz as grandes indústrias globais a cada vez mais investirem em dispositivos, tecnologias e ferramentas destinadas a predição de falhas decorrentes de não conformidades e avarias em máquinas, equipamentos e instalações industriais. Diante desse cenário, o campo de atuação que trata da manutenção preditiva, análise de previsão e diagnóstico de falhas ganhou um lugar de destaque, além de diversos investimentos em pesquisa e desenvolvimento, principalmente com políticas voltadas a concepção da indústria 4.0. Com a abordagem da indústria 4.0 é possibilitada a análise de componentes mecânicos em regime dinâmico e resposta em tempo real, ou seja, sem a necessidade de parar a máquina, o que está diretamente relacionado a diminuição dos custos e tempo de produção. Dito isso, a presente tese tem por objetivo apresentar uma nova metodologia na detecção e monitoramento de falhas tribológicas em motores a combustão interna, por meio da aprendizagem de máquinas por métodos não supervisionados e *big data*, utilizando técnicas de processamento de sinais, dos dados coletados de vibração e nível de pressão sonora do motor, utilizando algoritmos baseados em redes neurais artificiais (RNA) e análise de *clusters*, criando um sistema inteligente capaz de detectar padrões de falhas, a partir das condições de falhas e variação de carga mecânica em motores a combustão interna ciclo *Otto*.

**Palavras-chave:** Tribologia, motores a combustão interna, Aprendizagem de máquina, Big data, Redes Neurais Artificiais, Diagnóstico de falhas.

#### Abstract

The current industrial scenario points to an increase in industrial competitiveness, in the complexity of machinery and equipment, in the costs of industrial installations, in high demand products, in

addition to the concern with aspects of industrial safety and the environment. This trend induces large global industries to increasingly invest in devices, technologies and tools designed to predict failures resulting from non-conformities and breakdowns in machinery, equipment and industrial installations. Given this scenario, the field of action that deals with predictive maintenance, forecast analysis and failure diagnosis has gained a prominent place, in addition to several investments in research and development, mainly with policies aimed at the design of industry 4.0. With the industry 4.0 approach, it is possible to analyze mechanical components in a dynamic regime and respond in real time, that is, without the need to stop the machine, which is directly related to the reduction of costs and production time. That said, the present thesis aims to present a new methodology in the detection and monitoring of tribological failures in internal combustion engines, through machine learning by unsupervised methods and big data, using signal processing techniques, from the collected data engine vibration and sound pressure level, using algorithms based on artificial neural networks (RNA) and cluster analysis, creating an intelligent system capable of detecting fault patterns, based on fault conditions and mechanical load variation in motors internal combustion Otto cycle.

**Keywords:** tribology, internal combustion engines, machine learning, big data, artificial neural networks, fail diagnosis.

## 1. Introdução

Segundo A Mckinsey Global Institute [1], em até 2025, os processos relacionados à indústria 4.0 poderão reduzir os custos de manutenção de equipamentos entre 10% e 40%, a redução do consumo de energia entre 10% e 20% e um aumento entre 10% e 25% da eficiência no trabalho. Ao se tratar dos custos envolvendo efeitos tribológicos em todos os setores estratégicos da sociedade moderna. Jost [2] relatam que cerca de 30% da energia no transporte é usado para vencer o atrito, enquanto na indústria a quantidade corresponde a cerca de 15 a 20%. Em áreas residenciais e outras, a energia usada para superar o atrito é inferior a 10%. Como conclusão geral o estudo demonstra que cerca de 20% da produção de energia no mundo é convertida em efeitos tribológicos.

Investimentos em ensino, pesquisa e aplicação de conceitos de Tribologia contribuiria para a diminuição de custos e perdas nas indústrias, aumento do retorno sobre investimento e no aumento do produto interno bruto (PIB) [3]. O autor relata ainda que com os investimentos nessas áreas seria possível, em valores quantitativos, diminuir aproximadamente: £22 milhões em investimentos devido a maiores taxas de utilização e maior eficiência mecânica; £28 milhões na redução do consumo de energia por meio da redução do atrito; £100 milhões de investimentos para o acréscimo da vida útil de máquinas e equipamentos; £115 milhões em perdas devido a quebras; £230 milhões em custos em manutenção e reposição de peças; £10 milhões em recursos produtivos vinculados a força de trabalho; e £10 milhões com custos com lubrificantes.

As Redes Neurais Artificiais (RNAs) são técnicas computacionais criadas a partir de modelos matemáticos inspirados na estrutura neural de organismos inteligentes e daqueles que adquirem conhecimento através da experiência. Uma grande rede neural artificial pode ter centenas de unidades de processamento, já o cérebro de um mamífero pode ter muitos bilhões de neurônios [4]. Uma Rede Neural Artificial é composta por várias unidades de processamento, os quais são conectados por canais de comunicação denominado pesos. Essas unidades realizam operações sobre os dados de entrada e seus determinados pesos, a fim de transformar esses dados ponderados em uma determinada resposta de saída. O comportamento inteligente de uma RNA vem de interações entre as unidades de processamento da rede [4]. O sinal de entrada ao entrar no neurônio, logo é multiplicado pelo peso sináptico onde ocorre uma junção de todas as entradas já ponderadas

em uma função denominada somatório. Após obter o valor proveniente da função somatório, é necessário definir a função de ativação. Um dado importante para definir a saída de uma RNA é a função de ativação. Geralmente, o estado de ativação dos neurônios se comporta como binário (0 e 1), bipolar (-1 e 1) ou reais.

Quanto à função de aprendizado, Kohonen [5] relata que estas funções servem para realizar a alteração dos valores dos pesos da rede, possibilitando o aprendizado de um determinado padrão. Aguiar e Oliveira [6] afirmam que o aprendizado de uma rede consiste no ajuste de seus parâmetros dado uma apresentação de conjuntos de padrões específicos. Os padrões de treinamento contêm as informações desejáveis para que uma rede aprenda. Os parâmetros a ajustar são os pesos das conexões que interligam os neurônios. Haykin [7] descreve alguns passos que devem ser seguidos para a adequada aplicação da abordagem neural, sendo os seguintes passos: Coleta de dados; Separação em subconjuntos; Configuração da rede; Treinamento; Teste.

O *Self-Organizing Map-SOM*, também chamado de Mapa de Kohonen, é um tipo de Rede neural artificial treinada por aprendizagem competitiva não-supervisionada que se baseia em princípios de auto-organização de dados, que permite a representação de dados multidimensionais em *Clusters* [5]. O Mapa de Kohonen é baseado na aprendizagem competitiva, em que os neurônios da grade competem entre si no intuito de serem ativados ou disparados, resultando em apenas um neurônio de saída, ou um neurônio por grupo. O neurônio de saída vencedor da competição é chamado *neurônio leva tudo* ou *neurônio vencedor*. O self-Organizing Map é caracterizado pela criação de um mapa topográfico dos padrões de entrada, no qual os neurônios da grade são indicativos das características estatísticas dos padrões de entrada. As redes *SOM* têm a capacidade de transformar um sinal de entrada de dimensão randômica em um mapa discreto uni ou bidimensional, realizando transformações de forma topologicamente organizada [7].

Castro [8] elucida que, na aprendizagem competitiva, os neurônios da camada de saída competem pelo direito de permanecerem ativos para um determinado estímulo de entrada. Com isso ao final, apenas uma unidade permanecerá ativa para aquele determinado dado de entrada.

O mapa auto-organizável de Kohonen é uma ferramenta amplamente utilizada em diversas aplicações da ciência como para modelos e métodos paramétricos de estimação no controle da vibração de um piezoelétrico flexível pneumático com controle proporcional derivativo, obtendo vários modelos lineares locais, quando a dinâmica do sistema pneumático demanda uma alta não-linearidade [9]. Utilizada no diagnóstico de falhas em motores de indução, por meio da observância e classificação das principais falhas mecânicas e elétricas ocorridas durante o funcionamento do sistema, utilizando métodos de análise de dados acústicos, baseados na transformada Wavelet e análise de correlação, em sinergia com o Mapa Auto-Organizável de Kohonen para classificação dos tipos de falhas [10].

O mapa auto-organizável (SOM) de Kohonen também se mostra uma ferramenta usual no monitoramento do desgaste. Yen *et al.* [11] utilizaram a SOM para o monitoramento do desgaste de ferramentas baseadas em sinais de emissão relacionada a um processo de micro-fresagem, aliando técnicas de processamento de sinais direcionados a Transformada Rápida de Fourier com a utilização de uma rede Learning Vector Quantification (LVQ) na avaliação dos efeitos do algoritmo SOM no desempenho de classificação para o monitoramento do desgaste da ferramenta.

No trabalho de Huang *et al.* [12] foi trabalhado a abordagem do Mapa Auto-Organizável (SOM), juntamente com a rede *Backpropagation*, para a previsão de vida residual de rolamentos de esfera utilizando o sinal de vibração no domínio tempo e ,com uso do detector envelope para entrada do sinal, no domínio frequência, posteriormente a normalização dos sinais alimentaram a rede neural SOM. Com a saída dos vetores da SOM, foi utilizado o indicador Minimum Quantisation Error (MQE) para posterior interpolação dos valores da MQE e alimentação da rede neural Backpropagation. Logo em seguida da execução do modelo de previsão Backpropagation foi

utilizado a tecnologia weight application to failure times (WAFt) para finalmente obter a predição da vida do rolamento, baseado no monitoramento da degradação do elemento de máquina por meio do sinal de vibração.

Wong [13] foi utilizado o Mapa Auto-Organizável modificado para detecção automatizado do monitoramento das condições de máquina (MCM) usando sinal de vibração processado a partir da técnica de densidade espectral de potência. Experimentos usando conjuntos de dados de vibração com até oito sensores mostraram alta precisão na classificação e robustez em diferentes aplicações de monitoramento das condições.

Yang [14] utilizou a teoria da ressonância adaptativa (ART) em conjunto com a rede neural de Kohonen para o diagnóstico de falhas em máquinas rotativas, por meio do tratamento dos sinais de vibração e em comparação com a SOM, LVQ e RBF (função de base radial), tendo uma taxa de sucesso de 100%, enquanto as demais foram de 93% para a SOM, 93% para LVQ e 89% para a RBF. In Ref. [15] foi utilizado a rede SOM para identificação do estado do desgaste da ferramenta de usinagem, por meio da coleta dos sinais de vibração e deformação, cujo tratamento do sinal foi realizado em domínio frequência e com uso do pacote de análises Wavelet. Foram utilizados dois conjuntos de ferramentas para teste da rede e um terceiro conjunto para validação.

O trabalho tem por objetivo apresentar uma nova metodologia na detecção e monitoramento de falhas tribológicas em motores a combustão interna, por meio da aprendizagem de máquina pelo método não supervisionado e big data, através de técnicas de processamento de sinais aliadas a algoritmos de redes neurais artificiais (RNA) e análise de clusters. O restante do artigo está disposto das seguintes etapas. A seção 2 tem início com a descrição do desenvolvimento do sistema, explicando os métodos de transformação de sinal e processamento de recursos, como também a modelagem do Mapa Auto-Organizável. A seção 3 se trata dos conjuntos de dados experimentais, onde está descrito o desenvolvimento da bancada de análise tribológica em motores a combustão interna, a preparação dos corpos-de-prova, procedimento experimental e as técnicas de análise dos dados. A seção 4 apresenta os resultados experimentais. Finalmente a seção 5 com as conclusões.

## **2. Desenvolvimento do sistema**

Os sinais de vibração e nível de pressão sonora obtidos do motor a combustão interna incluem não apenas informações relacionadas ao desempenho termodinâmico do sistema, mas também informações geradas a partir das condições tribológicas dos elementos em contato. Portanto, desenvolvendo um algoritmo capaz de selecionar os recursos relacionados à condição de falha e classificar com precisão o tipo de recurso que está ativando no momento de ocorrência, é de extrema importância para o monitoramento da condição de falhas no sistema. Este estudo integra algoritmos de processamento de sinal e algoritmos de mapeamento auto-organizável (SOM) para identificar os conjuntos de neurônios que ativam em determinada condição de falha. Para verificar o desempenho da SOM, o algoritmo de clusterização pelo método de Ward's foi adotado para design de classificador e os resultados foram comparados com a rede neural por meio de uma matriz confusão, onde a rede foi treinada e validada.

### **2.1 Transformação de sinal e processamento de recursos**

Os sinais coletados foram no domínio tempo, onde esses foram transformados em sinal de domínio frequência por meio da Transformada Rápida de Fourier. Devido à limitação do uso da ferramenta Transformada Rápida de Fourier (FFT) em sistemas cujo sinal é não-periódico. Os sinais no domínio frequência foram divididos em intervalos, relativos às bandas de oitavas de frequência, onde foi extraído a energia do sinal para cada banda.

## 2.2 Self-Organizing Maps

O algoritmo responsável pela criação do Self-Organizing Map surge primeiramente iniciando os pesos sinápticos  $W$ , de todos os neurônios da rede, definidos como  $W = [W_1, W_2, \dots, W_n]^t$ , inicialmente atribuídos a valores aleatórios. A partir da iniciação da grade, são realizados três passos para a formação do Self-Organizing Map: a competição, cooperação e adaptação sináptica.

Para modelar o processo competitivo, considere um vetor de entrada  $X$  em que  $m$  represente a dimensão do espaço de entrada de dados. O vetor peso sináptico do neurônio  $j$  seja representado por  $W_j = j = 1, 2, \dots, l$ , onde  $l$  é o número total de neurônios na grade. Lembrando que, o vetor sináptico de cada neurônio deve possuir a mesma dimensão vetorial que o espaço de entrada. Após isso, compare os produtos internos  $w_j^T x$  para  $j = 1, 2, \dots, l$  para cada neurônio e selecione o maior. Com isso teremos a localização onde a vizinhança topológica dos neurônios excitados deve ser centrada.

A maximização do produto interno é matematicamente equivalente a minimização da distância euclidiana entre os vetores  $x$  e  $w_j$  encontrando o índice  $i(x)$ , dado pela equação (1).

$$i(x) = \operatorname{argmin}_j \|x - w_j\|, j = 1, 2, \dots, l \quad (1)$$

O neurônio  $i$  que melhor satisfaz a condição é denominado *neurônio vencedor*, ou *Best Matching Unit (BMU)*, para o vetor de entrada  $x$ . Dependendo da aplicação, a resposta da grade pode ser tanto o índice do neurônio vencedor quanto o vetor de peso sináptico mais próximo do vetor de entrada. Ao se tratar da modelagem do processo cooperativo é necessário ter conhecimento que o *neurônio vencedor* se localiza no centro de uma vizinhança topológica de neurônios cooperativos e que a excitação do *neurônio vencedor* altera fortemente os neurônios posicionados em sua vizinhança imediata, fazendo com que a distância lateral dos neurônios em torno do *neurônio vencedor* decaia suavemente. A vizinhança topológica  $h_{ji}$  entre o *neurônio vencedor*  $i$  e o conjunto de neurônios excitados  $j$  pode ser modelada a partir da função *gaussiana*:

$$h_{ji} = \exp\left(\frac{-d_{j,i}^2}{2\sigma^2}\right)$$

Em que  $d_{j,i}$  representa a distância lateral e  $h_{ji}$  é uma função unimodal da distância  $d_{j,i}$ , desde que a vizinhança  $h_{ji}$  seja simétrica em relação ao ponto máximo definido por  $d_{j,i} = 0$ , e a amplitude a vizinhança topológica  $h_{ji}$  decresça monotonamente com o aumento da distância lateral  $d_{j,i}$ . A distância lateral  $d_{j,i}$  para uma grade unidimensional pode ser dada a partir de um inteiro igual a  $|j - i|$ , já para uma grade bidimensional a distância lateral é definida como  $d_{j,i} = |r_j - r_i|_2$  em que  $r$  representa o vetor discreto do neurônio excitado  $r_j$  e do *neurônio vencedor*  $r_i$ . Uma característica importante da SOM é que o tamanho da vizinhança topológica diminui com o tempo, se considerarmos que a largura efetiva  $\sigma$  tenha como parâmetro dependente o tempo discreto, temos um decaimento exponencial expresso por equação (2).

$$\sigma_{(n)} = \sigma_0 \exp\left(\frac{-n}{\tau_1}\right), n = 0, 1, 2, \dots \quad (2)$$

Com isso a modelagem da vizinhança topológica  $h_{ji}$  diminui de maneira correspondente ao aumento do tempo  $n$  e com o decréscimo exponencial da largura efetiva  $\sigma$ . Como visto na equação (3).

$$h_{j,i(x)}(n) = \exp \quad (3)$$



Por fim temos o processo adaptativo sináptico na formação de um *Self-Organizing Map* e suas características. É necessário lembrar que para que a grade seja auto-organizável, é preciso que o vetor de peso sináptico  $w_j$  do neurônio  $j$  da grade se modifique em relação ao vetor de entrada  $x$ . Para que seja satisfeita a condição da hipótese Hebbiana para aprendizagem não-supervisionada é necessário incluir um termo de esquecimento -  $g(y_j)w_j$ , em que  $g(y_j)$  é uma função escalar positiva de  $y_j$  e que  $w_j$  se o peso sináptico do neurônio  $j$ . Sendo exigido que  $g(y_j) = 0$  para  $y_j = 0$ .

Com isso, é possível expressar a modificação do vetor peso do neurônio  $j$  da grade a partir do termo Hebbiano ( $\eta y_j x$ ) e o termo de esquecimento ( $g(y_j)w_j$ ), como visto na equação (4):

$$\Delta w_j = \eta y_j x - g(y_j)w_j \quad (4)$$

Em que  $\eta$  é o parâmetro da taxa de aprendizagem do algoritmo. Considerando  $g(y_j) = \eta y_j$  e  $y_j = h_{j,i(x)}$ , temos que:

$$\Delta w_j = \eta h_{j,i(x)}(x - w_j)$$

Com isso, temos que o vetor de peso atualizado  $w_j(n+1)$  é definido pela equação (5):

$$w_j(n+1) = w_j(n) + \eta(n)h_{j,i(x)}(n)(x - w_j(n)) \quad (5)$$


O qual é aplicado em todos os neurônios da vizinhança topológica do *neurônio vencedor*. Conforme observado na equação do peso atualizado, o parâmetro da taxa de aprendizagem é variável no tempo e corresponde a uma aproximação estocástica, satisfação essa que pode ser atendida utilizando um decaimento exponencial para  $\eta(n)$ , como consta na equação (6):

$$\eta(n) = \eta_0 \exp\left(\frac{-n}{\tau_2}\right), n = 0, 1, 2, \dots \quad (6)$$

### 3. Experimental data sets

#### 3.1. Ensaios tribológicos em motor a combustão interna

Os dados experimentais utilizados neste trabalho foram retirados de uma bancada de ensaios tribológicos em motores a combustão interna. A Fig.1 mostra o layout da máquina, a qual consiste em um motor a combustão interna ciclo Otto acoplado, no eixo do virabrequim, a um gerador monofásico, cuja solicitação de carga foi proveniente de um banco resistivo. Anéis de segmento e as válvulas de escape danificadas foram inseridas no motor, e sua vibração e nível de pressão sonora foram medidos por um acelerômetro e um decibelímetro através de um módulo de aquisição de sinal.



**Fig.1. Layout da bancada de ensaios tribológicos em motores a combustão interna**

O motor a combustão interna ciclo Otto é do tipo estacionário, de marca NMG65 Nagano, com uma potência de 6,5 hp, 196 cilindradas e taxa de compressão de 8.5:1. O gerador é monofásico de dois polos, de marca FG-2500, cuja potência nominal é 2,4 kW com sistema regulador de tensão e um dispositivo proporcional com a frequência da rede, que mantém a rotação do motor a uma faixa constante próximo de 3600 rpm. O banco resistivo de 2 kW é munido de dez lâmpadas fluorescentes de 250 W.

O sistema de instrumentação para coleta dos sinais de vibração e nível de pressão sonora, consistiu no uso de um transdutor de vibração de marca B&K com sensibilidade de 9,931 mv/g e um decibelímetro de marca SKDEC-02 com a taxa de aquisição de 8KS/s, os quais foram ligados aos módulos de vibração NI 9233 com conversor analógico de 24 bits e o módulo de tensão NI 9205, ambos da empresa *National Instruments*. Foram ainda acoplados a um conversor A/D NI cDAQ-9178 da *National Instruments*.

O sensor de vibração foi acomodado ao parafuso do cabeçote do motor o sensor de vibração magnético, próximo aos sistemas de acionamento das válvulas e das aletas do cilindro (em orientação axial ao movimento do pistão do motor a combustão interna). Já o decibelímetro foi fixado próximo a região do cilindro do motor.

### 3.2. Preparação de amostras

Nesta etapa serão descritos os procedimentos na elaboração dos corpos-de-prova que simulam o desgaste nos anéis de segmento e na válvula escape, a partir da simulação do desgaste radial dos anéis de segmento, da simulação de folga entre o guia e haste da válvula e o desgaste da haste da válvula.

#### 3.2.1. Anel de segmento

Para a análise de modos de falhas tribológicas nos anéis de segmento, foi introduzida falha no anel de compressão corta-fogo, com o intuito de captar as assinaturas de falhas para aprendizagem e reconhecimento da rede neural. Dessa forma, pôde ser simulada uma das principais falhas apresentadas: o desgaste radial.

Para simular o desgaste radial do anel de segmento de compressão tipo corta-fogo, foi realizado um corpo-de-prova, desgastado na região de abertura do anel de segmento. O anel de compressão foi desgastado na dimensão aproximada à dimensão do limite de uso do dispositivo, segundo a especificação do manual de serviços da Honda, levando em consideração que o motor Honda GX200 possui características similares ao motor utilizado nos ensaios.

Posterior ao desbaste, foi então mensurada a abertura do anel de segmento com o uso de um calibrador de folga 0,05-1 mm da Vonder, com o anel inserido a 5 mm no interior do cilindro. A Fig.2 mostra o método de análise para a medição da abertura do anel de segmento.

Segundo o Manual Honda de padrões de manutenção do motor GX200 (similar ao NMG65) a folga das extremidades dos anéis de compressão deve possuir um padrão de até 0,4 mm e seu limite de uso de 1 mm. O Quadro 1 evidencia as medidas de dimensões nominais dos anéis de segmento, dimensões do desgaste e a medida contida no manual tomado por base.


#### 3.2.2. Válvula de escape

O presente estudo tem como uma das metas estudar a influência do desgaste no par tribológicos guia de válvula-haste da válvula, por meio da folga entre os contatos desses elementos e a perda diametral da haste das válvulas de admissão e escape. Para simular a folga entre o guia de válvula e a haste da válvula foi desenvolvido um corpo-de-prova para a válvula de escape, tendo por base o Manual de Serviços Honda do motor GX200. O mesmo especifica o limite de uso de folga da haste,

sendo 0,12 mm para a válvula de escape. O método usado para simular o efeito da folga foi a partir do desgaste da haste da válvula, por meio de lixamento.

**Quadro 1. Dimensão do corpo-de-prova, relacionando as dimensões nominais, dimensões de desgaste, dimensões da abertura radial do anel de segmento e os dados do Manual Honda**

Anel de compressão corta-fogo				
Dimensão nominal	Dimensão da abertura padrão	Dimensão desgaste	Dimensão da abertura com desgaste	Limite de uso
7,00 mm	0,25 mm	$7,85 \pm 0,03$ mm	0,85 mm	1,00 mm



**Fig.2 Técnica de medição da abertura radial do anel de segmento utilizando calibrador de folga**

Já para simulação da perda diametral externa da haste, foi desenvolvido um corpo-de-prova para válvula de escape, utilizando também como base o Manual de Serviços Honda do motor GX200, que especifica o limite de uso do diâmetro externo da haste da válvula como sendo, 5,275 mm para a válvula escape. A introdução da falha foi por meio do lixamento da região da haste das válvulas. O Quadro 2, mostra os valores quantitativos das dimensões nominais de projeto, dimensão dos corpos-de prova e limites de uso das válvulas de admissão e escape segundo o Manual Honda.

Para determinação da dimensão desgaste dos corpos-de-prova, foi utilizado um micrometro analógico de resolução 0,01 mm, 0-25 mm de marca MITUTOYO, mensurando cinco vezes no mesmo ponto e posteriormente retirado a média e o desvio-padrão.

### 3.3. Procedimento experimental

Todos os procedimentos utilizados para a coleta dos dados tanto das condições de não conformidade quanto das condições originais do motor a combustão interna foram aquiridos sob as determinadas condições:

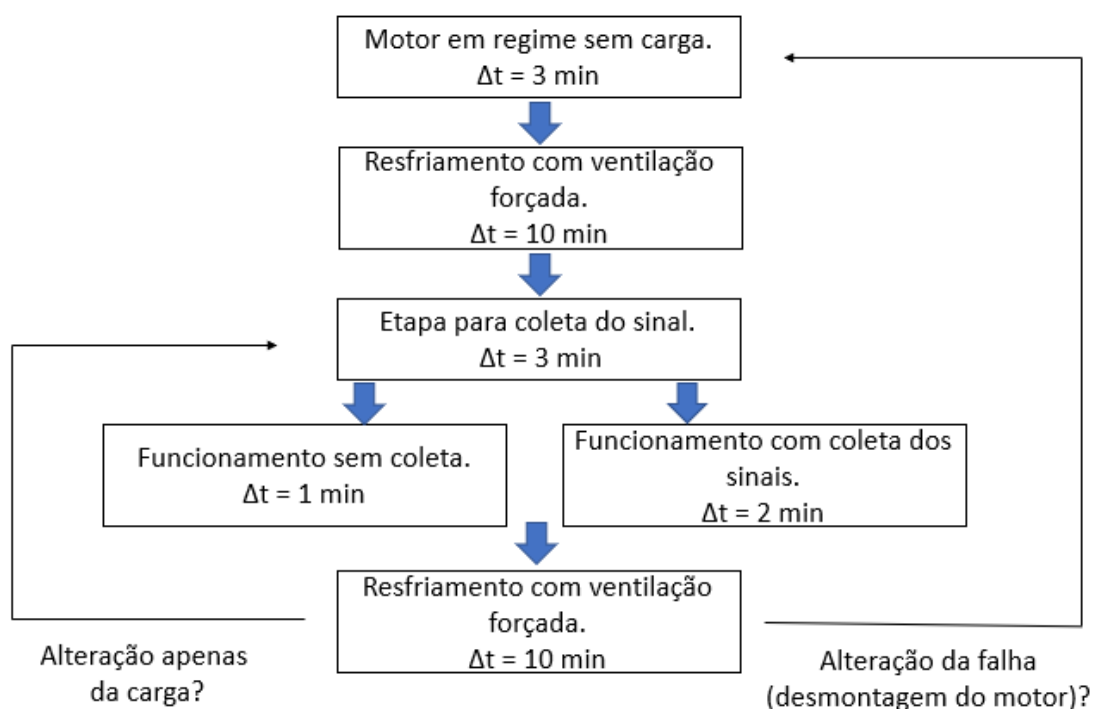
- Regime dinâmico em carga resistiva de 0 kW, 0,5 kW, 1 kW e 1,5 kW.
- Duração de 120 segundos.
- Taxa de aquisição de 8 KHz para os instrumentos principais.



**Quadro 2. Dimensões dos corpos-de-prova, relacionando as dimensões nominais, dimensões com desgaste, dimensões de folga e os dados de limite de uso do Manual Honda**

Válvulas de escape			
Folga da Haste/guia de válvula			
Diametro nominal da haste	Diametro da haste com desgaste	Dimensão da folga haste/guia com desgaste	Limite de uso
5,44 mm	5,39 ± 0,01 mm	0,09 ± 0.01 mm	0.12 mm
Diâmetro Externo			
Diametro nominal da haste	Diametro da haste com desgaste	Dimensão da folga	Limite de uso
5,44 mm	5,25 ± 0,01 mm	-	5.275 mm

No referente as condições iniciais de cada ensaio, para efeitos metodológicos e para a padronização das coletas de dados e condições de termodinâmicas do motor a combustão interna. Foi desenvolvido um protocolo experimental de forma a garantir padrões de repetibilidade e reprodutibilidade de coleta. O protocolo experimental pode ser representado segundo a Fig.3.



**Fig.3 Protocolo do procedimento de ensaio**

A primeira etapa do protocolo consiste em acionar o motor em regime sem carga, por um período de três minutos. Em seguida o motor é resfriado, com uso de um ventilador ilustrado na Fig.3, durante dez minutos. Após essa etapa, a bancada é novamente acionada durante três minutos, sendo um minuto dado apenas para atuação em regime (sem coleta do sinal) e dois minutos de coleta de dados, logo após mais dez minutos de resfriamento do motor e a repetição dos processos mencionados para uma nova coleta de dados.

Os ensaios foram realizados com o equipamento em operação normal e em três condições de falhas (folga entre o guia e a haste da válvula de escape, desgaste da haste da válvula de escape e desgaste radial do anel de segmento compressão), variando sua carga em 0 kW, 0,5 kW, 1 kW e 1,5 kW, totalizando de 16 experimentos, descritos no Quadro 3, cada um com 1.024.000 milhões amostras de coleta de vibração e 1.024.000 milhões amostras de coleta de nível de pressão sonora.

**Quadro 3. Descrição dos experimentos**

<b>Experimento 1</b>	<b>Condição sem falhas e sem carga</b>
Experimento 2	Condição sem falhas e carga de 0,5 kW
Experimento 3	Condição sem falhas e carga de 1 kW
Experimento 4	Condição sem falhas e carga de 1,5 kW
Experimento 5	Condição de falha tipo folga entre a válvula de escape - guia de válvula e sem carga
Experimento 6	Condição de falha tipo folga entre a válvula de escape - guia de válvula e com carga de 0,5 kW
Experimento 7	Condição de falha tipo folga entre a válvula de escape - guia de válvula e carga de 1 kW
Experimento 8	Condição de falha tipo folga entre a válvula de escape - guia de válvula e carga de 1,5 kW
Experimento 9	Condição de falhas tipo desgaste na haste da válvula de escape e sem carga
Experimento 10	Condição de falhas tipo desgaste na haste da válvula de escape e carga de 0,5 kW
Experimento 11	Condição de falhas tipo desgaste na haste da válvula de escape e carga de 1 kW
Experimento 12	Condição de falhas tipo desgaste na haste da válvula de escape e carga de 1,5 kW
Experimento 13	Condição de falha tipo desgaste radial do anel de segmento compressão e sem carga
Experimento 14	Condição de falha tipo desgaste radial do anel de segmento compressão e carga de 0,5 kW
Experimento 15	Condição de falha tipo desgaste radial do anel de segmento compressão e carga de 1 kW
Experimento 16	Condição de falha tipo desgaste radial do anel de segmento compressão e carga de 1,5 kW

### 3.4 Técnicas de Análise de Dados

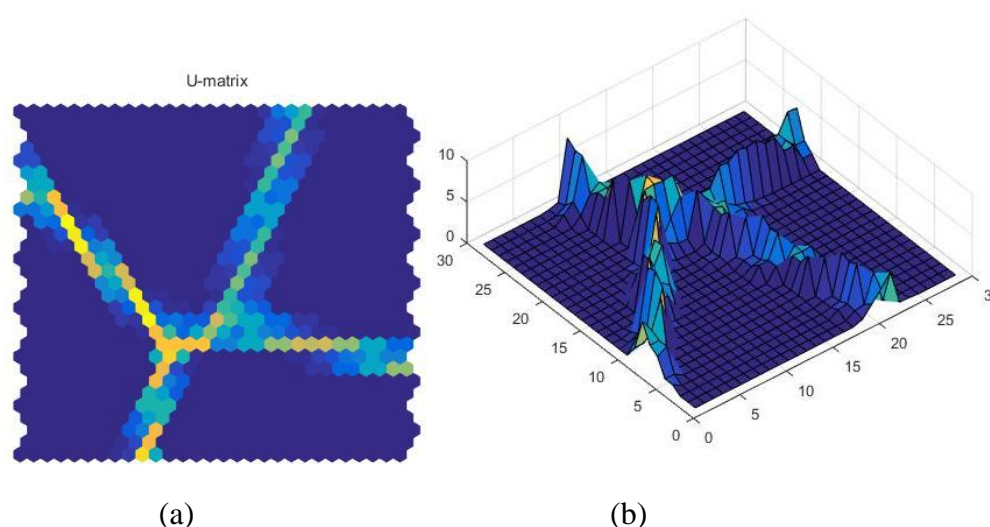
As técnicas de análise de dados foram divididas em sete etapas: etapa de aquisição de sinal, domínio frequência, etapa de densidade de frequência, etapa da rede neural: análise global, etapa de clusterização, etapa de associação e etapa de classificação/validação, conforme a Fig.4. Na etapa de aquisição do sinal, foram coletados os sinais de vibração, nível de pressão sonora. Os sinais de vibração e nível de pressão sonora foram coletados em uma taxa de amostragem de oito mil pontos por segundo (8 kHz). O tempo de aquisição total foi de 120 segundos (1.024.000 amostras por sensor), com início da coleta após sessenta segundos do funcionamento do motor em regime (com carga ou sem carga).

Posterior a etapa de aquisição dos sinais foi realizada a etapa de domínio frequência, onde as amostras coletadas (vibração e nível de pressão sonora) foram tratadas no domínio frequência, com

a realização da Transformada Rápida de Fourier (FFT) a cada dois segundos de aquisição, totalizando sessenta espectros de frequência para cada ensaio. Os dados de desempenho foram coletados nos 120 segundos, totalizando 60 pontos por ensaio.

Na terceira etapa, etapa de densidade de frequência, cada espectro de vibração e nível de pressão sonora foram submetidos a janelamentos de frequência baseados nas 10 primeiras bandas de oitavas de frequência do sinal, são elas: 3-6, 6-12, 12-24, 24-48, 48-96, 96-192, 192-384, 384-768, 768-1536, 1536-3072 Hz. As quais após separadas foram extraídos os valores da energia de cada janela de frequência, por meio do valor Root Mean Square (RMS). Totalizando uma matriz de 60x20 (bandas de oitavas de frequência dos sinais de vibração e nível de pressão sonora) para cada ensaio. A formula utilizada para o cálculo do valor da energia do sinal discreto RMS foi:

$$Erms = \sqrt{\frac{1}{n} \sum_{i=1}^n X_i^2}$$



**Fig.4 Exemplo de Matriz U (a) bidimensional e (b) tridimensional dos dados coletados das falhas em uma condição de carga**

A figura ilustra as etapas dos tratamentos dos sinais de vibração e nível de pressão sonora. A etapa da rede neural consistiu no uso de uma rede neural não-supervisionada de Kohonen, conhecida como Self-Organizing Map (SOM), que desenvolve um mapa a partir do grau de similaridade dos neurônios, baseados no vizinho mais próximo e neurônio vencedor. O Software utilizado para tratamento dos sinais e aplicação da rede neural foi o MatLab 2016. Foram utilizados 66,6% dos dados coletados para treinamento da rede neural e 33,3% para certificação e confiabilidade do mapa de Kohonen. A matriz U foi composta de uma matriz de 15x15 neurônios hexagonais, utilizando sistema linear para inicialização dos pesos e método gaussiano para o cálculo de vizinhança.

Na análise global dos resultados, foi gerado um mapa de Kohonen bidimensional e tridimensional, baseado na matriz U do mapa auto-organizável de Kohonen, que relacionava todas as falhas em todas as cargas, para as matrizes de oitavas de vibração e nível de pressão sonora, através de uma matriz treinamento geral de 640x20 dados. A Fig.4 evidencia um exemplo de matriz U bidimensional e tridimensional dos dados de falhas em uma condição de carga. As figuras (a) e (b) mostram a distribuição de neurônios de matriz 15x15, os quais quanto maior os tons de azul, mais similaridade os neurônios possuem. Diferentemente, quanto mais a cor do neurônio tende ao vermelho, mais o comportamento do neurônio diverge dos demais.

A matriz U tridimensional trás consigo uma melhor maneira de entendimento quanto as fronteiras de subconjuntos originados pelos neurônios, por se assemelhar com um mapa topográfico, é possível identificar as zonas de grupos, bem como a relação de semelhança por meio da topografia

de fronteira. Indicando que, quanto maior a topografia de fronteira, maior as cores do neurônio se aproximam do vermelho, em consequência maior o grau de dissimilaridade entre os grupos vizinhos.

A etapa de clusterização consistiu na mineração dos dados dos neurônios da matriz U para cada condição de carga e condição geral utilizando o método de Ward's, com o objetivo de criar subconjuntos de neurônios baseados na decodificação de padrões por tipos de falhas.

A Etapa de associação foi marcada pela nomeação dos agrupamentos encontrado pela clusterização, com as condições de falhas inseridas no ensaio. Esta etapa tratou de um procedimento supervisionado, gerado a partir de uma matriz confusão entre os dados reais de treinamento das condições de falhas, rotulados em 160 pontos divididos pelos números de condições de falhas, com os dados preditivos originados a partir da normalização dos dados da rede neural.

Com os dados da matriz confusão foi possível gerar uma tabela de relação entre os subconjuntos dos neurônios e as condições de falha do motor. Posteriormente foi plotado a Matriz U identificando os subconjuntos de neurônios por cores, sendo cada condição de falha associada com diferentes regiões no mapa, denominado clusters de neurônios.


Na Etapa de classificação/validação os dados de validação, 33,3% dos dados coletados, uma matriz 320x20 para validação global. Foram classificados e validados a partir do teste baseado em matriz confusão. Gerando uma matriz de validação, o qual as linhas representam a condição de falha e as colunas os clusters de neurônios.

A matriz confusão consistiu em relacionar os dados reais de teste de condições de falhas, rotulados em 160 pontos divididos em quatro grupos, com os dados preditivos originados a partir da normalização dos dados da rede neural Kohonen.


#### **4. Resultados e Discussão**

No tratante a etapa de resultados das condições de falhas no motor a combustão interna na formatação de imposição global de carga, foram analisadas as quatro condições de falhas, a saber: condição sem falha, condição folga entre a guia e haste da válvula de escape, desgaste na haste da válvula de escape e desgaste radial do anel de segmento de compressão, nas quatro condições de carga, a saber: sem carga (0 kW), 0,5 kW, 1 kW e 1,5 kW. Os dados de condições de falhas submetidos a condição global de carga foram analisados a partir das etapas de domínio frequência, etapa de densidade de frequência, etapa de rede neural: análise das falhas por carga, etapa de clusterização, etapa de associação e etapa de classificação/validação.

Sendo seus resultados extraídos a partir da análise da matriz U bidimensional, matriz U tridimensional, etapa de associação com uso da matriz pelo método de clusterização Ward's, da matriz U de associação, que relaciona o tipo de condição através de legenda e cores da matriz U e a matriz de validação. A Fig.5. evidencia a matriz U bidimensional da rede SOM, onde é possível visualizar desesseis subconjuntos bem delimitados, em consonância com a quantidade de condições de falhas e condições de carga padronizadas nessa etapa dos resultados. A matriz U tridimensional, Fig.6, mostra a matriz U em 3D para condição global de carga, evidenciando de forma mais clara a condição de fronteira entre os subconjuntos.



**Fig.5 Matriz U bidimensional da rede SOM na condição de análise global**



**Fig.6 Matriz U tridimensional da rede SOM na condição de análise global**

A etapa de associação entre as condições de falhas, relaciona as condições de falhas e de cargas com os subconjuntos do matriz de neurônio (matriz U), a partir da matriz de associação realizada pelo método de clusterização Ward's, utilizando a matriz de treinamento. Conforme demonstra a Quadro 4.



**Quadro 4. Matriz de associação dos subconjuntos de neurônios da Matriz U com as condições de falhas, utilizando a clusterização pelo método Ward's. condição de análise global**

Cx/Co	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16
SF00	0	0	0	0	0	0	0	0	0	0	0	0	0	40	0	0
SF05	0	0	0	0	40	0	0	0	0	0	0	0	0	0	0	0
SF10	0	0	0	0	0	0	40	0	0	0	0	0	0	0	0	0
SF15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	40	0
DV00	0	0	0	0	0	0	0	40	0	0	0	0	0	0	0	0
DV05	0	0	0	0	0	0	0	40	0	0	0	0	0	0	0	0
DV10	0	0	0	0	0	0	0	0	0	0	40	0	0	0	0	0
DV15	0	0	0	0	0	0	0	0	0	40	0	0	0	0	0	0
FV00	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	40
FV05	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	40
FV10	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	40
FV15	0	0	0	0	0	0	0	0	40	0	0	0	0	0	0	0
DA00	0	40	0	0	0	0	0	0	0	0	0	0	0	0	0	0
DA05	40	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
DA10	0	0	0	40	0	0	0	0	0	0	0	0	0	0	0	0
DA15	0	0	0	0	0	0	0	0	0	0	0	0	40	0	0	0

Cx – Cluster

Co – Condição

SF00 – Sem falha e sem carga

SF05 – Sem falha e com carga de 0,5 kW

SF10 – Sem falha e com carga de 1 kW

SF15 – Sem falha e com carga de 1,5 kW

DE00 – Desgaste na haste da válvula de escape e sem carga

DE05 – Desgaste na haste da válvula de escape e com carga de 0,5 kW

DE10 – Desgaste na haste da válvula de escape e com carga de 1 kW

DE15 – Desgaste na haste da válvula de escape e com carga de 1,5 kW

FE00 – Folga entre a guia e haste da válvula de escape e sem carga

FE05 – Folga entre a guia e haste da válvula de escape e com carga de 0,5 kW

FE10 – Folga entre a guia e haste da válvula de escape e com carga de 1 kW

FE15 – Folga entre a guia e haste da válvula de escape carga de 1,5 kW

DA00 – Desgaste radial do anel de segmento compressão e sem carga


DA05 – Desgaste radial do anel de segmento compressão e com carga de 0,5 kW

DA10 – Desgaste radial do anel de segmento compressão e com carga de 1 kW

DA15 – Desgaste radial do anel de segmento compressão e com carga de 1,5 kW

Os números apresentados na matriz, correspondem aos 66,6% dos dados utilizados na *matriz de treinamento*, cuja sua matriz possui dimensão de 640x20, sendo uma matriz 40x20 por condição de falha. A partir da *matriz U de associação* foi possível identificar as condições de falhas e condições de carga por subconjuntos na matriz U. Como demonstrado na Fig.7.

A partir da matriz U de associação é possível identificar condições de carga e falhas tão similares entre si, que essas constituíram um mesmo cluster, é o caso da condição de folga na guia de válvula e haste de válvula de escape nas condições de carga em 0 kW, 0,5 kW e 1 kW, como também no caso da condição desgaste da haste na carga 0 kW e 0,5 kW. Sendo possível afirmar que a dinâmica do comportamento da falha é a mesma para esse cluster independente da carga inserida no motor a combustão interna, desde que a carga seja as mencionadas para os dados clusters.



- SF00 – Sem falha e sem carga  
 SF05 – Sem falha e com carga de 0,5 kW  
 SF10 – Sem falha e com carga de 1 kW  
 SF15 – Sem falha e com carga de 1,5 kW  
 DE00 – Desgaste na haste da válvula de escape e sem carga  
 DE05 – Desgaste na haste da válvula de escape e com carga de 0,5 kW  
 DE10 – Desgaste na haste da válvula de escape e com carga de 1 kW  
 DE15 – Desgaste na haste da válvula de escape e com carga de 1,5 kW  
 FE00 – Folga entre a guia e haste da válvula de escape e sem carga  
 FE05 – Folga entre a guia e haste da válvula de escape e com carga de 0,5 kW  
 FE10 – Folga entre a guia e haste da válvula de escape e com carga de 1 kW  
 FE15 – Folga entre a guia e haste da válvula de escape e com carga de 1,5 kW  
 DA00 – Desgaste radial do anel de segmento compressão e sem carga  
 DA05 – Desgaste radial do anel de segmento compressão e com carga de 0,5 kW  
 DA10 – Desgaste radial do anel de segmento compressão e com carga de 1 kW  
 DA15 – Desgaste radial do anel de segmento compressão e com carga de 1,5 kW

**Fig.7 Matriz U de associação da rede SOM da análise global**

As condições de falhas submetidas a carga de 1,5 kW foram todas dispostas na região inferior do mapa, constituindo um super cluster, mostrando que a máquina térmica submetida a essas condições, possui um comportamento totalmente atípico quando relacionado com as demais cargas. De maneira ainda mais atípica que os demais, o desgaste do anel de segmento de compressão na condição de carga de 1,5 kW pode ser entendido como o pior cenário de criticidade devido ao maior distanciamento dos neurônios de fronteira, prevista na matriz U tridimensional. Como etapa final, a tabela x indica a matriz de validação da rede, com uso dos 33,3% dos dados totais, dispostos numa matriz 320x20.

A partir da tabela x de validação da rede neural para análise global, é possível afirmar que a rede neural utilizada para identificação das condições de falhas, teve uma eficiência de 100%. Em todas as etapas da análise dos resultados, o mapa neural de falhas por condição se mostrou como uma técnica eficaz na categorização da falha e categorização da falha por carga, sendo considerado um método eficiente para a previsão e diagnóstico inteligente de falha, em tempo real.

**Quadro 5. Matriz de validação da rede neural para condição de carga à 1,5 kW**

Cx/Co	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16
SF00	0	0	0	0	0	0	0	0	0	0	0	0	0	20	0	0
SF05	0	0	0	0	20	0	0	0	0	0	0	0	0	0	0	0
SF10	0	0	0	0	0	0	20	0	0	0	0	0	0	0	0	0
SF15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	20	0
DV00	0	0	0	0	0	0	0	20	0	0	0	0	0	0	0	0
DV05	0	0	0	0	0	0	0	20	0	0	0	0	0	0	0	0
DV10	0	0	0	0	0	0	0	0	0	0	20	0	0	0	0	0
DV15	0	0	0	0	0	0	0	0	0	20	0	0	0	0	0	0
FV00	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	20
FV05	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	20
FV10	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	20
FV15	0	0	0	0	0	0	0	0	20	0	0	0	0	0	0	0
DA00	0	20	0	0	0	0	0	0	0	0	0	0	0	0	0	0
DA05	20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
DA10	0	0	0	20	0	0	0	0	0	0	0	0	0	0	0	0
DA15	0	0	0	0	0	0	0	0	0	0	0	0	20	0	0	0

Cx – Cluster

Co – Condição

SF00 – Sem falha e sem carga

SF05 – Sem falha e com carga de 0,5 kW

SF10 – Sem falha e com carga de 1 kW

SF15 – Sem falha e com carga de 1,5 kW

DE00 – Desgaste na haste da válvula de escape e sem carga

DE05 – Desgaste na haste da válvula de escape e com carga de 0,5 kW

DE10 – Desgaste na haste da válvula de escape e com carga de 1 kW

DE15 – Desgaste na haste da válvula de escape e com carga de 1,5 kW

FE00 – Folga entre a guia e haste da válvula de escape e sem carga

FE05 – Folga entre a guia e haste da válvula de escape e com carga de 0,5 kW

FE10 – Folga entre a guia e haste da válvula de escape e com carga de 1 kW

FE15 – Folga entre a guia e haste da válvula de escape carga de 1,5 kW

DA00 – Desgaste radial do anel de segmento compressão e sem carga

DA05 – Desgaste radial do anel de segmento compressão e com carga de 0,5 kW

DA10 – Desgaste radial do anel de segmento compressão e com carga de 1 kW

DA15 – Desgaste radial do anel de segmento compressão e com carga de 1,5 kW

Quanto ao nível de criticidade referente ao cenário global de carga e falha, a condição de falha e de carga que mais contribuíram significativamente para o aumento do nível de criticidade, quando relacionado a cargas na condição sem falha, foi o desgaste radial do anel de segmento tipo compressão, submetido a carga de 1,5 kW. O que torna essa condição de falha a mais danosa quando comparada relacionada as demais falhas.

## 5. Conclusões

O presente estudo apresentou propôs inicialmente a criação de uma nova abordagem de detecção e classificação de falhas tribológicas através do uso combinado de técnicas de aprendizagem de máquinas e big data, aliando ferramentas de análise multivariadas baseadas em análise de agrupamento (clusters) e redes neurais artificiais não-supervisionadas (Mapa Auto-Organizável), com processamento de sinais, para elaboração de sistemas de manutenção inteligentes capazes de prever, diagnosticar e monitorar falhas em motores a combustão interna. Por meio do procedimento experimental e análise dos dados, foi possível desenvolver uma rede auto gerenciável para análise

de falhas em motores a combustão, na condição na condição global de falhas e cargas (0 kW; 0,5 kW; 1 kW e 1,5 kW). Pôde-se verificar pelos resultados, que os três modos de falhas tribológicas (desgaste radial do anel de segmento, folga entre a guia de válvula e haste da válvula de escape e desgaste da haste da válvula de escape) e a condição sem falha, foram detectados e classificados pelo sistema criado, com 100% de precisão. A rede neural utilizada não encontrou dificuldades em detectar e classificar as falhas tribológicas inseridas experimentalmente no sistema eletromecânico estudado.

## Referencias

1. McKinsey Global Institute. *Unlocking the potencial of the internet of things*. 2015. <https://www.mckinsey.com/business-functions/digital-mckinsey/our-insights/the-internet-of-things-the-value-of-digitizing-the-physical-world>.
2. Holmberg, K., et al., *Global Impact of Friction on Energy Consumption, Economy and Environment*. FME Trans., 2015. **43**: p. 181-185.
3. Jost, H. P., *Tribology-origin and future*. Wear, 1990. **136**: p.1-17.
4. Braga, A., et al., *Redes Neurais Artificiais: Teoria e Aplicações* 2000, Rio de Janeiro, Brasil.
5. Kohonen, T. *Self-organizing Maps* 2001, Berlin: Springer.
6. Aguiar, H., et al., *Inteligência computacional aplicada à administração, economia e engenharia em matlab 2007*, São Paulo: Thomson Learning Edições Ltda.
7. Haykin, S., *Neural Networks: A Comprehensive Foundation* 2nd edition, Prentice-Hall, 1999.
8. Castro, L.N., *Fundamentals on Neurocomputing. Basic concepts, algorithms, and applications* 2006. Taylor and Francis Group.
9. Zhao, Z.I., et al., *Vibration control of a pneumatic driven piezoelectric flexible manipulator using self-organizing map based multiple models*. Mechanical Systems and Signal Processing, 2016. **70**: p.345-372.
10. Germen, E., et al., *Sound based induction motor fault diagnosis using Kohonen self-organizing map*. Mechanical Systems and Signal Processing, 2014. **46**(1): p.45-58.
11. Yen, C.L., et al., *Applying the self-organization feature map (SOM) algorithm to AE-based tool wear monitoring in micro-cutting*. Mechanical Systems and Signal Processing, 2013. **34**(1-2): p. 353-366.
12. Huang, R., et al., *Residual life predictions for ball bearings based on self-organizing map and back propagation neural network methods*. Mechanical Systems and Signal Processing, 2007. **21**(1): p. 193-207.
13. Wong, M.L.D., et al., *Modified self-organising map for automated novelty detection applied to vibration signal monitoring*. Mechanical Systems and Signal Processing, 2006. **20**(3): p. 593-610.
14. Yang, B.S., et al., *Neural network for fault diagnosis of rotating machinery*. Mechanical Systems and Signal Processing, 2004. **18**(3): p. 645-657.
15. Scheffer, C., et al., *Wear monitoring in turning operations using vibration and strain measurements*. Mechanical Systems And Signal Processing, 2001. **15**(6): p. 1185-1202.

## Conflicto de Intereses

No existe ningún conflicto de intereses entre los autores, ni de los autores con otras entidades vinculadas al contenido del artículo.