

APLICAÇÃO DE TÉCNICAS DE APRENDIZADO DE MÁQUINA NA DETECÇÃO DE FALHAS MECÂNICAS EM MÁQUINAS ROTATIVAS POR MEIO DA ANÁLISE DE VIBRAÇÕES

APPLICATION OF MACHINE LEARNING TECHNIQUES FOR MECHANICAL
FAULT DETECTION IN ROTATING MACHINERY THROUGH VIBRATION
ANALYSIS

Ciências Exatas e da Terra, Engenharias • 31/08/2026

REGISTRO DOI: [10.70773/revistatopicos/788062575](https://doi.org/10.70773/revistatopicos/788062575)

Vinicius galhardo¹

Jorge Nei Brito²

Hygor Santiago Lara³

RESUMO

A detecção precoce de falhas em máquinas rotativas é essencial para aumentar a confiabilidade operacional e reduzir custos de manutenção, sendo a Inteligência Artificial uma alternativa promissora para automatizar o diagnóstico de defeitos. Este trabalho teve como objetivo avaliar a aplicação de diferentes técnicas de aprendizado de máquina na identificação de falhas mecânicas em máquinas rotativas a partir de sinais de vibração. Os dados foram obtidos em uma bancada experimental instrumentada, submetida a condições de operação normal, desbalanceamento, desalinhamento e combinações dessas falhas, totalizando 14 condições distintas de funcionamento. Os sinais de vibração foram adquiridos por acelerômetro, processados por meio da Transformada Rápida de Fourier (FFT) e caracterizados pelas amplitudes da frequência de rotação e de seus quatro primeiros harmônicos, utilizadas como variáveis de entrada dos modelos de Árvore de Decisão, Random Forest, K-Nearest Neighbors, Support Vector Machine e Perceptron Multicamadas. O desempenho dos classificadores foi avaliado por meio da matriz de confusão, acurácia, precisão, revocação e escore F1. Os resultados demonstraram bom desempenho de todas as técnicas avaliadas, evidenciando grande capacidade de distinguir diferentes condições operacionais. A análise dos resultados mostrou que as características extraídas no domínio da frequência são representativas dos fenômenos físicos associados às falhas, permitindo que os algoritmos reconheçam padrões de forma consistente e contribuindo para o diagnóstico automatizado de falhas em máquinas rotativas.

Palavras-chave: Inteligência Artificial; Aprendizado de Máquina; Análise de Vibrações; Máquinas Rotativas; Diagnóstico de Falhas.

ABSTRACT

Early detection of faults in rotating machinery is essential to improve operational reliability and reduce maintenance costs, and Artificial Intelligence has emerged as a promising alternative for automating fault diagnosis. This study aimed to evaluate the application of different machine learning techniques for identifying mechanical faults in rotating machinery using vibration signals. Data were collected from an instrumented experimental test bench operating under normal conditions, unbalance, misalignment, and combinations of these faults, totaling fourteen distinct operating conditions. Vibration signals were acquired using an accelerometer, processed through the Fast Fourier Transform (FFT), and characterized by the amplitudes of the rotational frequency and its first four harmonics, which were used as input features for Decision Tree, Random Forest, K-Nearest Neighbors, Support Vector Machine, and Multilayer Perceptron models. Classifier performance was evaluated using confusion matrix, accuracy, precision, recall, and F1-score metrics. The results demonstrated high performance for all evaluated techniques, showing a strong capability to distinguish different operating conditions. The analysis indicated that the features extracted from the frequency domain effectively represent the physical phenomena associated with mechanical faults, enabling consistent pattern recognition and contributing to the automated diagnosis of faults in rotating machinery.

Keywords: Artificial Intelligence; Machine Learning; Vibration Analysis; Rotating Machinery; Fault Diagnosis.

1. INTRODUÇÃO

As máquinas rotativas desempenham papel fundamental nos sistemas industriais modernos, estando presentes em

equipamentos como motores elétricos, bombas, ventiladores, compressores e turbinas utilizados nos setores de geração de energia, mineração, siderurgia, petroquímica, manufatura e transporte. A continuidade da produção nesses segmentos depende diretamente da confiabilidade operacional desses equipamentos, tornando indispensável a adoção de estratégias capazes de minimizar falhas e aumentar sua disponibilidade (Randall, 2011; Scheffer; Girdhar, 2004). Falhas inesperadas em máquinas rotativas podem provocar interrupções no processo produtivo, elevar os custos de manutenção e comprometer a segurança operacional. Além dos prejuízos financeiros decorrentes das paradas não programadas, a propagação de danos para outros componentes do sistema pode aumentar significativamente o tempo de indisponibilidade do equipamento. Em consequência, a manutenção industrial evoluiu das abordagens corretivas para estratégias preventivas e, posteriormente, para a manutenção preditiva, cuja finalidade é identificar anomalias em estágio inicial antes que ocorram falhas funcionais (Mobley, 2002; Jardine; Lin; Banjevic, 2006).

Entre as técnicas empregadas no monitoramento de condição, a análise de vibrações destaca-se por possibilitar a identificação de alterações no comportamento dinâmico das máquinas sem a necessidade de interromper sua operação. Diferentes defeitos mecânicos produzem assinaturas vibratórias características, permitindo identificar falhas como desbalanceamento, desalinhamento, defeitos em rolamentos e folgas mecânicas por meio da interpretação dos sinais medidos (Randall, 2011; Bently; Hatch, 2003). Entretanto, a interpretação desses sinais depende, em grande parte, da experiência do analista, especialmente quando

diferentes mecanismos de falha atuam simultaneamente sobre o equipamento.

Nos últimos anos, o avanço das técnicas de Inteligência Artificial e, em particular, do aprendizado de máquina, ampliou as possibilidades de automatização do diagnóstico de falhas em máquinas rotativas. A utilização de algoritmos capazes de aprender padrões diretamente a partir de dados experimentais tem permitido reduzir a subjetividade da análise tradicional, tornando o processo de identificação de falhas mais rápido, consistente e reproduzível. Diversos trabalhos têm demonstrado resultados promissores na aplicação dessas técnicas ao monitoramento de condição, principalmente quando associadas ao processamento espectral dos sinais de vibração. Apesar dos avanços observados na literatura, ainda existem desafios relacionados à comparação do desempenho entre diferentes algoritmos de classificação quando submetidos ao mesmo conjunto de dados experimentais e às mesmas condições de processamento. Adicionalmente, muitos estudos utilizam um grande número de variáveis extraídas dos sinais de vibração, dificultando a interpretação física dos resultados e aumentando a complexidade computacional dos modelos. O presente trabalho parte da hipótese de que características espectrais diretamente relacionadas aos mecanismos físicos das falhas são suficientes para representar as condições operacionais estudadas e servir como entrada para diferentes técnicas de aprendizado de máquina. Essa abordagem busca preservar a interpretabilidade dos atributos utilizados, mantendo sua relação direta com os fenômenos vibratórios observados na máquina.

Considerando esse cenário, este trabalho tem como objetivo avaliar a aplicação de diferentes técnicas de aprendizado de máquina na

identificação de falhas mecânicas em máquinas rotativas a partir de sinais de vibração. Para isso, foi utilizada uma bancada experimental instrumentada submetida a diferentes condições de desbalanceamento, desalinhamento e combinações dessas falhas. Os sinais adquiridos foram processados por meio da Transformada Rápida de Fourier (FFT), sendo utilizadas como características de entrada dos modelos as amplitudes da frequência de rotação e de seus quatro primeiros harmônicos. Foram avaliados os algoritmos Árvore de Decisão, Random Forest, Support Vector Machine (SVM), K-Nearest Neighbors (KNN) e Perceptron Multicamadas (MLP), comparando seu desempenho na classificação das diferentes condições operacionais da bancada experimental.

2. FUNDAMENTAÇÃO TEÓRICA

2.1. Máquinas Rotativas e Monitoramento de Condição

As máquinas rotativas constituem a base de diversos processos industriais, sendo amplamente empregadas em sistemas de geração e transmissão de potência, bombeamento, ventilação e compressão. Devido à alta criticidade desses equipamentos, sua confiabilidade está diretamente relacionada à continuidade da produção e à redução dos custos de manutenção. Para essa aplicação, estratégias de monitoramento de condição têm sido amplamente utilizadas para acompanhar o estado operacional das máquinas e identificar alterações indicativas do desenvolvimento de falhas antes da ocorrência de danos mais severos (Mobley, 2002; Jardine; Lin; Banjevic, 2006).


Entre as técnicas empregadas no monitoramento de condição, a análise de vibrações destaca-se por fornecer informações

diretamente relacionadas ao comportamento dinâmico dos componentes mecânicos. Alterações na amplitude e na distribuição espectral das vibrações permitem identificar anomalias em elementos como rotores, eixos, acoplamentos e mancais, tornando essa técnica uma das mais consolidadas para aplicação em programas de manutenção preditiva (Randall, 2011; Bently; Hatch, 2003).

2.2. Falhas Mecânicas em Máquinas Rotativas


Os defeitos mais frequentes em máquinas rotativas destacam-se o desbalanceamento e o desalinhamento, ambos responsáveis por alterações significativas na resposta vibratória do sistema. O desbalanceamento ocorre quando o centro de massa do rotor não coincide com seu eixo de rotação, produzindo forças centrífugas periódicas que aumentam a amplitude da vibração, principalmente na frequência de rotação. Já o desalinhamento decorre da falta de coaxialidade entre eixos acoplados, produzindo esforços adicionais que modificam o comportamento dinâmico da máquina e tendem a intensificar componentes harmônicas do espectro de vibração (Bently; Hatch, 2003; Randall, 2011).

Figura 2.1. Espectro Característico do Desbalanceamento.



Fonte: Autor (2026).

Figura 2.2. Espectro Característico do Desalinhamento.



Fonte: Autor (2026).

Quando esses mecanismos atuam simultaneamente, suas assinaturas espectrais podem se sobrepor, tornando a interpretação manual dos sinais mais complexa. Essa característica reforça a necessidade de métodos automatizados capazes de reconhecer padrões associados às diferentes condições operacionais da

máquina, especialmente em cenários próximos aos encontrados em aplicações industriais.

2.3. Processamento dos Sinais de Vibração

Os sinais obtidos por acelerômetros são registrados no domínio do tempo e necessitam de processamento para evidenciar as frequências associadas aos fenômenos mecânicos presentes no sistema. Estão entre as técnicas mais utilizadas para essa finalidade destaca-se a Transformada Rápida de Fourier (Fast Fourier Transform – FFT), que converte o sinal temporal para o domínio da frequência, permitindo identificar as componentes espectrais relacionadas às diferentes fontes de excitação (Oppenheim; Schaffer, 2010).

A representação no domínio da frequência foi utilizada para extrair como características as amplitudes da frequência de rotação e de seus quatro primeiros harmônicos. A escolha desses parâmetros foi baseada na relação direta entre essas componentes espectrais e os mecanismos físicos associados ao desbalanceamento e ao desalinhamento, permitindo representar as condições experimentais por meio de um conjunto reduzido de atributos com significado físico bem definido.

2.4. Aprendizado de Máquina Aplicado Ao Diagnóstico de Falhas

O aprendizado de máquina corresponde a um conjunto de técnicas capazes de identificar padrões em dados e utilizá-los para realizar previsões ou classificações. No diagnóstico de falhas em máquinas rotativas, esses algoritmos aprendem a relação entre características extraídas dos sinais de vibração e as diferentes condições

operacionais, permitindo automatizar o processo de identificação de defeitos.

Foram avaliadas cinco técnicas de classificação supervisionada: Árvore de Decisão, Random Forest, Support Vector Machine (SVM), K-Nearest Neighbors (KNN) e Perceptron Multicamadas (MLP). A comparação entre esses algoritmos foi realizada utilizando a mesma base de dados e o mesmo conjunto de atributos extraídos da FFT, permitindo avaliar seu desempenho sob condições experimentais idênticas. A qualidade da classificação foi analisada por meio da matriz de confusão e das métricas de acurácia, precisão, revocação e escore F1, amplamente utilizadas na avaliação de modelos de classificação.

3. METODOLOGIA


3.1. Caracterização da Pesquisa

Esta pesquisa possui natureza experimental e abordagem quantitativa, tendo como objetivo avaliar a aplicação de técnicas de aprendizado de máquina na identificação de falhas mecânicas em máquinas rotativas por meio da análise de sinais de vibração. O estudo foi desenvolvido a partir de ensaios realizados em uma bancada experimental instrumentada, na qual foram reproduzidas diferentes condições de operação representativas de situações encontradas em sistemas rotativos industriais. A metodologia compreendeu as etapas de aquisição dos sinais de vibração, processamento no domínio da frequência, extração de características, construção da base de dados, treinamento dos modelos de classificação e avaliação do desempenho dos algoritmos.

3.2. Bancada Experimental

Os ensaios foram realizados na bancada experimental do Laboratório de Sistemas Dinâmicos (LASID) da Universidade Federal de São João del-Rei (UFSJ). O sistema é composto por um motor elétrico Eberle de 0,5 cv operando a aproximadamente 1720 rpm, acoplado a um eixo apoiado em dois mancais SN-509 equipados com rolamentos Fafnir 209K. A bancada permite a introdução controlada de massas para simulação de desbalanceamento e o ajuste da posição relativa dos mancais para geração de diferentes níveis de desalinhamento, possibilitando a reprodução de condições experimentais de forma repetitiva e controlada.

Figura 3.1 – Bancada Experimental Utilizada nos Ensaios.



Fonte: Autor (2026)

3.3. Aquisição dos Sinais de Vibração

A aquisição dos sinais foi realizada utilizando um analisador de vibrações SKF Microlog GX-75 equipado com acelerômetro SKF CMSS 2111 instalado sobre o mancal principal da bancada. As

medições foram efetuadas nos três eixos ortogonais (X, Y e Z), sendo registrados quarenta sinais por eixo para cada condição experimental, totalizando 120 sinais por condição. Cada aquisição foi composta por aproximadamente 16.384 pontos amostrais obtidos com frequência de amostragem de 2560 Hz, resultando em resolução espectral de aproximadamente 0,15625 Hz. Todos os ensaios foram realizados em regime permanente e sem carga externa, garantindo repetibilidade das condições de medição.

Parâmetros de aquisição dos sinais	
Parâmetro	Valor
Equipamento	SKF Microlog CX-75
Sensor	SKF CMSS 2111
Frequência de amostragem	2560 Hz
Resolução espectral	0,15625 Hz

⚠ Esta tabela possui muitas colunas e foi cortada para impressão. Para visualizá-la completa, acesse o artigo original em: <https://revistatopicos.com.br/artigos/aplicacao-de-tecnicas-de-aprendizado-de-maquina-na-deteccao-de-falhas-mecanicas-em-maquinas-rotativas-por-meio-da-analise-de-vibracoes?noblockage>

Tabela 3.1 – Parâmetros de Aquisição dos Sinais. Fonte: Autor (2026).

3.4. Condições Experimentais


Foram avaliadas quatorze condições operacionais distintas, abrangendo o funcionamento normal da bancada, diferentes níveis de desbalanceamento, diferentes níveis de desalinhamento e condições nas quais ambos os mecanismos de falha atuaram

simultaneamente. A condição balanceada e alinhada foi utilizada como referência de operação normal. As demais condições foram definidas de forma a isolar os efeitos do desbalanceamento ou do desalinhamento e, posteriormente, combinar ambos os defeitos, permitindo avaliar a capacidade dos modelos de aprendizado de máquina em identificar padrões vibratórios associados a diferentes níveis de severidade das falhas. Cada condição experimental foi composta por 120 sinais de vibração, obtidos por meio das quarenta aquisições realizadas em cada um dos três eixos de medição.

Condições experimentais avaliadas	
Condição	Descrição
C1	Desbalanceada eixo e alinhada
C2	Balanceada e alinhada
C3	Desbalanceada 3,4 g e alinhada
C4	Desbalanceada 5,4 g e alinhada
C5	Desbalanceada 8,4 g e alinhada

⚠ Esta tabela possui muitas colunas e foi cortada para impressão. Para visualizá-la completa, acesse o artigo original em: <https://revistatopicos.com.br/artigos/aplicacao-de-tecnicas-de-aprendizado-de-maquina-na-deteccao-de-falhas-mecanicas-em-maquinas-rotativas-por-meio-da-analise-de-vibracoes?noblockage>

Tabela 3.2 - Condições experimentais avaliadas. Fonte: Autor (2026)



Fonte: Autor (2026)

3.5. Processamento dos Sinais e Extração das Características

Após a aquisição, os sinais foram exportados para planilhas eletrônicas e processados computacionalmente em ambiente Python. Inicialmente, os sinais foram convertidos do domínio do tempo para o domínio da frequência utilizando a Transformada Rápida de Fourier (FFT). A partir dos espectros obtidos foram identificadas a frequência de rotação do eixo e as amplitudes correspondentes aos quatro primeiros harmônicos. Essas amplitudes constituíram as variáveis de entrada utilizadas pelos algoritmos de classificação, formando um conjunto reduzido de atributos diretamente relacionados aos mecanismos físicos responsáveis pelas alterações vibratórias observadas na bancada experimental. A utilização desse conjunto de características buscou representar as condições operacionais por meio de parâmetros de fácil interpretação física e baixo custo computacional.

Figura 3.3 - Fluxograma geral da metodologia empregada no desenvolvimento do trabalho.



Fonte: Autor (2026)

3.6. Construção da Base de Dados

A base de dados foi construída a partir das amplitudes da frequência de rotação e dos quatro primeiros harmônicos extraídos de cada aquisição. Cada registro foi associado à respectiva condição experimental, formando um conjunto de dados rotulado utilizado no treinamento supervisionado dos modelos de aprendizado de máquina. A organização da base permitiu manter a correspondência entre as características espectrais e as condições reais de operação da bancada, preservando a representatividade física dos dados utilizados durante o processo de classificação.

3.7. Modelos de Aprendizado de Máquina

Foram avaliados cinco algoritmos de classificação supervisionada:

- Árvore de Decisão;
- Random Forest;
- Support Vector Machine (SVM);

- K-Nearest Neighbors (KNN);
- Perceptron Multicamadas (MLP).

Todos os modelos foram treinados utilizando a mesma base de dados e o mesmo conjunto de atributos extraídos dos sinais de vibração, permitindo uma comparação direta entre as técnicas empregadas. Os hiperparâmetros de cada algoritmo foram definidos por meio de processo de otimização através da biblioteca *GridSearchCV* em python, garantindo condições equivalentes de treinamento para todos os classificadores.

3.8. Avaliação dos Modelos

O desempenho dos classificadores foi avaliado por meio das métricas de acurácia, precisão, revocação e escore F1, calculadas a partir das matrizes de confusão obtidas para cada algoritmo. Além dessas métricas, foram analisadas as curvas de aprendizado e a importância relativa das variáveis, permitindo comparar não apenas a capacidade de classificação dos modelos, mas também aspectos relacionados à generalização, interpretabilidade e contribuição de cada atributo para o processo de decisão.

4. RESULTADOS E DISCUSSÕES

4.1. Análise dos Espectros de Vibração


Inicialmente foram analisados os espectros de frequência correspondentes às diferentes condições experimentais da bancada, com o objetivo de verificar a influência das falhas introduzidas sobre a resposta vibratória do sistema. A transformação dos sinais para o domínio da frequência permitiu identificar alterações diretamente

relacionadas aos mecanismos físicos de desbalanceamento e desalinhamento, fornecendo as informações utilizadas posteriormente pelos algoritmos de aprendizado de máquina. Na condição balanceada e alinhada, adotada como referência de funcionamento normal, os resultados indicam um espectro caracterizado por baixas amplitudes ao longo da faixa de frequência analisada, indicando comportamento dinâmico compatível com a operação esperada da bancada experimental. A frequência de rotação apresentou predominância sobre as demais componentes espectrais, sem a presença de harmônicos significativos associados a mecanismos de falha. A introdução controlada de massas desbalanceadas promoveu aumento progressivo da amplitude na frequência de rotação, comportamento compatível com a literatura para esse tipo de defeito. À medida que a massa excêntrica foi aumentada, a análise revelou incremento correspondente na resposta vibratória, mantendo predominância da componente 1X. Nas condições de desalinhamento, além da frequência de rotação, a análise evidenciou que maior participação dos harmônicos superiores, indicando alteração no comportamento dinâmico do conjunto eixo-acoplamento. O aumento gradual do desalinhamento resultou em modificações sucessivas na distribuição espectral das amplitudes, evidenciando maior complexidade quando comparado às condições exclusivamente desbalanceadas.

As condições que combinaram desbalanceamento e desalinhamento apresentaram os espectros mais complexos do conjunto experimental, reunindo simultaneamente características associadas aos dois mecanismos de falha. Esses resultados corroboram a utilização de técnicas automáticas de classificação, uma vez que a interpretação visual desses espectros se torna progressivamente mais difícil à medida que múltiplos mecanismos


atuam simultaneamente sobre o sistema. Podemos notar na figura 4.1 que há um aparente destaque do segundo harmônico, mas se observamos a ordem de grandeza da amplitude desse harmônico, muito baixa, está dentro dos limites aceitáveis para condições de alinhamento.

Figura 4.1 – Balanceada e Alinhada.



Fonte: Autor (2026)

Figura 4.2 - Desbalanceada 7.4g e Alinhada.








Figura 4.3 - Balanceada e Desalinhada 5.



Fonte: Autor (2026)

Figura 4.4 – Desbalanceada 7.4g e Desalinhada 5.



Fonte: Autor (2026)

4.2. Construção das Características Utilizadas na Classificação

Após a análise dos espectros de vibração, procedeu-se à extração das características utilizadas no treinamento dos modelos de aprendizado de máquina. O objetivo dessa etapa foi representar cada condição experimental por meio de um conjunto reduzido de variáveis diretamente relacionadas ao comportamento vibratório da máquina, preservando a interpretação física dos dados e reduzindo a complexidade da base utilizada pelos classificadores. Inicialmente, os sinais adquiridos no domínio do tempo foram transformados para o domínio da frequência por meio da Transformada Rápida de Fourier (FFT). Em seguida, foram identificadas a frequência de rotação do eixo e as amplitudes correspondentes aos quatro primeiros harmônicos. Esses valores foram adotados como atributos da base de dados, por representarem as componentes espectrais mais diretamente influenciadas pelos mecanismos de desbalanceamento e desalinhamento avaliados neste estudo.

A escolha desse conjunto de características buscou manter uma relação direta entre os atributos utilizados pelos algoritmos e os fenômenos físicos observados na bancada experimental. Enquanto a componente correspondente à frequência de rotação apresentou maior sensibilidade às condições de desbalanceamento, os harmônicos superiores contribuíram para caracterizar as alterações provocadas pelo desalinhamento e pelas condições em que ambos os mecanismos de falha atuaram simultaneamente. Dessa forma, os atributos empregados preservam significado físico e permitem interpretar os resultados obtidos pelos modelos de classificação à luz do comportamento dinâmico da máquina.

A base de dados foi construída associando cada conjunto de amplitudes à respectiva condição experimental da bancada. Cada registro passou a representar uma aquisição individual de vibração,

identificada pela condição operacional correspondente. Essa organização permitiu que todos os algoritmos fossem treinados utilizando exatamente o mesmo conjunto de informações, garantindo uniformidade na comparação entre os diferentes métodos de classificação. A utilização de um número reduzido de atributos também contribuiu para simplificar o processo de treinamento dos modelos, evitando a inclusão de variáveis redundantes e favorecendo a interpretação dos resultados. Além disso, como todas as características empregadas possuem significado físico conhecido na análise de vibrações, tornou-se possível relacionar diretamente o desempenho dos classificadores às alterações espectrais observadas em cada condição experimental, aspecto que será discutido nas próximas subseções.

Figura 4.5 – Etapas do Processamento de Sinais



Fonte: Autor (2026)

Tabela 4.1 – Estrutura da base de dados utilizada. Fonte: Autor

Estrutura da base de dados utilizada	
Variável	Descrição

freq_rotacao	Frequência de rotação do eixo
harmonico_1	Amplitude em 1×
harmonico_2	Amplitude em 2×
harmonico_3	Amplitude em 3×
harmonico_4	Amplitude em 4×
defeito	Condição operacional

4.3. Desempenho dos Classificadores

A avaliação do desempenho dos modelos foi realizada utilizando o mesmo conjunto de atributos extraídos dos sinais de vibração para todos os algoritmos, permitindo uma comparação direta entre as técnicas de classificação estudadas. Foram avaliados os modelos Árvore de Decisão, Random Forest, Support Vector Machine (SVM), K-Nearest Neighbors (KNN) e Perceptron Multicamadas (MLP), empregando as mesmas condições de treinamento e validação descritas na metodologia.

A Tabela 4.2 apresenta o desempenho geral obtido por cada classificador.

Tabela 4.2 – Desempenho dos classificadores avaliados.

Método	Acurácia (%)	Desempenho geral
Árvore de Decisão	100,0	Excelente
Random Forest	100,0	Excelente

SVM	100,0	Excelente
KNN	99,8	Excelente
MLP	100,0	Excelente

Fonte: Autor (2026).

Observa-se que todos os algoritmos apresentaram desempenho elevado na classificação das condições experimentais. Quatro dos cinco modelos atingiram acurácia de 100% no conjunto de teste, enquanto o KNN apresentou acurácia de 99,8%, permanecendo igualmente classificado como de desempenho excelente. Essa pequena diferença não caracteriza superioridade prática entre os métodos, uma vez que todos foram capazes de identificar corretamente praticamente todas as amostras avaliadas. A grande proximidade entre os resultados indica que o conjunto de atributos utilizado apresentou significativa capacidade discriminante para representar as condições operacionais estudadas. Dessa forma, o desempenho observado não deve ser atribuído exclusivamente às características de um algoritmo específico, mas também à qualidade das informações extraídas dos sinais de vibração, que permitiram distinguir de forma consistente as condições normal, desbalanceada, desalinhada e de falhas combinadas.

Embora a acurácia seja uma métrica importante para avaliação inicial dos classificadores, ela não representa, isoladamente, todas as características de desempenho dos modelos. Diferenças relacionadas ao processo de aprendizado, à capacidade de generalização e à influência das variáveis de entrada tornam-se mais evidentes quando são analisadas as matrizes de confusão, as curvas de aprendizado e a importância relativa das características,

apresentadas nas subseções seguintes. Foi identificado que cada algoritmo apresentou comportamento distinto quanto à velocidade de convergência durante o treinamento, embora todos tenham alcançado desempenho final semelhante.

Os resultados obtidos reforçam ainda que as amplitudes da frequência de rotação e de seus quatro primeiros harmônicos constituíram um conjunto de atributos suficientemente representativo para caracterizar as diferentes condições experimentais da bancada. Assim, independentemente da técnica de classificação empregada, os modelos conseguiram estabelecer fronteiras de decisão capazes de separar adequadamente as classes analisadas.

4.4. Análise das Matrizes de Confusão


As matrizes de confusão foram utilizadas para analisar o desempenho dos classificadores em cada uma das condições experimentais, permitindo identificar a distribuição dos acertos e eventuais erros de classificação. Diferentemente da acurácia, essa ferramenta possibilita avaliar quais classes apresentam maior dificuldade de separação e verificar se existem padrões de confusão entre as condições operacionais estudadas.

A Figura 4.6 reúne as matrizes de confusão obtidas para os cinco algoritmos avaliados. Em síntese, observa-se considerável concentração dos elementos na diagonal principal, indicando que praticamente todas as amostras foram corretamente classificadas. Esse comportamento confirma os elevados índices de acurácia apresentados anteriormente e demonstra a grande capacidade dos modelos em distinguir as condições de operação da bancada

experimental. Nos modelos Árvore de Decisão, Random Forest, SVM e MLP, as matrizes apresentaram classificação integral das amostras do conjunto de teste, sem registros de erros entre as classes avaliadas. O KNN apresentou comportamento semelhante, diferindo apenas por um número reduzido de classificações incorretas, compatível com a acurácia de 99,8% obtida por esse algoritmo. Apesar dessa pequena diferença, o desempenho do KNN permaneceu equivalente ao dos demais métodos do ponto de vista prático, não comprometendo sua capacidade de identificação das condições experimentais.

Outro aspecto observado é a ausência de um padrão sistemático de confusão entre classes específicas. As condições de operação normal, desbalanceamento, desalinhamento e falhas combinadas permaneceram adequadamente separadas em todos os modelos, indicando que as características extraídas do domínio da frequência apresentaram consistente capacidade discriminante. Esse resultado reforça a hipótese de que as amplitudes da frequência de rotação e de seus quatro primeiros harmônicos são suficientes para representar as alterações vibratórias produzidas pelos mecanismos de falha investigados. A análise das matrizes de confusão demonstra que o desempenho obtido pelos classificadores decorreu da qualidade da representação dos dados experimentais, mais do que das particularidades de cada algoritmo. Embora os métodos empregados possuam princípios matemáticos distintos, todos foram capazes de estabelecer fronteiras de decisão adequadas para separar as condições operacionais estudadas

Figura 4.6 – Matrizes de Confusão Normalizadas, corroborando a consistência da metodologia adotada neste trabalho.



Fonte: Autor (2026)

4.5. Análise das Curvas de Aprendizado

As curvas de aprendizado foram utilizadas para avaliar a evolução do desempenho dos classificadores em função do aumento do conjunto de treinamento, permitindo analisar a capacidade de generalização de cada algoritmo e a quantidade de amostras necessária para estabilização do desempenho. Diferentemente da acurácia final, essa análise fornece informações sobre o comportamento do processo de treinamento, evidenciando diferenças que não são perceptíveis apenas pela comparação das métricas finais.


A Figura 4.7 apresenta as curvas de aprendizado obtidas para os cinco algoritmos avaliados. No conjunto de resultados, observou-se que todos os modelos apresentaram evolução consistente do desempenho à medida que novas amostras foram incorporadas ao treinamento, convergindo para altos índices de classificação. Esse comportamento demonstra que o conjunto de dados utilizado

possui características suficientemente representativas para o aprendizado dos diferentes modelos de classificação. Embora todos os classificadores tenham alcançado desempenho final semelhante, verificaram-se diferenças quanto à velocidade de convergência. A Árvore de Decisão apresentou rápida estabilização, atingindo seu desempenho máximo com um número reduzido de amostras de treinamento, comportamento coerente com a grande separabilidade dos atributos utilizados. A SVM também apresentou convergência relativamente rápida, alcançando desempenho muito satisfatório ainda nas primeiras etapas do treinamento. Em contrapartida, os modelos Random Forest e MLP necessitaram de um crescimento mais gradual do conjunto de treinamento até atingirem estabilidade, enquanto o KNN apresentou comportamento intermediário, mantendo boa capacidade de generalização mesmo com conjuntos reduzidos de dados. As diferenças observadas entre as curvas refletem características inerentes a cada algoritmo, relacionadas aos respectivos mecanismos de aprendizado. Entretanto, essas diferenças não resultaram em variações significativas no desempenho final, uma vez que todos os modelos convergiram para níveis de classificação considerados excelentes. Portanto, os resultados indicam que a escolha entre os algoritmos pode considerar aspectos como interpretabilidade, custo computacional e requisitos da aplicação, sem comprometer a capacidade de identificação das condições experimentais avaliadas.

Sob a perspectiva do conjunto de dados utilizado, as curvas de aprendizado reforçam a principal conclusão deste trabalho: as amplitudes da frequência de rotação e dos quatro primeiros harmônicos constituíram atributos capazes de representar adequadamente os diferentes estados operacionais da bancada

experimental. Assim, independentemente do método de classificação empregado, os modelos dispuseram de informações suficientes para estabelecer fronteiras de decisão consistentes, alcançando satisfatória capacidade de generalização.

Figura 4.7 – Curvas de Aprendizado



Fonte: Autor (2026)

4.6. Importância das Variáveis

Além da avaliação do desempenho dos classificadores, foi analisada a contribuição relativa das variáveis de entrada utilizadas pelos modelos. Essa etapa teve como objetivo verificar se as características extraídas dos sinais de vibração apresentavam coerência com os mecanismos físicos associados às falhas estudadas, permitindo relacionar o processo de classificação aos fenômenos observados experimentalmente. A análise da importância das variáveis foi realizada conforme as particularidades de cada algoritmo, considerando os critérios de avaliação disponíveis para cada modelo.

De forma geral, verificou-se que a frequência de rotação e seus quatro primeiros harmônicos apresentaram significativa capacidade discriminante para representar as diferentes condições operacionais da bancada experimental. Embora os algoritmos utilizem estratégias distintas para realizar a classificação, foi possível identificar que todos foram capazes de extrair informações relevantes desse conjunto reduzido de atributos, confirmando a consistência da metodologia empregada na construção da base de dados.


A interpretação dos resultados demonstra que as variáveis selecionadas possuem significado físico diretamente relacionado aos mecanismos de desbalanceamento e desalinhamento. A componente correspondente à frequência de rotação mostrou maior influência na identificação das condições de desbalanceamento, enquanto os harmônicos superiores contribuíram para caracterizar as alterações provocadas pelo desalinhamento e pelas condições em que ambos os defeitos ocorreram simultaneamente. Consequentemente, os atributos empregados permitiram representar adequadamente as diferentes respostas vibratórias observadas durante os ensaios experimentais.

Outro aspecto relevante é que o desempenho obtido pelos modelos foi alcançado utilizando um conjunto reduzido de variáveis. Esse resultado demonstra que não foi necessária a utilização de um grande número de atributos estatísticos ou espectrais para distinguir as condições avaliadas. A seleção de características diretamente associadas ao comportamento físico da máquina possibilitou reduzir a complexidade da base de dados sem comprometer a capacidade de classificação dos algoritmos. Os resultados obtidos reforçam que a qualidade das características de entrada exerceu papel determinante no desempenho dos

classificadores. Assim, a capacidade de separação observada ao longo deste trabalho deve ser atribuída, principalmente, à representatividade física dos atributos extraídos do domínio da frequência, e não exclusivamente às diferenças existentes entre os algoritmos de aprendizado de máquina empregados. Essa constatação complementa as análises apresentadas nas subseções anteriores e fornece a base para a discussão geral dos resultados apresentada a seguir.

Figura 4.8 – Importância das Variáveis

Figura 11 – Importância relativa das variáveis utilizadas pelos classificadores.



Nota: Amp_1X, Amp_2X, Amp_3X e Amp_4X representam as amplitudes da frequência de rotação (1X) e dos respectivos harmônicos (2X, 3X e 4X).
Freq_1X corresponde à frequência fundamental de rotação (1X).

Fonte: Autor (2026).

Fonte: Autor (2026)

5. CONCLUSÃO E CONSIDERAÇÕES FINAIS

Os resultados obtidos demonstraram que as cinco técnicas de aprendizado de máquina avaliadas apresentaram elevada capacidade para identificar as diferentes condições operacionais da bancada experimental. A comparação entre Árvore de Decisão, Random Forest, Support Vector Machine (SVM), K-Nearest

Neighbors (KNN) e Perceptron Multicamadas (MLP) evidenciou desempenhos praticamente equivalentes, com acurácia igual a 100,0% para quatro algoritmos e 99,8% para o KNN. Essa proximidade indica que o bom desempenho observado não pode ser atribuído exclusivamente às características particulares de um algoritmo específico, mas principalmente à qualidade das informações utilizadas como entrada pelos modelos. A análise conjunta das matrizes de confusão, das curvas de aprendizado e da importância das variáveis mostrou que as amplitudes da frequência de rotação e de seus quatro primeiros harmônicos constituíram um conjunto de atributos suficientemente representativo para descrever as diferentes condições experimentais avaliadas. A relação direta entre essas componentes espectrais e os mecanismos físicos de desbalanceamento e desalinhamento permitiu que algoritmos baseados em princípios matemáticos distintos estabelecessem fronteiras de decisão consistentes, alcançando grande capacidade de generalização.

Outro aspecto observado foi que modelos com diferentes níveis de complexidade apresentaram desempenho final semelhante. Enquanto alguns algoritmos convergiram rapidamente durante o treinamento e outros necessitaram de maior quantidade de amostras para estabilização, todos alcançaram excelente desempenho na classificação das condições operacionais. Esse comportamento reforça que, para o problema investigado, a seleção de atributos com significado físico exerceu maior influência sobre os resultados do que a sofisticação matemática dos classificadores empregados. Sob a perspectiva de aplicação industrial, os resultados obtidos demonstram que a utilização de técnicas de aprendizado de máquina associadas à análise espectral de vibrações constitui uma alternativa viável para o diagnóstico automatizado de falhas

mecânicas em máquinas rotativas. A utilização de um conjunto reduzido de características, diretamente relacionadas ao comportamento vibratório do sistema, simplifica a implementação dos modelos e favorece sua interpretação, aspectos importantes para aplicações em programas de manutenção preditiva.

Isso indica que o objetivo proposto neste trabalho foi alcançado, demonstrando que as técnicas de aprendizado de máquina avaliadas são capazes de identificar as condições de operação normal, desbalanceamento, desalinhamento e falhas combinadas a partir de atributos extraídos dos sinais de vibração. Mais do que comparar algoritmos, o estudo evidenciou que a representatividade física das características obtidas pela Transformada Rápida de Fourier (FFT) foi determinante para o elevado desempenho observado em todos os modelos analisados. Essa constatação representa a principal contribuição deste trabalho, ao demonstrar que um conjunto reduzido de atributos espectrais pode fornecer informações suficientes para o diagnóstico automatizado de falhas em máquinas rotativas.

Como limitações, destaca-se que os ensaios foram realizados em uma bancada experimental, sob condições controladas de operação e considerando apenas os mecanismos de desbalanceamento, desalinhamento e suas combinações. Embora essas condições permitam boa repetibilidade e controle das variáveis experimentais, aplicações industriais podem envolver a ocorrência simultânea de outros tipos de falhas e condições operacionais mais complexas. Nesse contexto, trabalhos futuros poderão ampliar a base experimental, incluir novos mecanismos de falha e avaliar o desempenho dos modelos em ambientes industriais reais,

contribuindo para o desenvolvimento de sistemas de monitoramento de condição cada vez mais robustos.

REFERÊNCIAS BIBLIOGRÁFICAS

ALCÁNTARA, J. et al. *Predictive maintenance in Industry 4.0: a systematic review*. Computers & Industrial Engineering, v. 159, 2021.

BENTLY, D. E.; HATCH, C. T. *Fundamentals of Rotating Machinery Diagnostics*. Minden: Bently Pressurized Bearing Press, 2003.

BREIMAN, Leo; FRIEDMAN, Jerome H.; OLSHEN, Richard A.; STONE, Charles J. *Classification and Regression Trees*. New York: Chapman & Hall, 1984.

BREIMAN, Leo. *Random forests*. Machine Learning, v. 45, n. 1, p. 5–32, 2001.

BRIGHAM, E. Oran. *The Fast Fourier Transform and Its Applications*. New Jersey: Prentice Hall, 1988.

BRITO, Lucas; SUSTO, Gian Antonio; BRITO, Jorge; DUARTE, Marcus. *An explainable artificial intelligence approach for unsupervised fault detection and diagnosis in rotating machinery*. Mechanical Systems and Signal Processing, v. 163, 2022.

CARVALHO, T. P. et al. *A systematic literature review of machine learning methods applied to predictive maintenance*. Computers & Industrial Engineering, v. 137, 2019.

CORTES, Corinna; VAPNIK, Vladimir. *Support-vector networks*. Machine Learning, v. 20, p. 273–297, 1995.

COVER, Thomas M.; HART, Peter E. *Nearest neighbor pattern classification*. IEEE Transactions on Information Theory, v. 13, n. 1, p. 21–27, 1967.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. *Deep Learning*. Cambridge: MIT Press, 2016.

HASTIE, Trevor; TIBSHIRANI, Robert; FRIEDMAN, Jerome. *The Elements of Statistical Learning*. 2. ed. New York: Springer, 2009.

JARDINE, Andrew K. S.; LIN, Daming; BANJEVIC, Dragan. *A review on machinery diagnostics and prognostics implementing condition-based maintenance*. Mechanical Systems and Signal Processing, v. 20, n. 7, p. 1483–1510, 2006.

MOBLEY, R. Keith. *An Introduction to Predictive Maintenance*. 2. ed. Oxford: Elsevier, 2002.

MUSZYNSKA, Agnes. *Rotordynamics*. Boca Raton: CRC Press, 2005.

OPPENHEIM, Alan V.; SCHAFER, Ronald W. *Discrete-Time Signal Processing*. 3. ed. New Jersey: Prentice Hall, 2010.

PEDREGOSA, Fabian et al. *Scikit-learn: Machine Learning in Python*. Journal of Machine Learning Research, v. 12, p. 2825–2830, 2011.

RANDALL, Robert B. *Vibration-Based Condition Monitoring: Industrial, Aerospace and Automotive Applications*. Chichester: Wiley, 2011.

RAO, Singiresu S. *Mechanical Vibrations*. 6. ed. Boston: Pearson, 2017.

RUMELHART, David E.; HINTON, Geoffrey E.; WILLIAMS, Ronald J. *Learning representations by back-propagating errors*. Nature, v. 323, p. 533–536, 1986.

SCHEFFER, Cornelius; GIRDHAR, Paresh. *Practical Machinery Vibration Analysis and Predictive Maintenance*. Amsterdam: Elsevier, 2004.

SINGH, S. et al. *Machine learning-based fault diagnosis of rotating machinery: a review*. IEEE Access, v. 10, 2022.

VIRTANEN, Pauli et al. *SciPy 1.0: Fundamental Algorithms for Scientific Computing in Python*. Nature Methods, v. 17, p. 261–272, 2020.

XIA, M. et al. *Intelligent fault diagnosis based on deep learning for rotating machinery*. Mechanical Systems and Signal Processing, v. 172, 2022.

ZHOU, W. et al. *Experimental investigation of rotor misalignment and unbalance faults*. Measurement, v. 178, 2021.

¹ Discente do Curso Superior de Engenharia Mecânica da Universidade Federal de São João del Rei. Campus Santo Antonio. E-mail: [acesse o artigo original para visualizar o e-mail](#)

² Docente do Curso Superior de Engenharia Mecânica da Universidade Federal de São João del Rei. Campus Santo Antonio. E-mail: [acesse o artigo original para visualizar o e-mail](#)

³ Docente do Curso Superior de Engenharia Mecânica da Universidade Estadual de Campinas. Campus Santo Antonio. E-mail: [acesse o artigo original para visualizar o e-mail](#)