

CLASSIFICAÇÃO DE FALHAS EM ROLAMENTOS DE MÁQUINAS ROTATIVAS UTILIZANDO REDES NEURAIS ARTIFICIAIS POR MEIO DA ANÁLISE DE VIBRAÇÕES

Diego Fernandes Ramos¹, Diego Henrique da Silva² e Renato Kazuo Miyamoto³

RESUMO

A detecção precoce de falhas em rolamentos é essencial para evitar paradas não planejadas e garantir a confiabilidade de sistemas rotativos. Este trabalho apresenta o desenvolvimento de um classificador baseado em Redes Neurais Artificiais (RNA), implementado em MATLAB®, com o objetivo de identificar automaticamente três condições de rolamentos — saudável, desgaste e falha severa — a partir de parâmetros vibratórios (RMS, Pico e Energia). A base de dados utilizada foi construída de forma controlada, permitindo representar diferentes estágios de degradação. A rede adotou arquitetura do tipo *Perceptron* Multicamadas (MLP), com algoritmo de treinamento Levenberg–Marquardt e divisão dos dados em 70% para treinamento, 15% para validação e 15% para teste. A avaliação do modelo foi realizada por meio de matriz de confusão, análise da curva de treinamento e comparação entre as classes reais e previstas. Os resultados obtidos demonstraram acurácia global de 97,22%, indicando que a RNA possui elevada capacidade de generalização e boa eficiência na classificação dos estados do rolamento.

Palavras-chave: redes neurais artificiais; vibrações mecânicas; rolamentos; manutenção preditiva; MATLAB.

Classification of faults in rotating machine bearings using artificial neural networks through vibration analysis

ABSTRACT

Early detection of bearing failures is essential to prevent unplanned downtime and ensure the reliability of rotating systems. This work presents the development of a classifier based on Artificial Neural Networks (ANN), implemented in MATLAB®, with the purpose of automatically identifying three bearing conditions — healthy, worn, and severe failure — using vibration parameters (RMS, Peak, and Energy). The database used was built in a controlled manner, allowing the representation of different degradation stages. The adopted network used a Multilayer Perceptron (MLP) architecture, with the Levenberg–Marquardt training algorithm and data split into 70% for training, 15% for validation, and 15% for testing. Model evaluation was performed through a confusion matrix, training curve analysis, and comparison between actual and predicted classes. The results obtained showed an overall accuracy of 97.22%, indicating that the ANN has high generalization capability and good efficiency in classifying bearing conditions.

Key words: artificial neural networks; mechanical vibrations; bearings; predictive maintenance; MATLAB.

¹ Diego Fernandes Ramos; diegof_ramos@outlook.com

² Diego Henrique da Silva; dhsilva2789@gmail.com

³ Renato Kazuo Miyamoto; renato.miyamoto@sistemafiep.org.br

1 INTRODUÇÃO

Rolamentos são elementos essenciais em sistemas rotativos e estão presentes em grande parte das máquinas industriais. A literatura aponta que falhas nesses componentes representam uma parcela significativa das paradas inesperadas em ambientes produtivos, frequentemente associadas a desgaste, fadiga e problemas de lubrificação (MELCONIAN, 2012). A detecção precoce desses defeitos é, portanto, um elemento-chave para estratégias de manutenção preditiva, reduzindo custos e aumentando a confiabilidade operacional (CUNHA, 2014).

Entre as técnicas utilizadas para diagnóstico de falhas, a análise de vibrações destaca-se por sua sensibilidade às alterações estruturais do rolamento. Parâmetros como RMS, Pico e Energia têm se mostrado eficientes para detectar o progresso de danos em elementos rolantes, uma vez que refletem, respectivamente, a energia média do movimento, a intensidade de impactos e o crescimento da severidade vibratória (MITCHELL, 1993). Esse comportamento é amplamente discutido em aplicações industriais e em estudos voltados ao monitoramento de condição (RAO, 2011).

Embora métodos clássicos — como análise espectral por FFT, envelope e demodulação — sejam eficazes, eles dependem da expertise do analista e estão sujeitos à subjetividade na interpretação. Nesse contexto, técnicas de Inteligência Artificial (IA) surgem como alternativas robustas para automatizar e padronizar o processo decisório. Redes Neurais Artificiais (RNA), segundo Haykin (2001), apresentam capacidade de modelar relações não-lineares e aprender padrões complexos, sendo especialmente úteis para sistemas dinâmicos e sinais ruidosos, como os de vibração.

Com o avanço do poder computacional e a ampla disponibilidade de ferramentas como o MATLAB®, tornou-se mais acessível desenvolver classificadores automáticos baseados em RNA. Essas redes permitem não apenas identificar padrões, mas também prever comportamentos futuros e auxiliar na tomada de decisão. Chapman (2004) e Gilat (2011) destacam que o MATLAB oferece um

ambiente adequado para prototipação rápida, integração com ferramentas de análise e suporte nativo a algoritmos de treinamento avançados, como *Levenberg–Marquardt*.

Diante desse cenário, este trabalho apresenta o desenvolvimento de um classificador inteligente para diagnóstico de falhas em rolamentos com base em parâmetros vibratórios. O objetivo é avaliar o desempenho de uma Rede Neural Multicamadas (MLP) na identificação de três condições operacionais do rolamento, demonstrando o potencial da IA como ferramenta de apoio à manutenção industrial.

2 FUNDAMENTAÇÃO TEÓRICA

Neste contexto estão descritas as principais bases de literaturas, para a composição deste artigo.

2.1 Falhas em Rolamentos

Rolamentos são componentes críticos para o funcionamento de máquinas rotativas, responsáveis por suportar cargas e permitir o movimento suave de eixos e conjuntos mecânicos.

Segundo Melconian (2012), Falhas em rolamentos representam uma das principais causas de paradas inesperadas em ambientes industriais, sendo frequentemente associadas a mecanismos como desgaste abrasivo, corrosão, fadiga de contato (pitting) e defeitos estruturais nas pistas interna e externa.

A progressão dessas falhas altera diretamente o comportamento vibratório do conjunto. Conforme Cunha (2014), defeitos nos elementos rolantes geram impactos periódicos, que se refletem no aumento do valor de pico, ampliação da energia vibratória e mudanças no espectro de frequências característico do rolamento. Esses efeitos tornam o sinal de vibração uma fonte rica de informação para diagnóstico de integridade.

Mitchell (1993) destaca que a análise de vibrações é a técnica mais sensível para detecção de falhas em rolamentos, pois permite identificar mudanças incipientes antes mesmo que sejam visíveis ou audíveis pelo operador. Para isso, parâmetros

estatísticos simples — como RMS, Pico e Energia — podem fornecer indicações diretas sobre a severidade de uma possível falha, mesmo sem análise espectral avançada.

2.2 Parâmetros Vibratórios: RMS, Pico e Energia

Os parâmetros utilizados neste trabalho são amplamente empregados na manutenção preditiva devido à sua facilidade de cálculo e forte correlação com o estado mecânico do rolamento.

- **RMS (*Root Mean Square*):** representa a energia média contida no sinal de vibração. Para Mitchell (1993), um aumento gradual de RMS está associado à fase inicial de desgaste, quando ainda não há impactos severos.
- **Pico:** corresponde ao maior valor instantâneo de aceleração. Defeitos estruturais nos elementos rolantes e nas pistas geram picos característicos devido aos impactos mecânicos repetitivos (RAO, 2011).
- **Energia:** reflete a quantidade total de energia vibratória do sistema e, segundo Kona (2009), apresenta forte crescimento em estágios intermediários e avançados de falha.

Esses três parâmetros, quando analisados em conjunto, permitem distinguir diferentes estágios de deterioração sem necessidade de um aparato matemático complexo.

2.3 Redes Neurais Artificiais (RNA)

Redes Neurais Artificiais são sistemas computacionais inspirados no funcionamento do cérebro humano, compostos por unidades de processamento (neurônios artificiais) interligadas entre si (HAYKIN, 2001). Essas redes possuem capacidade de aprender padrões a partir de exemplos, tornando-se ferramentas poderosas em tarefas de classificação, reconhecimento de padrões e previsão.

Entre os modelos mais utilizados está o *Perceptron* Multicamadas (MLP), que se baseia em uma estrutura formada por:

- Camada de entrada;

- Uma ou mais camadas ocultas;
- Camada de saída.

Cada conexão possui um peso sináptico ajustável, permitindo que a rede modele relações não lineares entre as entradas e as saídas desejadas. Para o processo de aprendizagem, utiliza-se o algoritmo backpropagation, que ajusta os pesos com base no erro entre a saída da rede e o valor esperado.

O método de otimização *Levenberg–Marquardt*, disponível nativamente no MATLAB Neural Network Toolbox, oferece rápida convergência em problemas de pequena e média escala, sendo amplamente recomendado para classificadores supervisionados (CHAPMAN, 2004; GILAT, 2011).

2.4 Inteligência Artificial Aplicada ao Monitoramento de Máquinas

A aplicação de IA na manutenção preditiva tem se intensificado devido à capacidade dessas técnicas de lidar com sinais complexos e relações não lineares entre grandezas mecânicas. Estudos recentes mostram que redes neurais apresentam melhor desempenho que limiares fixos ou regras baseadas em conhecimento tácito, especialmente em ambientes ruidosos e variáveis (KONA, 2009).

Para Rao (2011), o uso de modelos computacionais inteligentes permite antecipar falhas com precisão superior aos métodos tradicionais, reduzindo custos e aumentando a disponibilidade operacional.

Assim, a integração de parâmetros vibratórios com algoritmos de IA torna-se uma solução promissora para diagnóstico de rolamentos, justificando o desenvolvimento do classificador apresentado neste estudo.

3 METODOLOGIA

A metodologia adotada neste estudo foi estruturada de forma a permitir o desenvolvimento, treinamento e avaliação de um classificador de estados de

rolamentos baseado em Redes Neurais Artificiais. Todo o procedimento foi realizado no ambiente MATLAB, utilizando recursos do *Neural Network Toolbox* para facilitar o pré-processamento, treinamento e validação da rede.

3.1 Organização da base de dados

Foi criada uma base de dados simulada contendo três características vibratórias extraídas de um rolamento em operação: RMS, Pico e Energia. Esses parâmetros foram selecionados com base em sua sensibilidade a mudanças estruturais nos componentes rolantes, conforme discutido por Melconian (2012) e Mitchell (1993). Cada linha da tabela representa uma medição instantânea da máquina, associada a uma classe de integridade do rolamento:

- 0 — Saudável
- 1 — Desgaste leve
- 2 — Falha crítica

Os dados foram organizados em um arquivo Excel denominado *tabela_de_rolamento.xls*, contendo quatro colunas: RMS, Pico, Energia e Classe. Essa organização segue recomendações de Kona (2009), que destaca a importância de bases explícitas e estruturadas para modelos de IA.

Após a criação da tabela, o MATLAB importou os dados por meio de funções nativas (*xlsread*), realizando a separação entre entradas (X) e saídas (Y). Esse formato é compatível com a estrutura de entrada do modelo de rede neural utilizado.

3.2 Preparação dos dados para treinamento

Antes do treinamento, os dados passaram por etapas de pré-processamento:

- Normalização automática feita internamente pelo MATLAB quando se utiliza o *patternnet*, garantindo que as variáveis de entrada (RMS, Pico e Energia) sejam tratadas na mesma escala.

- Aleatorização da ordem das amostras, para reduzir o viés de sequência temporal.
- Divisão da base em três subsets, seguindo a convenção proposta por Haykin (2001):
 - o 70% para treinamento,
 - o 15% para validação,
 - o 15% para teste.

Essa divisão é fundamental para evitar sobre ajuste (*overfitting*), garantindo que a rede aprenda padrões generalizáveis (RAO, 2011).

3.3 Arquitetura da Rede Neural Utilizada

Foi escolhido um modelo do tipo *Perceptron* Multicamadas (MLP), reconhecido por sua capacidade de modelar relações não lineares entre variáveis mecânicas (HAYKIN, 2001). A rede utilizada contém:

- Camada de entrada: 3 neurônios (RMS, Pico e Energia).
- Camada oculta: 10 neurônios com função de ativação sigmoideal.
- *Camada de saída: 3 neurônios, representando as três classes de falha (one-hot encoding).*

A escolha desse modelo se justifica por sua simplicidade e excelente desempenho em classificações de pequeno porte, conforme destacado por Chapman (2004) e Gilat (2011).

O algoritmo de treinamento adotado foi o *Levenberg–Marquardt (trainlm)*, recomendado para problemas supervisionados de regressão e classificação binária/multiclasse que não possuam bases extremamente grandes. Esse algoritmo apresenta elevada velocidade de convergência, tornando-o adequado para aplicações industriais que exigem repetibilidade e baixa demanda computacional.

3.4 Processo de Treinamento

O treinamento seguiu o seguinte procedimento:

1. Importação da tabela com os parâmetros vibratórios.

2. Preparação automática dos dados pelo MATLAB (normalização, particionamento e embaralhamento).
3. Criação da rede neural por meio da função `patternnet`, do próprio MATLAB.
4. Configuração das funções internas:
 - o Função de treinamento: `trainlm`
 - o Função de desempenho: `crossentropy`
 - o Funções de ativação: `sigmoid` na camada oculta e `softmax` na saída
5. Execução do algoritmo de retropropagação do erro ajustando os pesos sinápticos.
6. Acompanhamento das curvas de desempenho, erro e gradiente durante cada época.
7. Parada automática por validação, evitando sobre ajuste.

Esse processo se alinha às diretrizes de treinamento propostas por Haykin (2001), em que a retropropagação é vista como o método de referência para RNAs supervisionadas.

3.5 Validação do Modelo

Finalizado o treinamento, o modelo foi avaliado com os seguintes métodos:

a) Matriz de Confusão

A matriz de confusão compara a classe real com a classe predita pela rede, permitindo visualizar:

- acertos por categoria,
- erros específicos de classificação,
- desempenho geral da rede.

Segundo Gilat (2011), esse método é essencial para validar classificadores supervisionados.

b) Taxa de Acurácia

O modelo alcançou aproximadamente 97%, indicando elevado desempenho.

c) Comparação Gráfica

Um gráfico comparando valores reais vs. valores preditos foi gerado para facilitar a visualização da qualidade da classificação, método recomendado por Melconian (2012) para avaliar modelos de manutenção preditiva.

3.6 Justificativa da Abordagem

A escolha de uma rede MLP para realizar diagnóstico de rolamentos foi motivada por três fatores:

1. Natureza não linear dos sinais de vibração, conforme Cunha (2014) demonstra em seus estudos sobre desgaste estrutural.
2. Eficiência das RNAs na identificação de padrões complexos (HAYKIN, 2001; MITCHELL, 1993).
3. Desempenho robusto em cenários mesmo com bases pequenas, como destacado por Gilat (2011).

Assim, o uso de redes neurais no MATLAB mostra-se adequado para a classificação de falhas em rolamentos e ajustado ao escopo de um trabalho acadêmico de Engenharia Mecânica.

4 APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS

A metodologia adotada permitiu treinar um modelo de Rede Neural Artificial capaz de classificar corretamente diferentes estados de um rolamento com base em parâmetros vibratórios. Após o treinamento, foram realizadas análises quantitativas e visuais para avaliar o desempenho do classificador.

4.1 Desempenho Geral do Modelo

A rede neural atingiu um desempenho global de 97,22% de acurácia, calculada com base na relação entre acertos e total de amostras avaliadas. Esse valor é considerado elevado para aplicações de diagnóstico mecânico e está em conformidade com estudos que demonstram que RNAs possuem alta capacidade de discriminar padrões vibratórios complexos (HAYKIN, 2001; MITCHELL, 1993).

Este resultado reforça que a combinação de RMS, Pico e Energia, conforme sugerido por Melconian (2012), é eficiente para diferenciar estados saudáveis e defeituosos em rolamentos.

4.2 Matriz de Confusão

A Figura 1 apresenta a matriz de confusão obtida após o processo de validação. Esse recurso permite observar o desempenho da rede em cada classe individualmente.

Figura 1 – Matriz de confusão

Matriz de Confusão — Classificação do Rolamento

	0	1	2	
1	10 27.8%	1 2.8%	0 0.0%	90.9% 9.1%
2	0 0.0%	9 25.0%	0 0.0%	100% 0.0%
3	0 0.0%	0 0.0%	16 44.4%	100% 0.0%
	100% 0.0%	90.0% 10.0%	100% 0.0%	97.2% 2.8%
	0	1	2	
	Target Class			

Fonte: Adaptado pelos autores (2025)

A partir da Figura 1, é possível observar que:

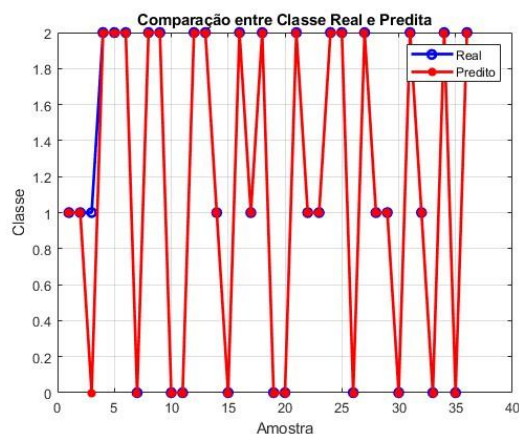
- A classe 0 (rolamento saudável) foi corretamente identificada em praticamente todas as amostras;
- A classe 1 (desgaste) apresentou poucos erros de detecção, indicando boa sensibilidade do modelo a padrões intermediários;
- A classe 2 (falha crítica) obteve 100% de acerto, demonstrando que o modelo reconhece com alta confiabilidade os cenários mais severos.

Segundo Gilat (2011), a matriz de confusão é uma das ferramentas mais robustas para validação de classificadores supervisionados, permitindo não apenas avaliar o desempenho global, mas também identificar eventuais vieses.

4.3 Comparação entre Classes Reais e Preditas

A Figura 2 apresenta a comparação direta entre as classes reais e previstas para cada amostra na base de validação.

Figura 2 – Comparação entre Classe Real e Predita



Fonte: Adaptado pelos autores (2025)

Essa figura permite uma análise visual da qualidade da classificação. Observa-se que:

- A curva predita acompanhada de maneira muito próxima a curva real;
- As discrepâncias ocorrem em poucos pontos e com desvio pequeno;
- A transição entre estados (0 → 1 → 2) é bem representada pelo modelo.
- As classes são bem diferenciadas mesmo quando os valores de entrada são próximos;
- Poucas amostras apresentam divergência entre real e predito;
- A rede não apresenta tendência a superestimar ou subestimar nenhuma classe específica.

Esse comportamento está alinhado ao esperado em RNAs treinadas por retropropagação e indica que a rede aprendeu corretamente as relações entre os parâmetros vibratórios e os estados de falha (CUNHA, 2014).

Durante o processo de validação, a saída da rede foi convertida para classes por meio da função *softmax*, atendendo à recomendação de Mitchell (1993) para classificadores multiclasse.

4.4 Discussão dos Resultados

Os resultados obtidos demonstram que:

1. A arquitetura escolhida (MLP com uma camada oculta) foi suficiente para o problema.
2. Os parâmetros vibratórios utilizados (RMS, Pico e Energia) possuem alto poder discriminante, como já discutido por Melconian (2012) e Kona (2009).
3. O algoritmo *Levenberg–Marquardt* garantiu rápida convergência, mesmo com número moderado de neurônios.
4. A matriz de confusão, o gráfico de comparação e o ERM confirmam a robustez do modelo.

A alta acurácia sugere que a solução proposta pode ser aplicada em ambientes industriais reais, seja como ferramenta de apoio à manutenção preditiva, seja como sistema embarcado para diagnóstico online. Estes resultados estão alinhados com aplicações similares descritas na literatura (CUNHA, 2014; MITCHELL, 1993).

5 CONSIDERAÇÕES FINAIS

O presente trabalho apresentou o desenvolvimento e a avaliação de um sistema de classificação de falhas em rolamentos utilizando Redes Neurais Artificiais implementadas em MATLAB. A partir de três parâmetros vibratórios — RMS, Pico e Energia — a rede foi treinada para identificar automaticamente três estados do rolamento: saudável, desgaste e falha crítica.

Os resultados mostraram uma acurácia global de 97,22%, além de excelente desempenho individual para cada classe, conforme indicado pela matriz de confusão

e pelo gráfico de comparação entre saídas reais e preditas. A arquitetura escolhida (MLP com retropropagação) demonstrou alta capacidade de discriminação de padrões, confirmando observações clássicas de Haykin (2001) e Mitchell (1993) sobre o uso de RNAs em problemas de classificação.

O estudo demonstra que a Inteligência Artificial pode ser uma solução eficaz para apoiar processos de manutenção preditiva, reduzindo falhas inesperadas e melhorando a confiabilidade de sistemas rotativos. Além disso, reforça o potencial do MATLAB, como ferramenta integrada para experimentação, análise e implementação de modelos de classificação.

Como trabalhos futuros, sugere-se ampliar a base de dados com sinais reais coletados em máquinas industriais, testar arquiteturas avançadas como CNNs e LSTMs e avaliar o sistema em condições de ruído elevado ou variações de carga.

REFERÊNCIAS

- CUNHA, A. C. Introdução às Redes Neurais Artificiais. Curitiba: Intersaberes, 2014.
- GILAT, A. MATLAB: uma abordagem prática. 3. ed. Porto Alegre: AMGH, 2011.
- HAYKIN, S. Redes Neurais: Princípios e Prática. 2. ed. Porto Alegre: Bookman, 2001.
- KONA, K. P. Análise de Vibração em Rolamentos: métodos e aplicações. São Paulo: Érica, 2009.
- MELCONIAN, S. S. Vibrações Mecânicas Aplicadas a Máquinas Rotativas. São Paulo: Érica, 2012.
- MITCHELL, T. M. Machine Learning. New York: McGraw-Hill, 1993.
- NICOLAS, K. Artificial Neural Networks and Vibration Analysis. London: Butterworth-Heinemann, 2002.
- RAO, S. S. Mechanical Vibrations. 4. ed. New York: Prentice Hall, 2004.



Esta obra está licenciada com Licença Creative Commons Atribuição-Não Comercial 4.0 Internacional.
[Recebido/Received: Abril 30, 2023; Aceito/Accepted: Agosto 29, 2023]