

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA - CCET
DEPARTAMENTO DE ENGENHARIA MECÂNICA - DEMEC

Isac José Silva Miranda

**Aplicação de SVM na Classificação de Falhas em Rolamentos: Uma
Comparação entre o Domínio Tempo e Tempo-Frequência**

SÃO CARLOS -SP
2023

ISAC JOSÉ SILVA MIRANDA

**Aplicação de SVM na Classificação de Falhas em Rolamentos: Uma Comparação
entre o Domínio Tempo e Tempo-Frequência**

Monografia apresentada ao Departamento de engenharia mecânica da Universidade Federal de São Carlos, como requisito parcial para obtenção do título de bacharel em engenharia mecânica.

Orientador: Prof. Dr. Sidney Bruce Shiki

São Carlos-SP
2023



FUNDAÇÃO UNIVERSIDADE FEDERAL DE SÃO CARLOS
COORDENAÇÃO DO CURSO DE ENGENHARIA MECÂNICA - CCEMec/CCET
Rod. Washington Luís km 235 - SP-310, s/n - Bairro Monjolinho, São Carlos/SP, CEP 13565-905
Telefone: (16) 33519703 - <http://www.ufscar.br>

DP-TCC-FA nº 5/2023/CCEMec/CCET

Graduação: Defesa Pública de Trabalho de Conclusão de Curso
Folha Aprovação (GDP-TCC-FA)

FOLHA DE APROVAÇÃO

ISAC JOSÉ SILVA MIRANDA

APLICAÇÃO DE SVM NA CLASSIFICAÇÃO DE FALHAS EM ROLAMENTOS: UMA COMPARAÇÃO ENTRE O DOMÍNIO TEMPO E TEMPO-FREQUÊNCIA

Trabalho de Conclusão de Curso

Universidade Federal de São Carlos – Campus São Carlos

São Carlos, 16 de março de 2023

ASSINATURAS E CIÊNCIAS

Cargo/Função	Nome Completo
Orientador	Sidney Bruce Shiki
Membro da Banca 1	João Vitor de Carvalho Fontes
Membro da Banca 2	Vitor Ramos Franco



Documento assinado eletronicamente por **Sidney Bruce Shiki, Docente**, em 16/03/2023, às 11:54, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Vitor Ramos Franco, Docente**, em 16/03/2023, às 11:54, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Joao Vitor de Carvalho Fontes, Docente**, em 16/03/2023, às 11:56, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site <https://sei.ufscar.br/autenticacao>, informando o código verificador **0972210** e o código CRC **BF331D43**.

Referência: Caso responda a este documento, indicar expressamente o Processo nº 23112.007899/2023-24

SEI nº 0972210

DEDICATÓRIA

Dedico este trabalho a todos que me acompanharam nesta jornada, em especial aos meus familiares, amigos e professores, que me apoiaram e incentivaram durante todo o processo.

AGRADECIMENTO

Gostaria de expressar minha gratidão a todas as pessoas que contribuíram para a realização deste trabalho. Primeiramente, agradeço ao meu orientador, Prof. Dr. Sidney Bruce Shiki, pela orientação, paciência e incentivo. Agradeço também aos professores e funcionários da UFSCar, que forneceram conhecimentos e direcionamentos durante toda a minha jornada na instituição.

Não poderia deixar de mencionar meus amigos e familiares, que me apoiaram em todos os momentos, mesmo quando eu estava sobrecarregado e cansado. Seus encorajamentos e palavras de ânimo foram fundamentais para me manter motivado e focado.

Aqueles que passam por nós não vão sós, não nos deixam sós. Deixam um pouco de si, levam um pouco de nós.

(Antoine de Saint-Exupéry)

RESUMO

Para otimizar a eficiência operacional de elementos mecânicos, a manutenção preditiva é uma técnica importante para detectar falhas em componentes antes de consequências mais graves, como acidentes, perdas de produtividade e paradas inesperadas em processos produtivos. Este trabalho utilizou análises de vibração para classificar falhas em rolamentos esféricos por meio de sinais de vibração adquiridos em rolamentos sem falhas e com falhas pontuais inseridas em seus elementos. Foram utilizados descritores estatísticos (desvio-padrão, valor de rms e fator de forma) no domínio tempo e a transformada wavelet packet com valores de energia e entropia de Shannon no tempo-frequência para realizar as análises. A classificação dos dados foi realizada por meio do algoritmo de aprendizado de máquina SVM (Support Vector Machine). Ambas as abordagens se mostraram eficazes na discriminação dos sinais, com acurácias de predição de 97,92% e 100%, respectivamente, demonstrando a aplicabilidade da técnica na identificação de falhas em rolamentos esféricos. A abordagem tempo-frequência foi mais eficaz do que a abordagem no domínio tempo, uma vez que algumas falhas foram classificadas erroneamente nesta última.

Palavras-chave: SVM; falhas em rolamentos; *wavelet packet transform*; manutenção preditiva.

ABSTRACT

In order to enhance the operational efficiency of mechanical components, predictive maintenance has emerged as a critical technique for detecting potential failures before they lead to severe consequences such as accidents, productivity losses, and unexpected disruptions in production processes. This investigation employed vibration analysis to differentiate faults in spherical bearings, utilizing vibration signals collected from both faultless bearings and those bearing point defects. Statistical descriptors such as standard deviation, root mean square value, and shape factor were employed in the time domain, while the wavelet packet transform, featuring energy values and Shannon entropy in the time-frequency domain, was used to perform the analyses. The data was classified using the Support Vector Machine (SVM) machine learning algorithm. Both approaches demonstrated their effectiveness in discerning the signals, with prediction accuracies of 97.92% and 100%, respectively, highlighting the feasibility of this technique for fault identification in spherical bearings. The time-frequency approach was more effective than the time domain approach, as the latter yielded misclassifications in certain cases.

Keyword: SVM, bearing failures, wavelet packet transform, predictive maintenance.

LISTA DE ILUSTRAÇÕES

Figura 1 - Componentes presentes em um rolamento esférico.....	22
Figura 2 - Características geométricas de um rolamento de esferas	24
Figura 3 - Possíveis planos de separação para duas classes.....	35
Figura 4 - Hiperplano em diferentes domínios	36
Figura 5 - Separação de duas classes com margem dura	37
Figura 6 - Separação de duas classes com margem suave.....	38
Figura 7 - Separação de duas classes não linearmente separáveis adotando uma função de Kernel	39
Figura 8 - Experimento para aquisição de dados de vibração	44
Figura 9 – Boxplot (sem <i>outliers</i>) descritores estatísticos por classe	49
Figura 10 – Boxplot (com <i>outliers</i>) descritores estatísticos por classe	49
Figura 11 – Pseudocódigo para o método Relief-F	51
Figura 12 - Árvore de decomposição do sinal em 5 níveis.....	52
Figura 13 - Sinal no domínio tempo sem defeito	55
Figura 14 - Sinal PI7 em comparação ao sinal SD.....	56
Figura 15 - Sinal SD em comparação ao sinal ESF7	57
Figura 16 - Sinal SD em comparação ao sinal PE7	57
Figura 17 - Sinal SD em comparação ao sinal PI21	58
Figura 18 - Sinal SD em comparação ao sinal ESF21	58
Figura 19 - Sinal SD em comparação ao sinal PE21	59
Figura 20 - Números de descritores e a acurácia para funções de Kernel - Domínio tempo	61
Figura 21 - Números de descritores e a custo computacional para funções de Kernel – Domínio tempo.....	61
Figura 22 - Números de descritores e a acurácia para funções de Kernel - Tempo- frequência	63
Figura 23 - Números de descritores e a custo computacional para funções de Kernel - Tempo-frequência	64
Figura 24 - Matriz de confusão - Domínio Tempo	66
Figura 25 - Matriz de confusão - Domínio tempo-frequência	67

LISTA DE TABELAS

Tabela 1 - Equações das frequências características de falhas	25
Tabela 2 - Dimensões em polegadas do rolamento SKF 6205-2RSL JEM.....	45
Tabela 3 - Características dos dados disponibilizados.....	45
Tabela 4 – Informações de dados de vibração não segmentados	46
Tabela 5 – Dados segmentados	46
Tabela 6 – Classe adotada para cada defeito.....	47
Tabela 7 - Dimensão dos dados com descritores estatísticos	48
Tabela 8 - Índices e pesos atribuídos a cada descritor	51
Tabela 9 - Dimensão dos dados com descritores - Entropia de Shannon e Energia	52
Tabela 10 - Índices e pesos atribuídos a cada descritor – Tempo-Frequência	53
Tabela 11 - Representação das classes nos dados de treinamento	53
Tabela 12 - Descritores estatísticos - Domínio tempo.....	60
Tabela 13 - Energia e Entropia de Shannon - Domínio tempo-frequência	62
Tabela 14 - Acurácias para dados de treino e teste em diferentes domínios.....	65

SUMÁRIO

1 INTRODUÇÃO	15
1.2 OBJETIVO	16
1.2.1 OBJETIVOS ESPECÍFICOS	16
1.3 APRESENTAÇÃO DO TRABALHO	16
2 FUNDAMENTAÇÃO TEÓRICA.....	18
2.1 ESTRATÉGIAS DE MANUTENÇÃO.....	18
2.1.1 MANUTENÇÃO CORRETIVA.....	19
2.1.2 MANUTENÇÃO PREVENTIVA	19
2.1.3 MANUTENÇÃO PREDITIVA.....	20
2.2 ROLAMENTOS	21
2.2.1 FREQUÊNCIAS CARACTERÍSTICAS DE FALHA DE ROLAMENTOS	23
2.3 ANÁLISE DE SINAL DE VIBRAÇÃO	25
2.3.1 ANÁLISE DE SINAIS DE VIBRAÇÃO NO DOMÍNIO TEMPO	26
2.3.2 ANÁLISE DE SINAIS DE VIBRAÇÃO NO DOMÍNIO DA FREQUÊNCIA.....	28
2.3.3 ANÁLISE DE SINAL DE VIBRAÇÃO NO DOMÍNIO TEMPO-FREQUÊNCIA .	29
2.3.3.1 TRANSFORMADA WAVELET	30
2.4 SVM	35
3 MATERIAIS E MÉTODOS	43
3.1 FERRAMENTAS UTILIZADAS.....	43
3.2 DESCRIÇÃO DA BASE DE DADOS.....	43
3.3 SEGMENTAÇÃO DOS DADOS.....	45
3.4 EXTRAÇÃO DE DESCRITORES.....	47
3.4.1 DOMÍNIO TEMPO.....	47
3.4.1.1 SELEÇÃO DE DESCRITORES RELEVANTES AO SVM	48
3.4.2 DOMÍNIO TEMPO-FREQUÊNCIA	51
3.4.2.1 SELEÇÃO DE DESCRITORES RELEVANTES AO SVM	53
3.4 APLICAÇÃO DO CLASSIFICADOR SVM.....	53
4 RESULTADOS.....	55
5 CONSIDERAÇÕES FINAIS	68
REFERÊNCIAS.....	70

1 INTRODUÇÃO

A manutenção preditiva é uma técnica utilizada para reduzir custos e aumentar a eficiência operacional. Ela tem como objetivo prever falhas em equipamentos antes que elas ocorram, permitindo que a manutenção seja realizada de forma planejada e eficiente. No contexto de máquinas que possuem rolamentos esféricos, a manutenção preditiva é especialmente importante, uma vez que a falha desses componentes pode levar a uma série de problemas operacionais, tais como paradas não planejadas, perda de produtividade e até mesmo acidentes (KARDEC; NASCIF, 2014).

A classificação de falhas em rolamentos esféricos é um desafio importante na manutenção preditiva. Existem diversas técnicas que podem ser utilizadas para essa finalidade, tais como análise de vibração, análise de ruído, análise térmica, entre outras (GIRDHAR, 2004). Neste trabalho, optou-se por utilizar a análise de vibração, uma vez que ela é uma técnica bem estabelecida e que tem se mostrado eficiente na detecção e classificação de falhas em rolamentos.

Para realizar a análise de vibração, é necessário capturar o sinal gerado pelo rolamento em operação. Esse sinal pode ser processado no domínio tempo, no domínio da frequência ou em ambos. No domínio tempo, é possível extrair descritores estatísticos, tais como média, desvio padrão, assimetria e curtose, os quais representam, de forma condensada, a forma da onda do sinal de vibração. No domínio da frequência, é possível utilizar a transformada de Fourier para obter o espectro de frequência do sinal (SANTOS, 2017)

Uma abordagem que tem se mostrado eficiente na análise de sinais de vibração é a utilização da transformada *wavelet*, que permite realizar a análise tanto no domínio tempo quanto no domínio da frequência. A *wavelet packet transform* é uma variação da transformada *wavelet* que permite a análise de sinais com alta resolução em diferentes escalas de frequência.

A extração de descritores estatísticos e atributos de energia e entropia de Shannon são técnicas valiosas para caracterizar o comportamento do sinal, respectivamente, no domínio do tempo e no domínio tempo-frequência. Esses descritores e atributos podem ser usados como entrada para algoritmos de aprendizado de máquina para classificação, como o SVM (*Support Vector Machine*).

O SVM é um algoritmo de classificação que tem se mostrado eficiente em uma série de aplicações (KECMAN, 2005). Ele é capaz de classificar dados em diferentes classes com base em um conjunto de treinamento. No contexto de rolamentos esféricos, o SVM pode ser utilizado para classificar sinais em diferentes categorias, tais como sinais correspondendo à estrutura saudável, sinais com falhas incipientes e sinais com falhas avançadas.

1.2 OBJETIVO

Este trabalho tem como objetivo principal contribuir para o desenvolvimento de técnicas de manutenção preditiva em rolamentos esféricos, avaliando a acurácia do algoritmo de aprendizado de máquina SVM no domínio tempo e no domínio tempo-frequência.

1.2.1 OBJETIVOS ESPECÍFICOS

São objetivos específicos deste trabalho:

- Segmentar adequadamente os sinais adquiridos;
- Extrair descritores estatísticos no domínio tempo;
- Extrair os valores de energia e entropia de Shannon na análise no domínio tempo-frequência;
- Classificar a relevância dos descritores extraídos por meio do método Relief-F;
- Aplicar e otimizar os parâmetros do classificador SVM;
- Avaliar a acurácia do algoritmo SVM na classificação de diferentes classes em rolamentos esféricos.

1.3 APRESENTAÇÃO DO TRABALHO

A estrutura deste trabalho é composta por cinco capítulos. No primeiro capítulo, é apresentada a introdução ao tema, com a justificativa da escolha do tema, objetivo geral e específicos.

No segundo capítulo, é realizada a fundamentação teórica relacionada à manutenção, principalmente à preditiva, análise de vibração, rolamentos esféricos, transformada *wavelet* e suas variáveis, descritores estatísticos, energia entropia de

Shannon em sinais e SVM.

No terceiro capítulo, é apresentada a metodologia utilizada para a realização deste trabalho, com detalhes sobre a coleta de dados, pré-processamento dos sinais, extração de descritores e aplicação do SVM.

No quarto capítulo, são apresentados os resultados obtidos neste trabalho, com a análise e interpretação dos dados coletados e processados, bem como a avaliação da eficiência dos algoritmos de classificação.

No quinto e último capítulo, são apresentadas as conclusões do trabalho, com uma síntese dos principais resultados obtidos, as contribuições do trabalho e as limitações encontradas, bem como as sugestões para trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 ESTRATÉGIAS DE MANUTENÇÃO

Estratégias de manutenção estão diretamente ligadas ao momento histórico-social ao qual a sociedade se encontra, os últimos 50 anos apontam as diversas mudanças que atividades de manutenção tem passado. Essas alterações são devidas ao aumento do número e complexidade dos itens a serem mantidos, às novas técnicas de manutenção e necessidade constante aumento de produtividade.

Segundo Kardec e Nascif (2014), a partir da década de 30 a forma de enxergar e executar manutenções pode ser dividida em três principais gerações:

- A primeira geração é a qual abrange o período prévio à segunda guerra mundial, em um cenário industrial pouco mecanizado, com equipamentos simples e via de regra super dimensionados e no âmbito socioeconômico a produtividade não era prioritária. A estratégia de manutenção que melhor supria as necessidades era a corretiva, com serviços de limpeza, lubrificação e reparo após a quebra do equipamento ou componente.
- A segunda geração é situada entre o início da segunda grande guerra e meados da década de 60, neste período houve a redução da mão de obra, a necessidade de aumento de produtividade e equipamentos mais complexos. A estratégia de manutenção se adequou às necessidades vigentes, sendo necessário sistemas de planejamento e controle de manutenção, o que pode ser classificado em linhas gerais como estratégia de manutenção preventiva.
- A terceira geração é pautada a partir da década de 70, onde acelerou-se o processo de mudança nas indústrias, onde as paralisações na produção se tornavam cada vez mais críticas dado a aderência ao sistemas “just-in-time”, onde estoques reduzidos para a produção significavam que pequenas pausas poderiam causar a paralisação das fábricas. O aumento das automações e capacidade de análise indicadores de bom funcionamento dos equipamentos oriundos dessa geração aceleraram a ampliação do conceito de manutenção preditiva.

Ao longo das décadas percebeu-se que a falta de manutenção ou aplicação da estratégia inadequada pode acarretar diversos prejuízos para uma organização,

como, o aumento do custo de produção, paradas não planejadas, diminuição da qualidade e não uniformidade dos produtos.

Definir uma estratégia de manutenção para uma organização considera diversos pontos, como, características das instalações, equipamentos, capacidade produtiva, custos atrelados à produção etc. Os três principais tipos de manutenção são definidos conforme as formas de intervenção, sendo utilizados por organizações não somente de forma isolada, porém em conjunto para maximizar a eficiência da estratégia adotada.

2.1.1 MANUTENÇÃO CORRETIVA

A manutenção corretiva é uma técnica de manutenção que se concentra na correção de problemas após a sua ocorrência. É uma abordagem reativa, onde a manutenção é realizada apenas após a detecção de uma falha. A manutenção corretiva é geralmente mais cara do que a manutenção preventiva, pois exige mais tempo, mão de obra e materiais. Além disso, as interrupções dos processos são mais frequentes e prolongadas (KARDEC; LAFRAIA, 2002).

Ainda de acordo com Kardec e Lafraia (2002), a manutenção corretiva é dividida em duas categorias: manutenção corretiva programada e manutenção corretiva não programada. A manutenção corretiva programada é aquela realizada em horários predefinidos e com o objetivo de evitar ou minimizar as falhas. Já a manutenção corretiva não programada é aquela realizada fora do horário programado devido a uma falha inesperada.

A manutenção corretiva tem vital importância para garantir a disponibilidade dos equipamentos e destaca a necessidade de se ter uma equipe de manutenção altamente treinada e experiente para realizar as atividades de manutenção corretiva de forma eficiente.

2.1.2 MANUTENÇÃO PREVENTIVA

A manutenção preventiva é uma técnica fundamental para garantir o correto funcionamento de máquinas, equipamentos e instalações. Ela consiste em realizar inspeções regulares, limpando, lubrificando e substituindo peças desgastadas antes que surjam problemas. Desta forma, a manutenção preventiva prolonga a vida útil das máquinas e garante a continuidade da produção, evitando interrupções (KARDEC;

NASCIF, 2014).

De acordo com Kardec e Lafraia (2002), a manutenção preventiva é considerada uma das melhores formas de garantir a eficiência e a continuidade da produção de uma empresa. Além disso, a manutenção preventiva aumenta a segurança dos funcionários, diminuindo os custos com reparos e manutenção corretiva.

A implementação de uma programação de manutenção preventiva é essencial para garantir a boa condição das máquinas e equipamentos. Os planos de inspeção e avaliação periódicos permitem identificar problemas antes que eles ocorram, permitindo que as equipes de manutenção corrijam-nos antes que evoluam para situações mais graves. Isso ajuda a garantir a continuidade da produção, aumenta a eficiência e evita interrupções no funcionamento dos equipamentos. Além disso, a manutenção preventiva é uma aliada ao meio ambiente e a segurança dos funcionários, uma vez que equipamentos danificados podem liberar resíduos perigosos (KARDEC; NASCIF, 2014).

2.1.3 MANUTENÇÃO PREDITIVA

A manutenção preditiva é uma técnica avançada que visa identificar problemas potenciais em equipamentos antes que eles ocorram. Ela tem como objetivo maximizar a disponibilidade dos equipamentos e minimizar os custos de manutenção. De acordo com Kardec e Lafraia (2002), a manutenção preditiva é baseada em dados e análises avançadas, que permitem prever a degradação de componentes críticos antes da ocorrência de uma falha.

A manutenção preditiva utiliza tecnologias avançadas, como sensores, sistemas de monitoramento, inteligência artificial e análise de dados para coletar e processar informações sobre o desempenho dos equipamentos. Com base nestas informações, é possível identificar problemas potenciais e agendar manutenções preventivas de forma não prematura e antes que as falhas ocorram. Esta abordagem é mais eficiente e econômica do que a manutenção corretiva, pois corrige problemas antes que eles se tornem graves e causem interrupções na produção (KARDEC; LAFRAIA, 2002).

A manutenção preditiva é aplicável a uma ampla gama de equipamentos, incluindo máquinas industriais, equipamentos de transporte, sistemas elétricos e de

refrigeração, especialmente em indústrias que requerem equipamentos críticos para a produção, como a mineração, petroquímica e indústria de energia.

Além dos benefícios econômicos, a manutenção preditiva é importante para a segurança dos trabalhadores e meio ambiente. Ela previne problemas e agenda manutenções preventivas, reduzindo o risco de acidentes e emissão de poluentes. A manutenção preditiva também pode melhorar a eficiência energética dos equipamentos, o que é interessante do ponto de vista ambiental.

De acordo com Kardec e Lafraia (2002), a manutenção preditiva é cada vez mais importante para as empresas que buscam maximizar a disponibilidade dos equipamentos, minimizar os custos de manutenção e melhorar a eficiência energética. Para aproveitar ao máximo os benefícios da manutenção preditiva, as empresas precisam investir em tecnologias avançadas e capacitar seus funcionários para coletar e analisar dados.

O monitoramento da condição de determinado elemento pode ser feito por meio de vibração, emissão acústica, análise de óleo, análise de partículas, monitoramento de espessuras, termografia, monitoramento de performance, corrente e voltagem. Contudo, a análise da vibração é a prática mais eficiente para detecção de falhas em rolamentos de elementos rolantes (GIRDHAR, 2004).

2.2 ROLAMENTOS

Rolamentos são amplamente utilizados em máquinas rotativas e possuem a função de conectar partes fixas e móveis de uma máquina, possuem um preço razoavelmente pequeno quando comparado aos demais elementos de máquina e são os principais responsáveis por paradas para manutenção em máquinas rotativas (YANG; MATHEW; MA, 2005).

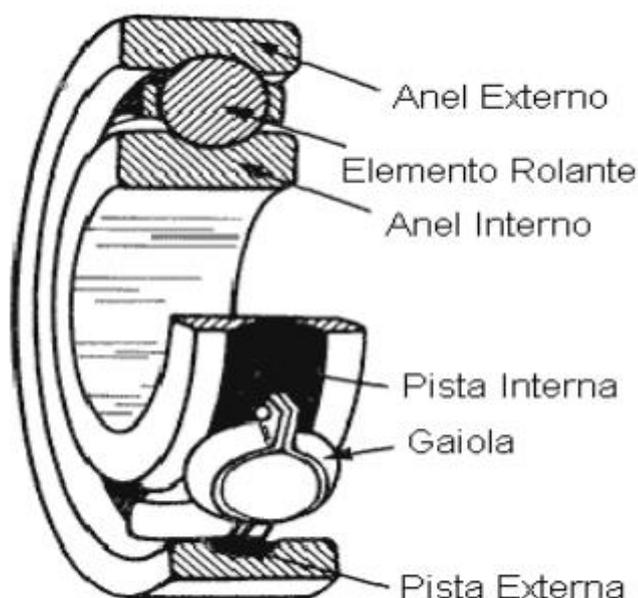
Existem diversos tipos de rolamento, os quais são classificados por meio de seu tipo de elemento rolante, os principais rolamentos adotados na indústria são os rolamentos esféricos e de rolos ou cilindros.

Os rolamentos de esferas possuem rotação suave e capacidade de carga reduzida, dado a pequena área de contato entre as pistas internas e externas. Exemplos de sua aplicação são em polias, discos rígidos, caixa de transmissão e eixo de motores. São ilustrados na Figura 1 os principais componentes presentes em um rolamento de esferas.

Os rolamentos de rolos suportam cargas maiores em comparação aos rolamentos de esferas, contudo, perdem a capacidade de suportar cargas caso os trilhos estejam desalinhados. Possuem ampla aplicação em veículos ferroviários, máquinas de vibração e em transmissões.

Rolamentos são considerados elementos mecânicos críticos e a principal origem de falhas em equipamentos mecânicos. A vida de um rolamento é, via de regra, menor que a dos demais elementos de máquina, contudo, é possível ampliar a vida do rolamento com a adoção de alguns cuidados, como, resfriamento, limpeza, lubrificação adequada e não utilização de carregamentos superiores aos definidos via projeto (SHIGLEY, MISCHKE, 1990).

Figura 1 - Componentes presentes em um rolamento esférico



Fonte: (MESQUITA, 2002)

Os defeitos em rolamentos podem ser definidos como locais ou distribuídos, onde defeitos distribuídos são atribuídos ao processo de fabricação que o elemento fora submetido, instalação inadequada ou desgaste dos componentes. São exemplos de defeitos distribuídos rugosidade superficial, ondulações, desalinhamento entre as pistas e montagem incorreta.

Os defeitos em rolamentos estão localizados na sua pista interna, pista externa, elementos rolantes ou gaiola, cada uma dessas falhas possíveis acarreta

impulsos no sinal de vibração quando uma falha colide com outra superfície (SAWALHI; RANDALL; ENDO, 2007).

WEBER et al. (2009) aponta que os defeitos em rolamentos evoluem vagarosamente e emitem sinais com bastante antecedência da falha catastrófica, permitindo por meio de análise do comportamento dos sinais a ação preventiva para substituição do rolamento defeituoso.

Berry (1991) resume em 4 estágios a degradação inicial em rolamentos, com:

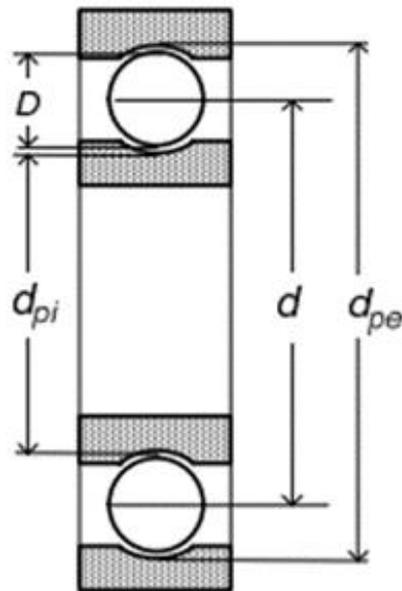
- 1º estágio: Defeitos subsuperficiais com ruído e temperatura inalterados e sem componentes de defeitos nos espectros de frequência.
- 2º estágio: Primeiros bites com sinais dos defeitos, imperceptíveis a olho nu com sensível aumento de ruído e temperatura inalterada. Frequências de defeitos perceptíveis em escala logarítmica.
- 3º estágio: Defeitos localizados e visíveis com ruídos audíveis e leve aumento de temperatura. Frequências de defeitos perceptíveis em escala linear.
- 4º estágio: Propagação do defeito por toda superfície do elemento, elevado ruído e temperatura. Múltiplas frequências da rotação do eixo se tornam evidentes.

2.2.1 FREQUÊNCIAS CARACTERÍSTICAS DE FALHA DE ROLAMENTOS

Mcfadden (1984) indica que o defeito presente em um elemento do rolamento quando entra em contato com outra superfície gera um impulso por meio do choque, excitando as ressonâncias do rolamento e equipamento. A ocorrência desses impulsos apresenta uma frequência determinada, unicamente pela localização do defeito que pode ocorrer na pista interna, pista externa, elementos rolantes ou gaiola.

O cálculo de tais frequências necessita de conhecimento breve de características geométricas e construtivas do rolamento, além de sua velocidade angular. São ilustradas na Figura 2 as características geométricas necessárias ao cálculo das frequências características de falha de rolamentos.

Figura 2 - Características geométricas de um rolamento de esferas



Fonte: BEZERRA, 2004

Sendo:

D = diâmetro das esferas;

d = diâmetro primitivo;

d_{pi} = diâmetro da pista interna;

d_{pe} = diâmetro da pista externa;

β = ângulo de contato;

N_e = número de esferas.

Tomando-se:

- f_{dpe} : Frequência de Falha da Pista Externa;
- f_{dpi} : Frequência de Falha da Pista Interna;
- f_{de} : Frequência do Rolamento;
- f_g : Frequência de Falha da Gaiola.

Obtém-se, na Tabela 1, as frequências características de falhas (BEZERRA,2004).

Tabela 1 - Equações das frequências características de falhas

FREQUÊNCIAS	EQUAÇÕES
Frequência de Falha da Gaiola	$f_g = \frac{f_{pe}}{2} \left(1 + \frac{D \cos \beta}{d} \right)$
Frequência de Falha da Pista Interna	$f_{dpi} = \frac{f_{pe} N_e}{2} \left(1 + \frac{D \cos \beta}{d} \right)$
Frequência de Falha da Pista Externa	$f_{dpe} = \frac{f_{pe} N_e}{2} \left(1 - \frac{D \cos \beta}{d} \right)$
Frequência de falha na esfera	$f_{de} = \frac{f_{pe} d}{2D} \left(1 + \frac{D^2 \cos^2 \beta}{d^2} \right)$

Fonte: (BEZERRA, 2004)

Bezerra (2004) aponta que nas formulações apresentadas na Figura 3 não se considera o escorregamento entre os elementos, portanto, a frequência calculada pode possuir uma alteração em relação a frequência real da falha, que constatou-se possuir uma diferença de 1 a 2%.

2.3 ANÁLISE DE SINAL DE VIBRAÇÃO

A análise de sinais de vibração de rolamentos é uma área importante da manutenção preventiva que visa detectar precocemente possíveis falhas em rolamentos, antes que causem danos maiores ao equipamento. Essa análise é feita através da coleta e avaliação de sinais de vibração gerados pelo equipamento em operação (SANTOS, 2017).

Existem dois domínios principais em que os sinais de vibração podem ser analisados: o domínio tempo e o domínio da frequência. No domínio tempo, a análise se concentra na visualização e avaliação da forma e comportamento do sinal ao longo do tempo. Já no domínio da frequência, a análise se concentra na identificação das frequências presentes no sinal e na compreensão de como elas afetam o seu comportamento (AHERWAR; KHALID, 2012).

A análise tempo-frequência é uma abordagem mais avançada que combina as informações obtidas tanto no domínio tempo quanto no domínio da frequência. Isso permite uma compreensão mais completa do sinal, incluindo informações sobre a evolução das frequências ao longo do tempo. Essa abordagem é muito útil para a detecção de falhas em rolamentos, pois permite identificar mudanças súbitas e

significativas no sinal de vibração que podem indicar problemas com os rolamentos (PRUDHOM et al., 2017).

2.3.1 ANÁLISE DE SINAIS DE VIBRAÇÃO NO DOMÍNIO TEMPO

A análise de sinais de vibração em rolamentos no domínio tempo é uma área de grande importância na manutenção industrial. O objetivo principal é detectar falhas precoces em rolamentos para evitar danos graves aos equipamentos. Para isso, são utilizadas técnicas avançadas de processamento de sinais, e a forma mais comum de análise é através de descritores estatísticos. Esta abordagem permite que as características do sinal sejam quantificadas e comparadas com padrões para a detecção de anormalidades e indicação de falhas.

Os descritores estatísticos são uma forma de representar características do sinal de vibração dos rolamentos, e cada um deles fornece informações diferentes sobre o comportamento do sinal (ALFREDSON; MATHEW, 1985; BEZERRA, 2004; SANTOS, 2017; MA et al, 2018).

1. Valor da média do sinal (μ) - O valor da média do sinal é a média aritmética dos valores do sinal ao longo do tempo. Ele representa o valor médio do sinal e pode ser usado para detectar mudanças na amplitude do sinal.

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i \quad (1)$$

Em que μ é o valor da média, N é o número de amostras do sinal x , e x_i é o valor da i – ésima amostra.

2. Valor do desvio padrão do sinal (σ) - O desvio padrão mede a variação dos valores do sinal em relação à sua média. Ele indica o quanto o sinal varia ao longo do tempo.

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (2)$$

Em que σ é o valor do desvio padrão, N é o número de amostras do sinal x , μ é o valor da média do sinal x_i é o valor da i – ésima amostra.

3. O Valor RMS do sinal (*rms*) - Medida da intensidade do sinal. Ele é definido como a raiz quadrada da média dos quadrados dos valores do sinal ao longo do tempo.

$$rms = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (3)$$

Em que N é o número de amostras do sinal x e x_i é o valor da i – ésima amostra.

4. Valor de Pico (peak-value) (*pv*) - Valor máximo do sinal ao longo do tempo. Ele indica a amplitude máxima do sinal.

$$pv = \max_{i=1}^N x_i \quad (4)$$

Em que N é o número de amostras do sinal x e x_i é o valor da i – ésima amostra.

5. Fator de Crista (crest-factor) (*cf*) - Razão entre o valor de pico e o valor RMS do sinal. Ele indica a amplitude relativa do sinal em relação à sua intensidade.

$$cf = \frac{pv}{rms} \quad (5)$$

Em que pv é o valor de pico do sinal e rms é o valor RMS do sinal.

6. Fator de Impulso (impulse-Factor) (*if*) - Razão entre o valor de pico e a média do sinal. Ele indica a amplitude relativa do sinal em relação à sua média.

$$if = \frac{pv}{\mu} \quad (6)$$

Em que if é o fator de impulso, pv é o valor de pico do sinal e μ é o valor da média do sinal.

7. Curtose do Sinal (k) - A curtose mede a concentração dos valores do sinal em relação à sua média. Ela indica se o sinal tem uma distribuição mais achatada ou mais pontiaguda do que uma distribuição normal.

$$k = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^4}{\left(\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2\right)^2} \quad (7)$$

Em que N é o número de amostras do sinal x , μ é o valor da média do sinal e x_i é o valor da i – ésima amostra.

8. Fator de assimetria (Skewness-Factor) (sf) - O fator de assimetria mede a simetria do sinal em relação à sua média. Ele indica se o sinal tem uma distribuição mais inclinada para a esquerda ou para a direita.

$$sf = \frac{\sum_{i=1}^n (x_i - \mu)^3}{n\sigma^3} \quad (8)$$

Em que x_i são as amostras do sinal, μ é a média e σ é o desvio padrão.

9. Fator de forma (Shape-Factor) (sf) - O fator de forma é a razão entre o valor RMS do sinal e a média do sinal. Ele indica a forma geral do sinal e pode ser usado para detectar mudanças na forma do sinal.

$$sf = \frac{pv}{rms} \quad (9)$$

2.3.2 ANÁLISE DE SINAIS DE VIBRAÇÃO NO DOMÍNIO DA FREQUÊNCIA

A análise no domínio da frequência é uma técnica utilizada para avaliar sinais elétricos e mecânicos. Ela consiste em transformar o sinal do domínio tempo para o domínio da frequência, permitindo uma análise mais eficiente e detalhada. A análise no domínio da frequência tem aplicações em diversos setores, incluindo manutenção

industrial, controle de processos, sistemas de segurança, entre outros.

A Transformada Rápida de Fourier (FFT, sigla do inglês, *Fast Fourier Transform*) é um poderoso algoritmo utilizado para calcular a Transformada Discreta de Fourier (DFT, sigla do inglês, *Discrete Fourier Transform*). A DFT decompõe uma série de dados discretos em componentes de frequências distintas, tornando-a uma ferramenta fundamental em diversos setores. A utilidade das Transformadas Discretas de Fourier é inegável, pois permite a revelação da periodicidade dos dados de entrada e das forças relativas dos componentes periódicos (ZHOU et al., 2015). Além da transformada de Fourier, a análise no domínio da frequência também inclui técnicas como a densidade espectral de potência que é calculada a partir de autocorrelação e correlação cruzada.

A principal vantagem da análise no domínio da frequência em relação a análise no domínio tempo é que ela fornece informações sobre a distribuição de energia do sinal em diferentes frequências. Isso torna mais fácil detectar componentes específicos do sinal que possam ser associados a falhas ou problemas em equipamentos. Além disso, a análise no domínio da frequência também permite identificar relações entre diferentes componentes de frequências, o que é útil para a solução de problemas (GUPTA;PRADHAN, 2017).

No entanto, a análise no domínio da frequência também tem algumas desvantagens. Por exemplo, ela pode ser mais complexa do que a análise no domínio tempo, especialmente quando se trata de sinais não-periódicos. Além disso, a análise no domínio da frequência pode sofrer de perda de informação, especialmente se a amostragem do sinal não for adequada.

2.3.3 ANÁLISE DE SINAL DE VIBRAÇÃO NO DOMÍNIO TEMPO-FREQUÊNCIA

A análise de vibração no domínio tempo-frequência é uma técnica crucial para avaliar sinais de vibração de rolamentos, pois permite a identificação precisa de mudanças nos sinais que podem indicar problemas com os rolamentos. Duas das transformadas mais comuns utilizadas na análise tempo-frequência são a Transformada *Wavelet* e a *Short-Time Fourier Transform* (STFT).

A Transformada *Wavelet* é uma técnica poderosa que utiliza *wavelets*, funções matemáticas especiais, para decompor o sinal em componentes de diferentes frequências e durações. Isso permite uma análise detalhada do sinal, incluindo

informações sobre como diferentes frequências evoluem ao longo do tempo. Além disso, a Transformada *Wavelet* é capaz de lidar com sinais não estacionários, o que é fundamental na análise de sinais de vibração de rolamentos, já que esses sinais podem mudar ao longo do tempo (ATTO; BERTHOUMIEU; BOLON, 2012).

Já a STFT divide o sinal em segmentos curtos e aplica a Transformada de Fourier a cada segmento, permitindo a visualização da evolução das frequências ao longo do tempo. Esta técnica é especialmente útil na análise de sinais com mudanças repentinas, como as que ocorrem em falhas de rolamentos, pois pode identificar rapidamente mudanças significativas nas frequências do sinal (VORA; GAIKWAD; KULKARNI, 2015).

Ambas as transformadas são amplamente utilizadas na análise de sinais de vibração de rolamentos, devido à sua capacidade de fornecer informações detalhadas sobre o comportamento do sinal ao longo do tempo. No entanto, cada uma tem suas próprias vantagens e desvantagens e a escolha da melhor técnica depende do tipo de sinal a ser analisado e da informação desejada.

Por exemplo, a Transformada *Wavelet* é mais adequada para a análise de sinais com componentes de frequências e durações variadas, enquanto a STFT é mais adequada para sinais com mudanças repentinas e rápidas nas frequências. Desta forma, a análise de vibração no domínio tempo-frequência com auxílio da transformada *wavelet* é uma ferramenta valiosa no acompanhamento da evolução de falhas em rolamentos (LI; WANG, 2000).

2.3.3.1 TRANSFORMADA WAVELET

Wavelets são funções matemáticas de curta duração que têm sido amplamente utilizadas na análise de sinais e imagens. Elas foram introduzidas pela primeira vez por Alain N. Y. Haar na década de 1910 e foram desenvolvidas com mais intensidade na década de 1980 por Jean Morlet, Gerard Battle e Pierre-Auguste Chavelet (MALLAT, 1999).

Wavelets são diferentes de outros tipos de transformadas, como a Transformada de Fourier, pois eles possuem uma escala e um deslocamento variáveis, o que as permite se adaptar a diferentes tipos de sinais e acompanhar as mudanças em diferentes escalas de tempo. Além disso, eles também são localmente ortogonais, o que significa que cada *wavelet* pode ser usada para analisar uma parte

específica do sinal sem afetar as outras partes (STOLLNITZ; DEROSE; SALESIN, 1995).

Na Equação 10 é ilustrada, de forma geral, uma função *wavelet*:

$$\Psi_{(a,b)}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (10)$$

Em que $\psi(t)$ é a função *wavelet*, a é a escala e b é o deslocamento. A escala é usada para controlar o comprimento da função *wavelet*, enquanto o deslocamento é usado para controlar sua posição no tempo.

Segundo Mallat (1999), a Transformada *Wavelet* é uma técnica de análise de sinais no domínio tempo-frequência que decompõe o sinal em componentes baseados em famílias de wavelets. Esta técnica permite uma localização precisa das informações no domínio tempo-frequência, tornando-a uma excelente alternativa para a análise de sinais que não são estacionários. Existem três tipos principais de Transformadas Wavelet: Contínua (CWT, sigla em inglês, *Continuous Wavelet Transform*), Discreta (DWT, sigla em inglês, *Discrete Wavelet Transform*) e *Wavelet packet transform* (WPT).

A CWT é calculada usando uma wavelet-mãe escolhida a partir da família de wavelets contínuas e é realizada por meio de uma integral de convolução do sinal com a wavelet-mãe escalada e deslocada no tempo. O resultado da transformada é uma série de coeficientes que representam a contribuição da wavelet-mãe em diferentes frequências e momentos do tempo (MALLAT, 1999).

A Transformada *Wavelet* Contínua utiliza funções matemáticas chamadas wavelets mãe para decompor o sinal. Uma wavelet-mãe é uma função que é zero fora de um determinado intervalo e possui características definidas de frequência e duração. A wavelet-mãe é utilizada para criar wavelets filhas através da escala e translação (MALLAT, 1999).

A Transformada *Wavelet* Contínua pode ser representada matematicamente como:

$$W_c(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} f(t) \psi\left(\frac{t-b}{a}\right) dt \quad (11)$$

em que $f(t)$ é o sinal a ser analisado, a é a escala, b é a translação e $\psi(t)$ é a wavelet-mãe.

A Transformada *Wavelet* Discreta (DWT) é uma técnica matemática utilizada para análise de sinais em domínios de tempo e frequência que apresenta eficiência computacional em relação à Transformada *Wavelet* Contínua (CWT). A DWT permite a decomposição do sinal em uma série de coeficientes que representam diferentes escalas e localizações no domínio do tempo, o que permite uma análise detalhada do sinal. A DWT é baseada na convolução do sinal com a *wavelet*.

A DWT é amplamente utilizada em aplicações de processamento de sinal, incluindo análise de áudio, imagens, sinais de vibração, entre outras. Uma das principais vantagens da DWT é a sua capacidade de manter informações tanto na escala quanto na localização, o que é importante em aplicações em que as características do sinal precisam ser preservadas. Além disso, a DWT é computacionalmente eficiente e pode ser implementada rapidamente em hardware ou *software*.

No entanto, é importante destacar que a DWT tem algumas limitações, incluindo a perda de informações na reconstrução do sinal e a dependência da escolha da wavelet. Para minimizar essas limitações, é necessário escolher cuidadosamente a *wavelet* apropriada e utilizar técnicas de reconstrução de sinal adequadas. A Transformada *Wavelet* Discreta pode ser representada como (SKODRAS, 2015):

$$W_d[n] = \sum_{k=-\infty}^{\infty} f[k]\psi[n-k] \quad (12)$$

Em que $W_d[n]$ é a transformada *wavelet* discreta do sinal $f[k]$. $\psi[n-k]$ é a função *wavelet* associada ao sinal $f[k]$, a soma é feita sobre todas as amostras k do sinal $f[k]$.

A Transformada *Wavelet Packet* é uma extensão da Transformada *Wavelet* Discreta (DWT) que permite uma decomposição mais detalhada de um sinal em termos de sua componente wavelet. Em vez de apenas decompor o sinal em diferentes escalas de tempo, a Transformada *Wavelet packet* permite decompor o sinal em diferentes frequências também (WICKERHAUSER, 1991).

A *Wavelet Packet Transform* é uma extensão da Transformada *Wavelet* Discreta que permite uma decomposição mais precisa do sinal em sub-bandas mais finas. A WPT divide recursivamente cada sub-banda em duas novas sub-bandas, uma de alta frequência e outra de baixa frequência, permitindo uma análise mais refinada do sinal.

A WPT permite a decomposição de um sinal em uma combinação de wavelets discretas com diferentes escalas e frequências. Isso torna possível uma análise mais detalhada e precisa dos sinais, o que é particularmente útil na detecção de sinais fracos e que se alteram de forma abrupta (WICKERHAUSER, 1991).

A aplicação da Transformada *Wavelet Packet* na análise de sinais é ampla e variada. Ele é amplamente utilizado na análise de vibrações, por exemplo, para identificar problemas como falhas mecânicas, desgaste e vibrações anormais. Também é comumente utilizado na análise de sinais de áudio e imagem, em que permite uma representação mais detalhada dos sinais em termos de sua componente wavelet.

Existem várias wavelets mãe diferentes que podem ser utilizadas na Transformada *Wavelet*, incluindo a Morlet, Daubechies, entre outras. A escolha da wavelet-mãe depende do tipo de sinal a ser analisado e da informação desejada.

Vujovi (2015) indica que para decomposição de sinais de vibração em rolamentos os melhores parâmetros a serem adotados, são: wavelets mãe Daubechies 8 e o melhor nível de decomposição é o nível 5.

Os níveis em uma Transformada *Wavelet* se referem ao número de vezes que o sinal é subdividido e decomposto em suas componentes wavelet. A decomposição é realizada recursivamente, em que cada nível é obtido a partir do nível anterior através da aplicação da transformada wavelet.

A utilização de atributos é uma técnica fundamental no processamento de sinais, pois permite representar os dados de forma mais simplificada e informativa. A extração desses atributos é uma etapa crítica na análise de sinais, pois envolve a identificação dos atributos mais importantes para a classificação.

Na classificação de falhas em rolamentos, dois *atributos* são frequentemente utilizados: a Entropia de Shannon e a Energia.

Segundo Liu et al. (2014), a Entropia de Shannon é uma medida da incerteza ou complexidade de um sinal. Na análise de sinais de vibração de rolamentos, a Entropia de Shannon pode ser usada para detectar falhas no rolamento, pois é

comum que a Entropia mude com a ocorrência de uma falha.

A teoria da Entropia de Shannon pode ser formulada da seguinte forma: Dado um sinal discreto X com N amostras, a Entropia de Shannon pode ser definida, segundo Zhao, Wang e Yan (2015), como:

$$H(X) = - \sum_{i=1}^N p_i \log_2 p_i \quad (13)$$

Em que p_i é a probabilidade de ocorrência da i -ésima amostra do sinal.

Ao aplicar a Transformada *Wavelet packet* (WPT) ao sinal de vibração, é possível calcular a Entropia de Shannon para cada sub-faixa gerada pela WPT. Em seguida, é possível comparar a Entropia de Shannon de cada sub-faixa com valores esperados para identificar a ocorrência de uma falha no rolamento.

A Energia é outro *atributo* que pode ser extraído da Transformada *Wavelet packet* (WPT). Ele é calculado como a soma dos quadrados das amplitudes dos coeficientes da WPT. A equação matemática para o cálculo da Energia é dada por (WANG et al., 2022):

$$E = \sum_{i=1}^N |d[i]|^2 \quad (14)$$

Em que N é o número de coeficientes da WPT e $d[i]$ é o valor dos coeficientes da WPT na posição i .

A Energia é amplamente utilizada como um atributo na análise de sinais devido à sua robustez e insensibilidade à escala. Esta característica a torna uma escolha popular para aplicações de detecção de falhas em rolamentos, pois permite a identificação de padrões presentes no sinal mesmo com variações na amplitude ou escala (WESCOAT, 2020). Além disso, a Energia é fácil de ser calculada e interpretada, o que a torna uma medida útil na avaliação da qualidade do sinal de vibração em rolamentos.

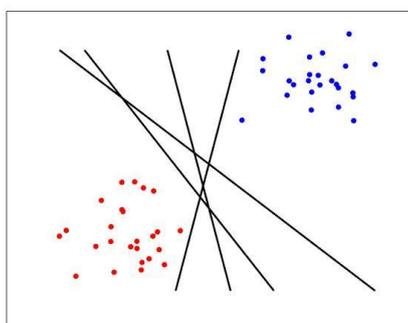
2.4 SVM

Support Vector Machine (SVM) é um algoritmo de aprendizado de máquina amplamente utilizado para resolução de problemas de classificação e regressão. Foi originalmente desenvolvido por Vladimir Vapnik e seus colaboradores nos anos 90 (CORTES; VAPNIK,1995).

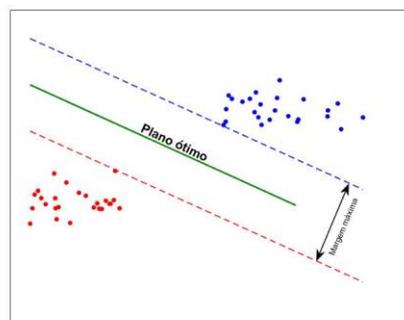
O funcionamento da SVM baseia-se na busca pela melhor separação linear dos dados em duas classes, onde a linha que melhor separa as classes é conhecida como hiperplano de separação. Além disso, a SVM procura encontrar o hiperplano que maximiza a margem, ou seja, a distância mínima entre os pontos mais próximos das classes diferentes, conhecidos como vetores de suporte (CORTES; VAPNIK,1995).

O hiperplano é uma reta ou superfície que divide o espaço de características multidimensionais em duas regiões. Em outras palavras, o hiperplano é a fronteira de decisão que separa as diferentes classes de dados de treinamento, como pode ser observado nas Figuras 3 e 4, existem diversas configurações possíveis, contudo, busca-se maximizar a margem.

Figura 3 - Possíveis planos de separação para duas classes



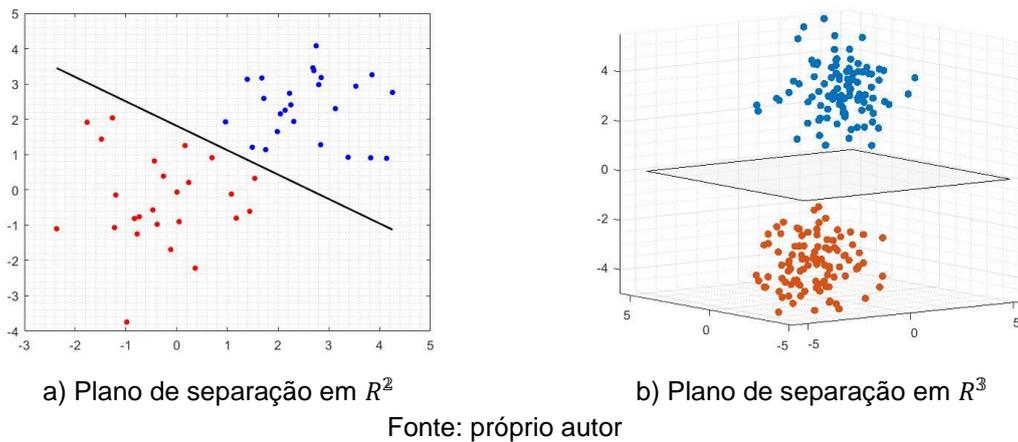
a) Possíveis planos de separação



b) Maximização da margem

Fonte: próprio autor

Figura 4 - Hiperplano em diferentes domínios



A teoria por trás do SVM é baseada no princípio de maximização da margem entre as classes. A margem é a distância máxima entre o hiperplano e as instâncias mais próximas de cada classe, conhecidas como pontos de suporte. Quanto maior a margem, melhor a separação entre as classes, o que significa uma classificação mais precisa dos dados. A equação do hiperplano pode ser representada matematicamente por (KECMAN, 2005):

$$w^T x + b = 0 \quad (15)$$

Em que w é o vetor de pesos, x é o vetor de características de entrada e b é o termo de interceptação. O objetivo do SVM é encontrar o vetor de pesos w e o termo de interceptação b que maximizem a margem entre as classes.

A solução do SVM é encontrada por meio de uma programação quadrática, que busca encontrar a combinação ótima de pesos e interceptação que maximizem a margem. O resultado final é o hiperplano que separa as classes de maneira mais precisa, levando em consideração a margem máxima.

A margem em SVM é a distância mínima entre a fronteira de decisão e os pontos de treinamento. Ela é uma medida da separabilidade dos dados e, quanto maior a margem, mais fácil é separar os dados. Além disso, a margem também ajuda a prevenir o *Overfitting*, pois impede que o modelo se ajuste demais aos dados de treinamento (KECMAN, 2005).

Existem dois tipos de margem em SVM: margem dura (*hard margin*) e margem suave (*soft margin*), representadas respectivamente nas Figuras 5 e 6.

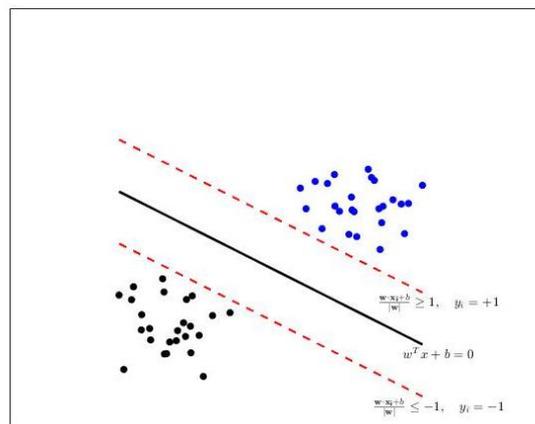
A margem dura é definida como a distância mínima entre a fronteira de decisão e os pontos de treinamento, com a exigência de que todos os pontos de treinamento sejam classificados corretamente e estejam fora da fronteira de decisão (JAKKULA, 2006). Matematicamente, isso pode ser representado como:

$$\frac{w \cdot x_i + b}{\|w\|} \geq 1, y_i = +1 \quad (16)$$

$$\frac{w \cdot x_i + b}{\|w\|} \leq -1, y_i = -1 \quad (17)$$

Em que y_i é a classe alvo do ponto de treinamento i , w é o vetor de peso, x_i é o vetor de características do ponto de treinamento i , b é o viés e $\|w\|$ é a norma de w .

Figura 5 - Separação de duas classes com margem dura



Fonte: próprio autor

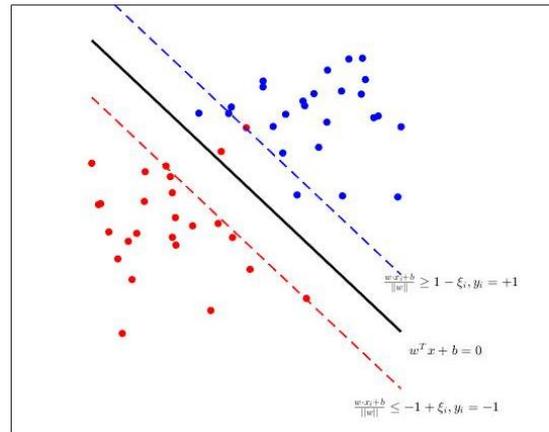
A margem suave é uma abordagem mais flexível que permite que alguns pontos de treinamento caiam dentro da fronteira de decisão. Isso é útil quando o conjunto de dados tem muitos ruídos ou outliers. Na margem suave, os pontos dentro da fronteira são penalizados, mas ainda são considerados para a construção da fronteira (JAKKULA, 2006). Matematicamente, isso pode ser representado como:

$$\frac{w \cdot x_i + b}{\|w\|} \geq 1 - \xi_i, y_i = +1 \quad (18)$$

$$\frac{w \cdot x_i + b}{\|w\|} \leq -1 + \xi_i, y_i = -1 \quad (19)$$

Em que $\xi_i \geq 0$ é a penalização para o ponto de treinamento i que cai dentro da fronteira. O objetivo é encontrar o valor ótimo de w e b que maximiza a margem suave enquanto penaliza adequadamente os pontos que caem dentro da fronteira.

Figura 6 - Separação de duas classes com margem suave

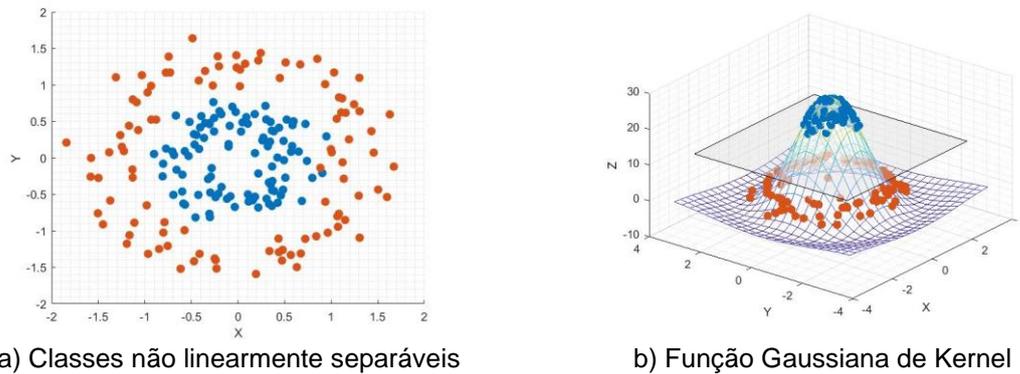


Fonte: próprio autor

A SVM é amplamente utilizada em uma ampla variedade de aplicações, incluindo reconhecimento de padrões, processamento de linguagem natural, mineração de dados e análise de imagens. Uma de suas principais vantagens é a sua capacidade de lidar com problemas que possuem muitas características, como é o caso da análise de imagens, já que a SVM pode selecionar as características mais relevantes para a classificação (CHANG, 2011).

A SVM também oferece a possibilidade de utilizar diferentes tipos de funções kernel, que são responsáveis por transformar os dados de entrada em uma representação de alta dimensionalidade, possibilitando a separação das classes, como verificado na Figura 7. Isso significa que a SVM pode lidar com problemas de classificação não linear ao transformar os dados para uma representação de alta dimensionalidade.

Figura 7 - Separação de duas classes não linearmente separáveis adotando uma função de Kernel



Fonte: próprio autor

O uso de kernels é uma técnica fundamental na construção da fronteira de decisão no SVM, pois permite transformar os dados de entrada em um espaço de características mais adequado para a classificação. Além disso, o uso de kernels também permite que o algoritmo SVM seja aplicado a dados que não são linearmente separáveis, o que é uma grande vantagem em comparação com outros algoritmos de classificação (BURGES, 1998).

Existem diferentes tipos de kernel, cada um com suas próprias características e aplicações específicas. Alguns dos mais comuns incluem:

Kernel linear (PATLE; CHOUHAN, 2013): é o kernel mais simples e é usado quando os dados são linearmente separáveis. O kernel linear é dado por:

$$k(x_i, x_j) = x_i^T x_j \quad (20)$$

Kernel polinomial (BURGES, 1998; PATLE; CHOUHAN, 2013): é usado quando os dados são parcialmente linearmente separáveis. O kernel polinomial é dado por:

$$k(x_i, x_j) = (x_i^T x_j + c)^d \quad (21)$$

Em que c é uma constante e d é o grau do polinômio.

Kernel Gaussiano (BURGES, 1998; PATLE; CHOUHAN, 2013): é também conhecido como kernel radial e é usado para lidar com dados que são completamente

não-linearmente separáveis. O kernel Gaussiano é dado por:

$$k(x_i, x_j) = \exp\left(-\gamma \|x_i - x_j\|^2\right) \quad (22)$$

Em que γ é uma constante.

A escolha do kernel a ser usado depende da natureza dos dados de entrada e da tarefa de classificação. Em geral, o kernel radial (ou gaussiano) é o mais utilizado, pois é capaz de lidar com uma ampla variedade de dados não-lineares.

A forma de treinamento para o algoritmo de *Support Vector Machines* (SVM) pode ser subdividida em treinamento supervisionado e treinamento não-supervisionado, onde:

- Treinamento supervisionado: esse tipo de treinamento é utilizado para resolver problemas de classificação ou regressão, onde o algoritmo aprende a prever a classe ou o valor de uma variável dependente a partir dos dados de treinamento rotulados. O objetivo é encontrar o hiperplano de separação que melhor divide as amostras de treinamento em suas respectivas classes.
- Treinamento não-supervisionado: esse tipo de treinamento é utilizado para resolver problemas de clusterização, onde o algoritmo aprende a identificar grupos ou cluster nas amostras de treinamento sem a necessidade de rótulos prévios. O objetivo é encontrar um hiperplano que maximize a separação entre os grupos, minimizando a variação intra-grupo e maximizando a variação inter-grupo (CHEN; DINO; AKRAM, 2020).

Em ambos os tipos de treinamento, o algoritmo SVM utiliza a função de perda (também conhecida como função de custo) para medir o quão bem o hiperplano de separação se ajusta aos dados de treinamento. A função de perda é otimizada durante o treinamento para encontrar o hiperplano ótimo de separação.

A função de perda (ou custo) na SVM é usada para medir o desempenho do modelo e para ajustar seus parâmetros. A função de perda mais comumente usada na SVM em problemas com múltiplas classes é a função hinge loss (GU, 2018), que é dada por:

$$\mathcal{L}_i(y_i, f(x_i)) = \max(0, 1 - y_i \cdot f(x_i)) \quad (23)$$

em que y_i é a classe real do exemplo x_i e $f(x_i)$ é a previsão do modelo para a classe de x_i .

A função hinge loss mede a quantidade de erro do modelo. Quando a previsão $f(x_i)$ é correta ($y_i \cdot f(x_i) > 0$), a função de perda é zero. Quando a previsão é incorreta ($y_i \cdot f(x_i) \leq 0$), a função de perda é positiva e mede a magnitude do erro (GU, 2018).

A função de perda hinge loss é comumente usada em conjunto com a regularização para evitar o *Overfitting* do modelo. A função total de custo é dada por:

$$\mathcal{J} = \frac{1}{N} \sum_{i=1}^N \mathcal{L}_i(y_i, f(x_i)) + \lambda \|w\|^2 \quad (24)$$

Em que N é o número de exemplos de treinamento, w é o vetor de pesos do modelo e λ é a constante de regularização.

SVM também tem suas limitações. Por exemplo, o tempo de treinamento pode ser longo quando o número de exemplos de treinamento é grande, o que pode ser um problema em aplicações em tempo real. Além disso, a SVM é sensível ao escalonamento dos dados, o que pode afetar sua precisão.

Existem algumas estratégias para realizar classificação multi-classe com o algoritmo de *Support Vector Machines* (SVM). Algumas das principais abordagens são:

- *One-vs-One* (OvO): nesse esquema, é treinado um classificador binário para cada par de classes. Ao final, as previsões são agregadas, geralmente através de votação, para determinar a classe final. Essa estratégia é computacionalmente intensiva, já que é necessário treinar $N(N-1)/2$ classificadores, em que N é o número de classes (FACELI, 2011).
- *One-vs-All* (OvA): nesse esquema, é treinado um classificador binário para cada classe, considerando-a como positiva e as outras como negativas. Ao final, a classe com a maior pontuação é selecionada como a previsão. Esse

esquema é mais eficiente computacionalmente que o OvO, já que é necessário treinar apenas N classificadores (FACELI, 2011).

3 MATERIAIS E MÉTODOS

3.1 FERRAMENTAS UTILIZADAS

A principal ferramenta utilizada neste trabalho foi o *software* MATLAB®, que é um ambiente de computação numérica e programação que permite a análise e visualização de dados, o desenvolvimento de algoritmos, a criação de interfaces gráficas de usuário e a implementação de modelos e sistemas de simulação. Ele possui uma ampla gama de ferramentas e funções para análise numérica, incluindo álgebra linear, análise de dados, otimização, processamento de sinais, processamento de imagens, controle e muito mais.

O MATLAB® é amplamente utilizado em muitas áreas, incluindo ciência, engenharia, finanças, computação, física, química e outras. Ele tem uma sintaxe simples e intuitiva que torna a programação mais fácil para iniciantes e experientes programadores. Além disso, o MATLAB oferece suporte a uma ampla variedade de formatos de arquivo, como CSV, Excel, arquivos de texto, imagens, vídeos e áudio, tornando-o uma escolha popular para análise e visualização de dados em muitas áreas.

3.2 DESCRIÇÃO DA BASE DE DADOS

Inicialmente, acessou-se o site da "*CASE WESTERN RESERVE UNIVERSITY*" para obter os sinais de vibração dos dados de teste de rolamento de esferas, tanto para rolamentos sem defeitos quanto defeituosos. O provedor de dados descreveu o uso de um motor elétrico *Reliance* de 2 HP e a medição da aceleração em pontos próximos e distantes do rolamento do motor. Todas as condições reais de teste do motor e o estado de falha do rolamento foram cuidadosamente documentados para cada experimento realizado.

Os rolamentos do motor foram intencionalmente danificados por meio do processo de usinagem por eletroerosão, com a introdução de falhas de diâmetros que variaram entre 0,007 e 0,040 polegadas, de maneira separada, na pista interna, no elemento rolante e na pista externa. Em seguida, os rolamentos danificados foram reinstalados no motor de teste, e os dados de vibração foram registrados em uma faixa de cargas de motor de 0 a 3 cavalos-vapor, com velocidades de motor variando

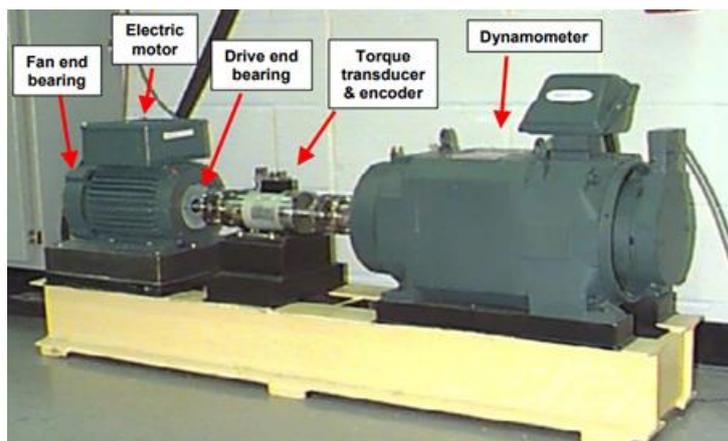
de 1797 a 1720 RPM, cada sinal de vibração foi amostrado a uma frequência de 12 kHz e teve duração de 10 segundos.

A bancada de testes apresentada na Figura 8 é composta por um motor de 2 HP (à esquerda), um transdutor de torque e um encoder (no centro) e um dinamômetro (à direita).

Foram utilizados rolamentos SKF para as falhas com diâmetros de 0,007, 0,014 e 0,021 polegadas, enquanto que os rolamentos equivalentes da NTN foram empregados para as falhas com diâmetros de 0,028" e 0,040".

Os dados de vibração foram coletados usando acelerômetros acoplados por meio de base magnética na posição ortogonal no final do motor e no final da ventoinha do alojamento do motor. Os sinais de vibração foram coletados usando um gravador DAT de 16 canais e foram pós-processados em um ambiente MATLAB®.

Figura 8 - Experimento para aquisição de dados de vibração



Fonte: (CWRU, 2022)

Os dados de vibração foram coletados em 12kHz, e também coletados em 48kHz para rolamentos em quatro condições operacionais distintas do sistema experimental: (1) condição normal; (2) com falha na pista interna; (3) com falha na pista externa; e (4) com falha na esfera.

Neste trabalho adotou-se o modelo de rolamento SKF 6205-2RSL JEM, que consiste em um rolamento rígido de esferas, com rotação de 1797 RPM, carga nula no motor, arquivos com 12.000 amostras por segundo e diâmetros de falha de 0,007" e 0,021". É indicado na Tabela 2 as principais dimensões geométricas do rolamento, enquanto a Tabela 3 ilustra as demais propriedades dos dados utilizados.

Tabela 2 - Dimensões em polegadas do rolamento SKF 6205-2RSL JEM

Diâmetro interno	Diâmetro Externo	Espessura	Diâmetro das Esferas	Diâmetro Primitivo
0,9843	2,0472	0,5906	0,3126	1,537

Fonte: CWRU, 2022

Tabela 3 - Características dos dados disponibilizados

Diâmetro da falha (in)	Carga no motor (HP)	Velocidade (RPM)	Pista interna (.MAT)	Esferas (.MAT)	Pista Externa (.MAT)
0,007	0	1797	IR007_0	B007_0	OR007@12_0
0,021	0	1797	IR021_0	B021_0	OR021@12_0

Fonte: CWRU, 2022

3.3 SEGMENTAÇÃO DOS DADOS

A segmentação dos dados é um processo fundamental na análise de sinais de vibração em rolamentos, pois permite a extração de informações relevantes de cada segmento do sinal. Os sinais originais de vibração colhidos no experimento são compostos por muitos pontos. A segmentação consiste em dividir o sinal em segmentos menores, chamados de janelas ou amostras, que são processados individualmente.

A escolha do tamanho da janela é crucial, pois influencia diretamente na qualidade da segmentação. Janelas muito pequenas podem conter informações insuficientes para a detecção de falhas, enquanto janelas muito grandes podem misturar informações de diferentes condições de funcionamento, prejudicando a análise.

Os arquivos referentes aos dados de cada defeito foram carregados no MATLAB® e segmentados em janelas de 2000 amostras, em sintonia ao trabalho de Soares, Pinto e Lobão (2020).

É apresentado na Tabela 4 os dados não segmentados, onde a coluna "ARQUIVO" contém o nome do arquivo baixado, a coluna "DADOS" mostra a coluna dentro do arquivo que contém a variável de vibração do rolamento posicionado no *drive-end* (por exemplo, "X097_DE_time"), enquanto a coluna "DIMENSÃO" indica o número de pontos amostrais adquiridos. Além disso, as colunas "CLASSE" e

"ÍNDICE" identificam a classe adotada para cada estado do sinal do rolamento e seu respectivo índice.

Por outro lado, na Tabela 5 são ilustrados os dados segmentados. Na coluna "NÚMERO DE SEGMENTOS", são exibidos a quantidade de segmentos alojados no sinal. Por exemplo, no caso do rolamento sem defeitos, há 120 segmentos de 2000 pontos amostrais em cada segmento.

Tabela 4 – Informações de dados de vibração não segmentados

ARQUIVO	DADOS	DIMENSÃO (LxC)	CLASSE	ÍNDICE
Normal_0	X097_DE_time	243938x1	SD	1
IR007_0	X105_DE_time	121265x1	PI7	2
B007_0	X118_DE_time	122571x1	ESF7	3
OR007@12_0	X156_DE_time	122281x1	PE7	4
IR021_0	X209_DE_time	122136x1	PI21	5
B021_0	X222_DE_time	121991x1	ESF21	6
OR021@12_0	X258_DE_time	121846x1	PE21	7

Fonte: próprio autor

Tabela 5 – Dados segmentados

CLASSE	ÍNDICE	NÚMERO DE SEGMENTOS
SD	1	120
PI7	2	60
ESF7	3	60
PE7	4	60
PI21	5	60
ESF21	6	60
PE21	7	60

Fonte: próprio autor

As classes SD, PI7, ESF7, PE7, PI21, ESF21 e PE21 foram definidas para representar, respectivamente, a ausência de defeitos e a presença de defeitos em diferentes componentes do rolamento, com diâmetros de falhas de 0,007" e 0,021". Em particular, a classe PI indica um defeito na pista interna, ESF indica um defeito na

esfera e PE indica um defeito na pista externa. Na Tabela 6 é explicitada a relação das classes com os defeitos e seu respectivo índice.

Tabela 6 – Classe adotada para cada defeito

DEFEITO	DIÂMETRO [in]	CLASSE	ÍNDICE
Sem defeito	-	SD	1
Pista interna	0,007	PI7	2
Esfera	0,007	ESF7	3
Pista externa	0,007	PE7	4
Pista interna	0,021	PI21	5
Esfera	0,021	ESF21	6
Pista externa	0,021	PE21	7

Fonte: próprio autor

3.4 EXTRAÇÃO DE DESCRITORES

A extração de descritores é uma etapa importante na aplicação de SVM para classificação. Os descritores são características ou atributos que descrevem os dados de entrada. Este trabalho se utiliza de duas classes de descritores, os obtidos por meio do sinal no domínio tempo e os descritores obtidos por meio do sinal tempo-frequência.

3.4.1 DOMÍNIO TEMPO

Para extrair os descritores no domínio tempo, foram utilizadas as Equações 1 a 9, que permitiram obter nove principais descritores estatísticos para cada janela de dados. Esses descritores incluem a média, desvio padrão, valor RMS, valor de pico, fator de crista, fator de impulso, curtose, fator de assimetria e fator de forma, respectivamente numerados de 1 a 9.

Estes descritores descrevem a forma e distribuição dos dados em cada janela de 2000 amostras e podem fornecer informações valiosas sobre o estado do rolamento. A utilização desses descritores pode reduzir a dimensionalidade dos dados e melhorar a eficiência do processo de classificação por SVM. É apresentado

na Tabela 7 a dimensão resultante das janelas de dados após a extração dos descritores, ou seja, para a classe SD têm-se, para cada uma das 120 janelas, 9 descritores. Considerando-se todas as 7 classes, obtêm-se 480 conjuntos dos 9 descritores.

Tabela 7 - Dimensão dos dados com descritores estatísticos

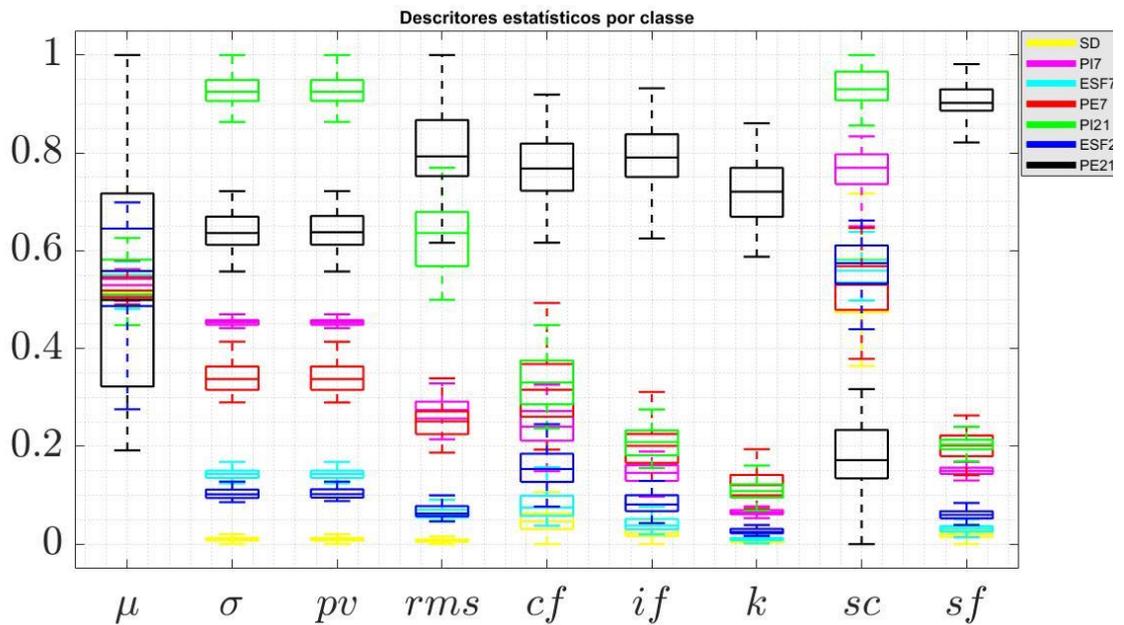
CLASSE	DIMENSÃO
SD	120x9
PI7	60x9
ESF7	60x9
PE7	60x9
PI21	60x9
ESF21	60x9
PE21	60x9

Fonte: próprio autor

3.4.1.1 SELEÇÃO DE DESCRITORES RELEVANTES AO SVM

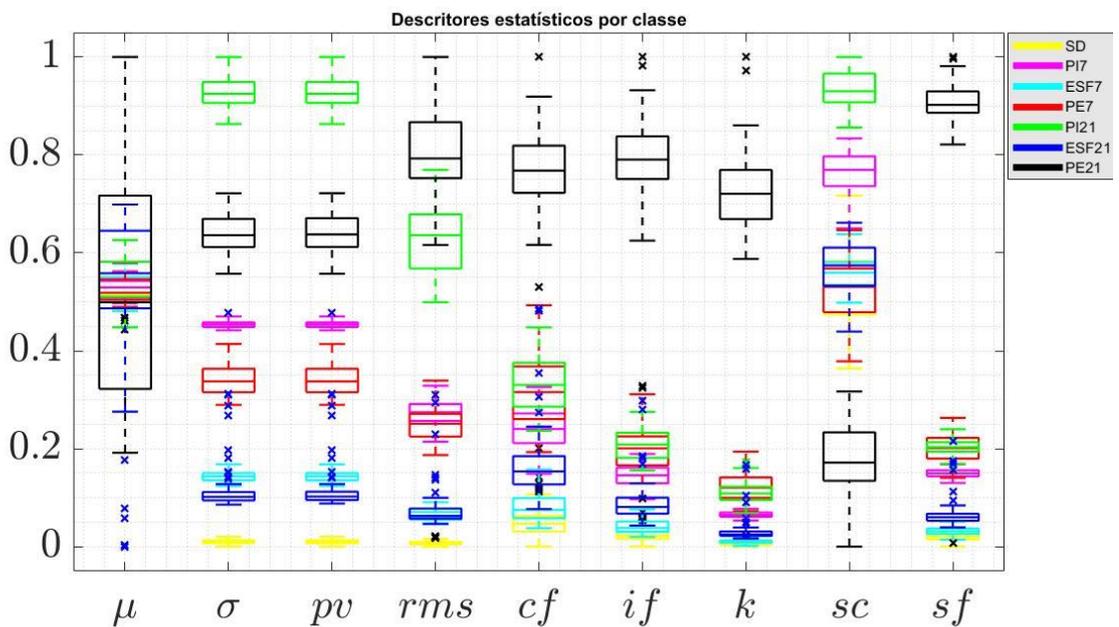
Para realizar uma análise inicial dos dados, foram utilizados gráficos tipo boxplot para entender o comportamento de cada descritor em cada classe por meio de sua distribuição. É ilustrado graficamente na Figura 9 a distribuição dos descritores normalizados, sem a presença de *outliers*. Indicando a possível separação das classes por meio do desvio padrão, contudo, na Figura 10 é apresentado o mesmo gráfico com a presença de *outliers* o que possibilita perceber sua baixa eficiência para a tarefa a seleção dos melhores descritores por um meio visual.

Figura 9 – Boxplot (sem outliers) descritores estatísticos por classe



Fonte: próprio autor

Figura 10 – Boxplot (com outliers) descritores estatísticos por classe



Fonte: próprio autor

Uma vez que a abordagem gráfica não foi suficiente para identificar as melhores combinações de descritores que caracterizassem com precisão cada classe, tornou-se necessária a utilização de técnicas de seleção de atributos. Assim,

para selecionar os descritores mais relevantes para o problema em questão, optou-se pelo método Relief-F.

O método Relief-F (ReF) é uma técnica de seleção de características que avalia a relevância das características com base em uma medida de distância entre exemplos. Kira e Rendell (1992) propuseram este método para selecionar características em tarefas de classificação binária, e posteriormente estendido para problemas de classificação multiclases, onde na Figura 11 é apresentado seu pseudocódigo.

O método Relief-F é um algoritmo de seleção de atributos amplamente utilizado em problemas de classificação, incluindo a aplicação em SVM. O Relief-F começa selecionando aleatoriamente uma instância de treinamento e procura pelos seus k vizinhos mais próximos. Ele usa esses vizinhos para atualizar a pontuação de relevância de cada atributo, aumentando a pontuação se os valores do atributo são diferentes entre a instância de referência e seu vizinho mais próximo da mesma classe, e diminuindo a pontuação se os valores são diferentes entre a instância de referência e seu vizinho mais próximo de classe diferente. Esse processo é repetido para cada instância de treinamento e a pontuação de relevância de cada atributo é calculada como a média das pontuações obtidas para cada instância. (REMESEIRO; BOLON-CANEDO, 2019). Dessa forma, as variáveis menos relevantes são descartadas, reduzindo a dimensionalidade dos dados e, possivelmente, melhorando a acurácia do modelo. O método Relief-F é particularmente útil em problemas de classificação com múltiplas classes e pode ser combinado com diferentes algoritmos de classificação, como SVM, redes neurais, entre outros.

Após a extração dos descritores, o método Relief-F foi aplicado aos dados para selecionar os atributos mais relevantes para a classificação. Neste estudo, foram considerados os 9 descritores estatísticos e a vizinhança de 10 pontos. A Tabela 8 apresenta os índices de relevância e os pesos atribuídos a cada descritor após a aplicação do método Relief-F, indicando a relevância de cada descritor para a classificação dos dados de vibração em rolamentos.

Figura 11 – Pseudocódigo para o método Relief-F

Algorithm Relief

Input: for each training instance a vector of attribute values and the class value

Output: the vector W of estimations of the qualities of attributes

1. *set all weights $W[A] := 0.0$;*
2. **for $i := 1$ to m do begin**
3. *randomly select an instance R_i ;*
4. *find nearest hit H and nearest miss M ;*
5. **for $A := 1$ to a do**
6. $W[A] := W[A] - \text{diff}(A, R_i, H)/m + \text{diff}(A, R_i, M)/m$;
7. **end**

Fonte: (KIRA; RENDELL, 1992)

Tabela 8 - Índices e pesos atribuídos a cada descritor

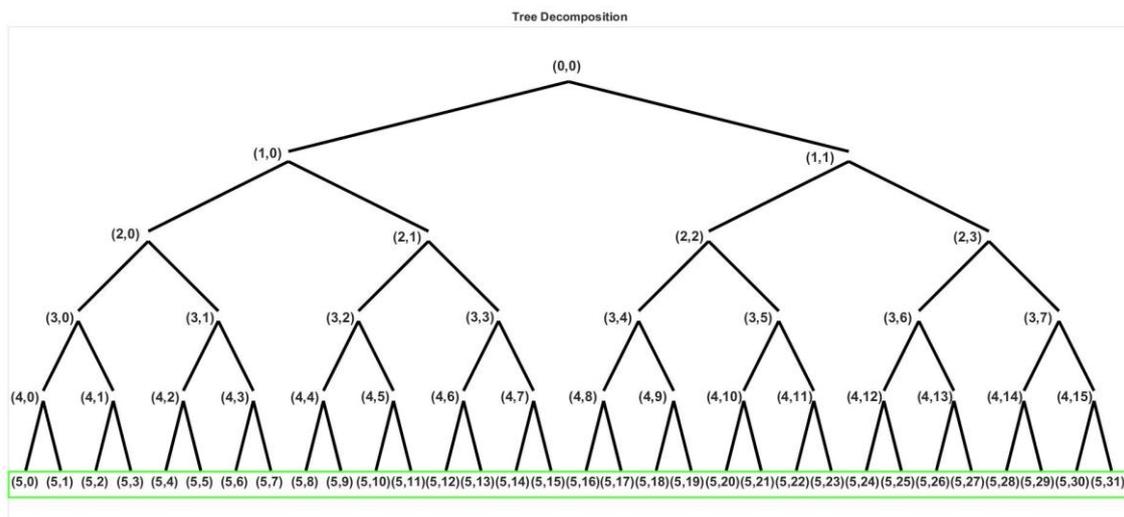
Descr.	σ	rms	sf	sc	pv	k	if	cf	μ
Índice	1º	2º	3º	4º	5º	6º	7º	8º	9º
Peso	0,0192	0,0192	0,0019	0,0181	0,0011	0,0105	0,0251	0,0006	0,0026

Fonte: próprio autor

3.4.2 DOMÍNIO TEMPO-FREQUÊNCIA

Para extrair descritores no domínio tempo-frequência, o sinal de interesse foi dividido em janelas de 2000 amostras e cada janela foi decomposta em 5 níveis utilizando uma wavelet-mãe Daubechies de ordem 8. Na Figura 12 é apresentada a árvore de decomposição do sinal de uma janela, onde cada nó representa um sub-sinal resultante de uma decomposição em um determinado nível.

Figura 12 - Árvore de decomposição do sinal em 5 níveis



Fonte: próprio autor

Após a decomposição *wavelet*, foram extraídos dois atributos do sinal: o valor da entropia de Shannon e a energia do quinto nível, calculados por meio das Equações 13 e 14, respectivamente. Esses descritores são importantes para descrever a distribuição de energia do sinal em diferentes escalas de frequência e, portanto, podem fornecer informações valiosas sobre o estado do sistema analisado. A aplicação desses atributos pode ainda reduzir a dimensionalidade dos dados e melhorar a eficiência do processo de classificação, como pode ser observado na Tabela 9, onde sem o uso dos atributos teríamos para o sinal sem defeito, por exemplo, 120 segmentos com 2000 pontos amostrais, contudo, com a adoção dos atributos, reduziu-se de 2000 para 64 pontos.

Tabela 9 - Dimensão dos dados com descritores - Entropia de Shannon e Energia

CLASSE	DIMENSÃO
SD	120x64
PI7	60x64
ESF7	60x64
PE7	60x64
PI21	60x64
ESF21	60x64
PE21	60x64

Fonte: próprio autor

3.4.2.1 SELEÇÃO DE DESCRITORES RELEVANTES AO SVM

Como no tópico 3.4.1.1, o método Relief-F foi utilizado para elencar a melhor combinação dos descritores. É ilustrado na Tabela 10 a posição e o peso de cada descritor, onde “SE” e “E” representam os valores de entropia de Shannon e energia em cada nó no quinto nível.

Tabela 10 - Índices e pesos atribuídos a cada descritor – Tempo-Frequência

Descr.	E(5,28)	E(5,26)	E(5,20)	E(5,29)	...	SE(5,3)	E(5,0)	SE(5,29)	SE(5,16)
Índice	1º	2º	3º	4º	...	61º	62º	63º	64º
Peso	0,0033	-0,0205	-0,0023	0,0201	...	0,0380	0,0656	0,0049	-0,0074

Fonte: próprio autor

3.4 APLICAÇÃO DO CLASSIFICADOR SVM

No início do experimento, os descritores foram particionados em dois conjuntos randômicos distintos, o conjunto de treinamento e o conjunto de teste, seguindo a estratégia de divisão 80/20, em que 80% dos dados foram alocados ao conjunto de treinamento e 20% dos dados foram designados para o conjunto de teste. Para a alocação dos dados de treinamento, seguiu-se a divisão em porcentagem presente na Tabela 11.

Tabela 11 - Representação das classes nos dados de treinamento

CLASSE	COMPOSIÇÃO [%]
SD	25,00%
PI7	13,28%
ESF7	11,46%
PE7	12,50%
PI21	12,50%
ESF21	13,02%
PE21	12,24%

Fonte: próprio autor

Para a aplicação do classificador SVM para mais de duas classes, foi necessário estabelecer e compreender a importância de alguns parâmetros, tais como o tipo de função de Kernel a ser utilizada e a estratégia de classificação de classes. Neste estudo, adotamos a estratégia de classificação "one-vs-all" (OvA),

amplamente recomendada na literatura para esse tipo de problema.

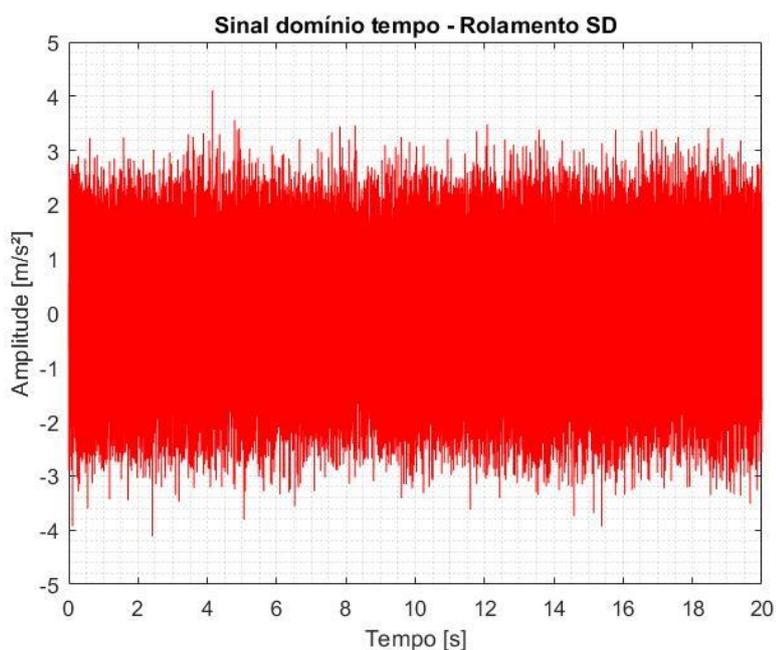
Por fim, a análise da eficiência de ambas as abordagens foi realizada por meio da avaliação da acurácia, permitindo uma avaliação objetiva do desempenho e potencial dos modelos.

4 RESULTADOS

A classificação das falhas nas pistas internas, pista externa e na esfera do rolamento do lado do acionamento (Drive End) foi realizada por meio do algoritmo SVM, utilizando dados disponibilizados pela *Case Western Reserve University* e características extraídas nos domínios do tempo e do tempo-frequência. Para isso, utilizou-se o *software* MATLAB® para realizar a análise dos dados e aplicar o método proposto, a fim de obter uma análise precisa e eficiente das falhas do rolamento.

É apresentado na Figura 13 o sinal não normalizado no domínio tempo para o rolamento sem defeito. O sinal foi obtido com uma rotação de 1.797 rpm, uma frequência de amostragem de 12.000 amostras/segundo e sem carga.

Figura 13 - Sinal no domínio tempo sem defeito



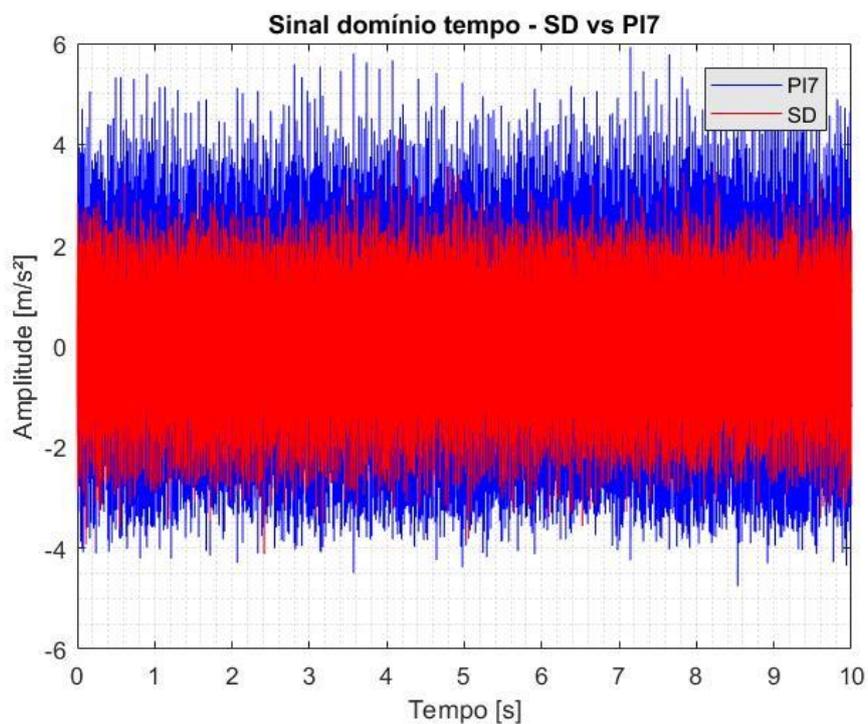
Fonte: próprio autor

O sinal apresenta uma distribuição homogênea com amplitudes reduzidas, o que sugere visualmente a ausência de defeitos. No entanto, é importante ressaltar que a avaliação de sinais de vibração requer uma análise mais aprofundada, pois defeitos podem não ser detectados apenas pela análise visual do sinal no domínio tempo. Por isso, técnicas de processamento de sinal são frequentemente utilizadas para extrair características relevantes e auxiliar na detecção de falhas em rolamentos.

São apresentados nas Figuras 14 a 19 os sinais normalizados por média e

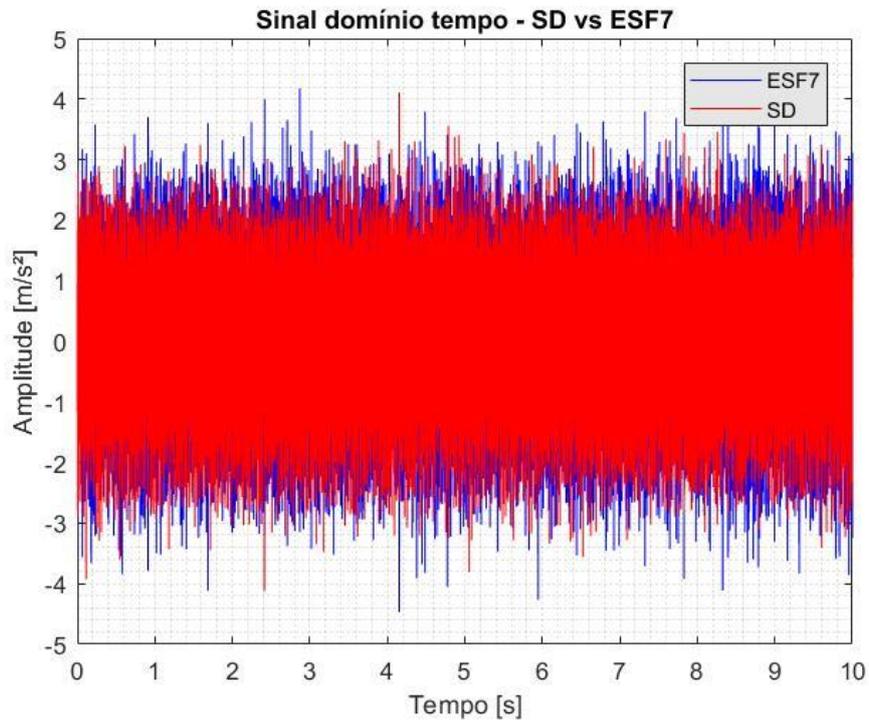
desvio padrão de cada um dos defeitos estudados, em comparação com o sinal sem defeitos, também normalizado. É possível perceber visualmente que há uma distância considerável entre os sinais com defeito e sem defeito, permitindo uma classificação visual simplista quanto à presença de defeito no rolamento, exceto para o sinal do defeito ESF7, que apresenta certa sobreposição com o sinal sem defeitos. Entretanto, essa abordagem pode apresentar grandes limitações para a classificação de cada tipo de defeito.

Figura 14 - Sinal PI7 em comparação ao sinal SD



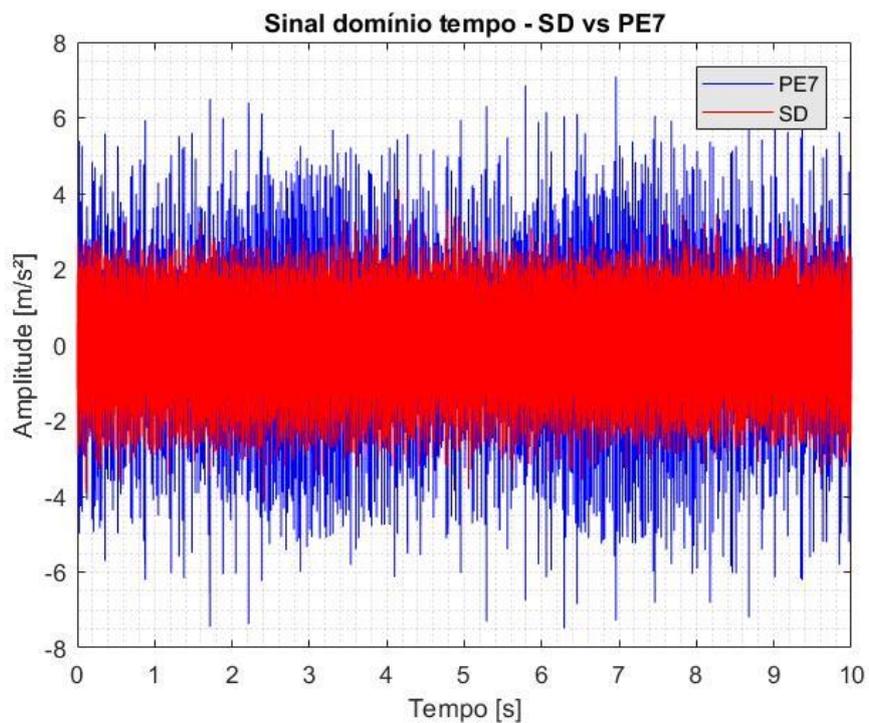
Fonte: próprio autor

Figura 15 - Sinal SD em comparação ao sinal ESF7



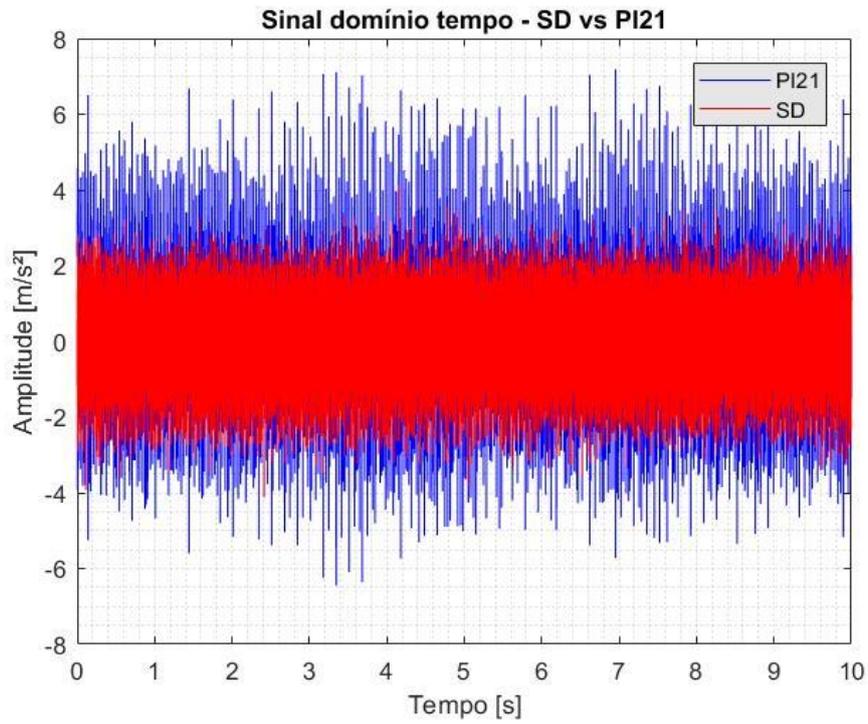
Fonte: próprio autor

Figura 16 - Sinal SD em comparação ao sinal PE7



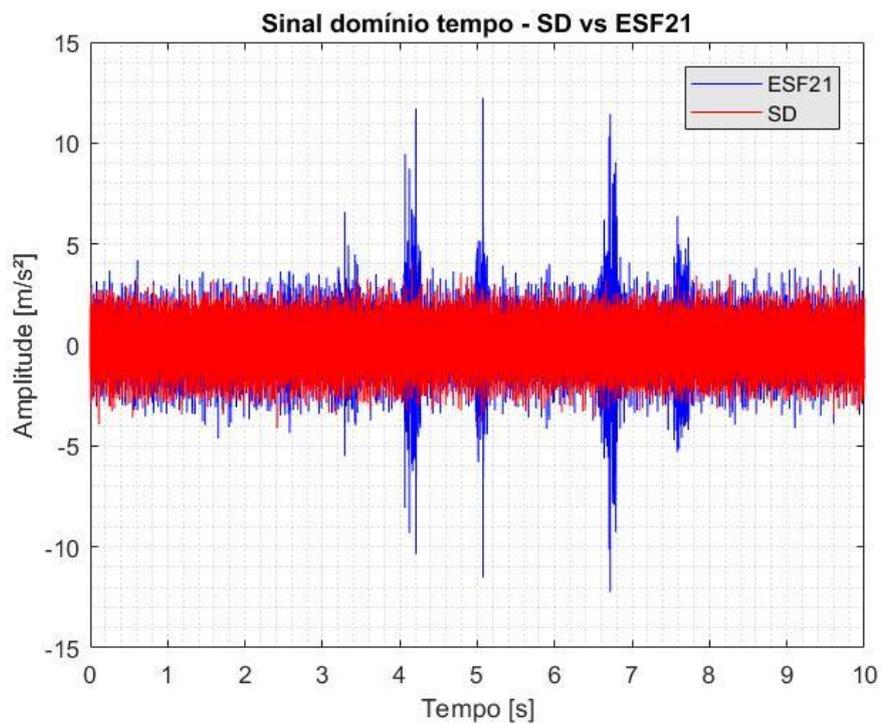
Fonte: próprio autor

Figura 17 - Sinal SD em comparação ao sinal PI21



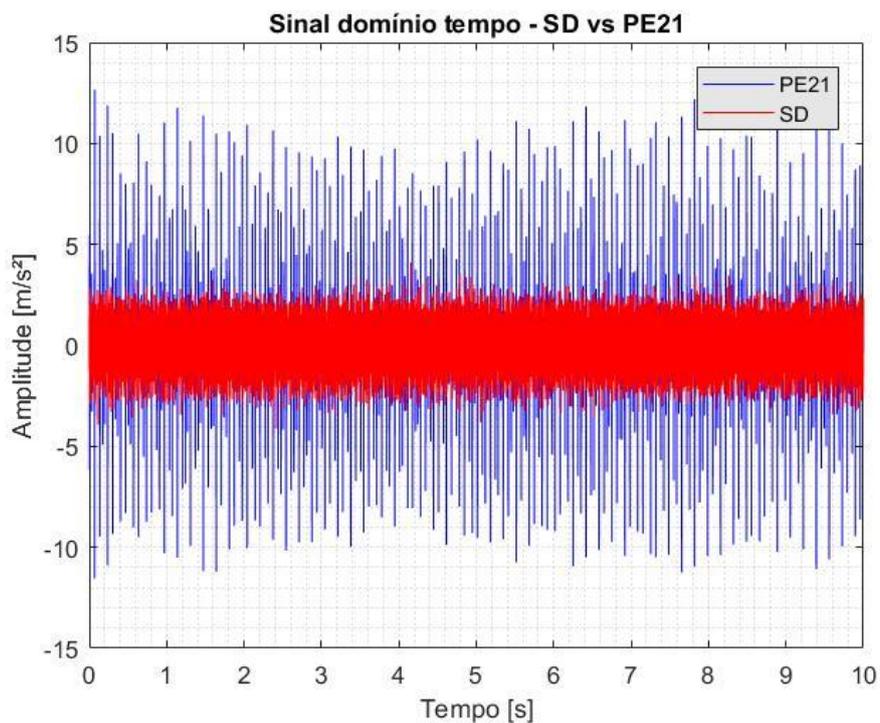
Fonte: próprio autor

Figura 18 - Sinal SD em comparação ao sinal ESF21



Fonte: próprio autor

Figura 19 - Sinal SD em comparação ao sinal PE21



Fonte: próprio autor

Para uma análise e classificação mais precisa no domínio tempo, foram utilizados descritores estatísticos provenientes das Equações 1 a 9, parcialmente apresentados na Tabela 12. Esses descritores permitem extrair informações relevantes dos sinais de vibração e, assim, auxiliar na classificação dos diferentes tipos de defeitos presentes nos rolamentos.

Tabela 12 - Descritores estatísticos - Domínio tempo

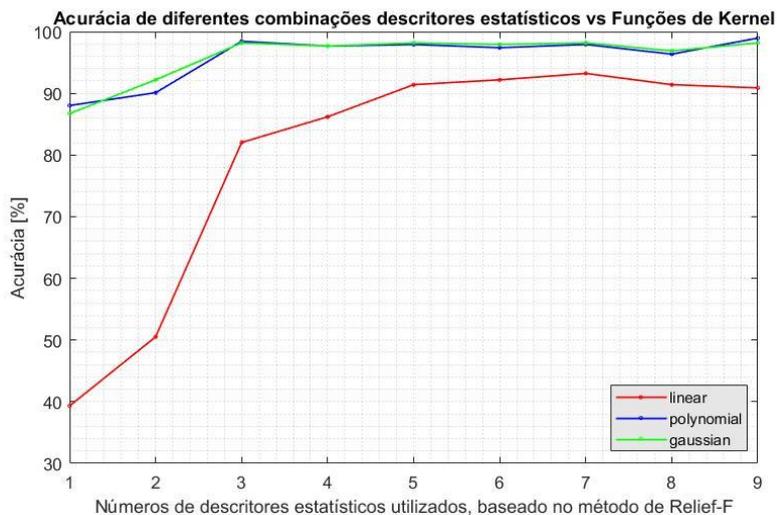
n	CLASSE	σ	<i>rms</i>	<i>sf</i>	<i>sc</i>	<i>pv</i>	<i>k</i>	<i>if</i>	<i>cf</i>	μ
1	SD	-0,0003	0,0729	0,0729	0,2854	3,9160	4,8848	2,9217	-0,1443	1,2474
2	SD	0,0004	0,0777	0,0777	0,2393	3,0797	3,8383	2,8483	-0,0550	1,2463
3	SD	-0,0012	0,0724	0,0724	0,2147	2,9675	3,7128	2,7968	0,0203	1,2511
4	SD	-0,0015	0,0727	0,0727	0,2619	3,6016	4,4870	2,8685	-0,0793	1,2458
5	SD	-0,0018	0,0718	0,0718	0,2281	3,1751	3,9761	2,9122	-0,1496	1,2523
⋮										
475	PE21	-0,0178	0,3590	0,3593	3,6414	10,1339	22,8678	32,9437	-0,2815	2,2566
476	PE21	-0,0186	0,3491	0,3495	3,8680	11,0666	24,8802	35,9085	-0,3452	2,2482
477	PE21	-0,0188	0,3535	0,3539	4,4101	12,4603	28,5330	45,7096	-0,3093	2,2899
478	PE21	-0,0196	0,3539	0,3544	4,4162	12,4617	28,9959	46,9837	-0,2653	2,3268
479	PE21	-0,0198	0,3619	0,3623	3,8315	10,5750	24,1098	36,7012	-0,2257	2,2799
480	PE21	-0,0206	0,3825	0,3829	3,6138	9,4369	22,0383	35,4063	-0,3371	2,3353

Fonte: próprio autor

Para identificar as combinações de descritores que proporcionassem maior acurácia na classificação, foram utilizados diferentes conjuntos de descritores com base no método Relief-F apresentado anteriormente. A relação entre o número de descritores e a acurácia para função de Kernel linear, polinomial e gaussiana é ilustrada na Figura 20, que apresenta o número de descritores no eixo x, ordenados de acordo com a relevância para a classificação, como indicado na Tabela 8.

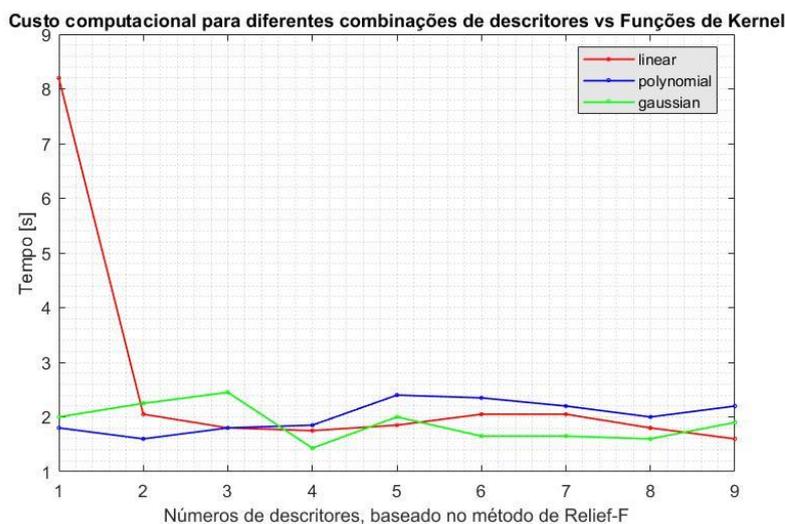
No contexto de análise de desempenho de um classificador, na Figura 21 é apresentada uma comparação do custo computacional para diferentes combinações de descritores e funções de Kernel. Para gerar esse gráfico, o modelo foi treinado várias vezes em configurações distintas e os tempos de treinamento foram registrados, sendo posteriormente calculada a média, que é ilustrada na Figura 21. Esses resultados são relevantes para avaliar a eficiência do classificador em diversas configurações e podem orientar a escolha dos parâmetros para otimizar o desempenho do modelo.

Figura 20 - Números de descritores e a acurácia para funções de Kernel - Domínio tempo



Fonte: próprio autor

Figura 21 - Números de descritores e a custo computacional para funções de Kernel – Domínio tempo



Fonte: próprio autor

É ilustrado na Figura 20 a similaridade na acurácia com uso dos três primeiros descritores estatísticos para as funções de Kernel Polinomial e Gaussiana. No entanto, é apontado na Figura 21 que o custo computacional da função de Kernel Polinomial é cerca de 40% menor do que o da função de Kernel Gaussiana. Portanto, este estudo optará pelo uso da função de Kernel Polinomial para o domínio tempo, juntamente com os três descritores estatísticos mais relevantes identificados pelo método Relief-F.

Além disso, nas Figuras 20 e 21 é possível o entendimento que não há uma

correlação diretamente proporcional entre acurácia observada e custo computacional com diferentes números de descritores estatísticos, ou seja, um número alto de descritores não necessariamente representará melhor o modelo, pois pode incorrer em erros de *overfitting* ou *underfitting*, essa relação pode ser observada no gráfico da Figura 20, onde pode-se observar um valor de acurácia menor adotando-se 4 descritores estatísticos de que quando se adota 3. Já na Figura 21 é possível observar uma variação do custo computacional de acordo com a complexidade de treinamento do modelo, essa complexidade deriva de vários fatores, como separabilidade dos dados e número de iterações.

A análise no domínio tempo-frequência foi realizada utilizando a transformada *wavelet packet* (WPT), com o sinal de vibração decomposto em 5 níveis por meio de uma *wavelet*-mãe Daubechies de ordem 8 (db8). Foram calculados os valores de energia e entropia de Shannon para cada nó da árvore de decomposição no quinto nível, utilizando as Equações 13 e 14, respectivamente. Os resultados parciais obtidos estão apresentados na Tabela 13, permitindo a avaliação do comportamento do sinal em diferentes frequências e níveis de resolução.

Tabela 13 - Energia e Entropia de Shannon - Domínio tempo-frequência

Atributo	SE(5,0)	E(5,0)	SE(5,1)	E(5,1)	SE(5,2)	...	E(5,29)	SE(5,30)	E(5,30)	SE(5,31)	E(5,31)
N	1	2	3	4	5	...	60	61	62	63	64
1	5,172	2,109	5,021	0,787	5,225	...	0,002	5,700	0,013	4,501	0,006
2	5,062	2,807	5,029	1,121	4,953		0,001	5,553	0,015	5,381	0,005
3	5,335	1,802	5,203	0,669	4,927		0,002	5,473	0,015	2,695	0,008
4	4,884	5,641	5,162	0,695	5,148		0,001	5,557	0,015	3,244	0,015
5	5,323	1,789	5,122	0,767	4,991		0,002	5,670	0,016	4,799	0,009
⋮	⋮					⋮	⋮				
476	5,561	1,709	5,082	0,628	4,28	...	0,608	3,260	3,864	4,355	1,292
477	5,456	1,201	5,264	0,757	4,362		0,873	4,935	2,051	3,894	3,023
478	5,435	1,114	4,936	0,826	4,682		0,623	3,099	4,911	4,278	1,801
479	5,520	1,067	5,056	0,997	4,402		0,863	3,221	3,403	4,372	1,933
480	5,581	1,058	5,168	0,403	4,424		0,588	3,004	4,282	4,285	1,529

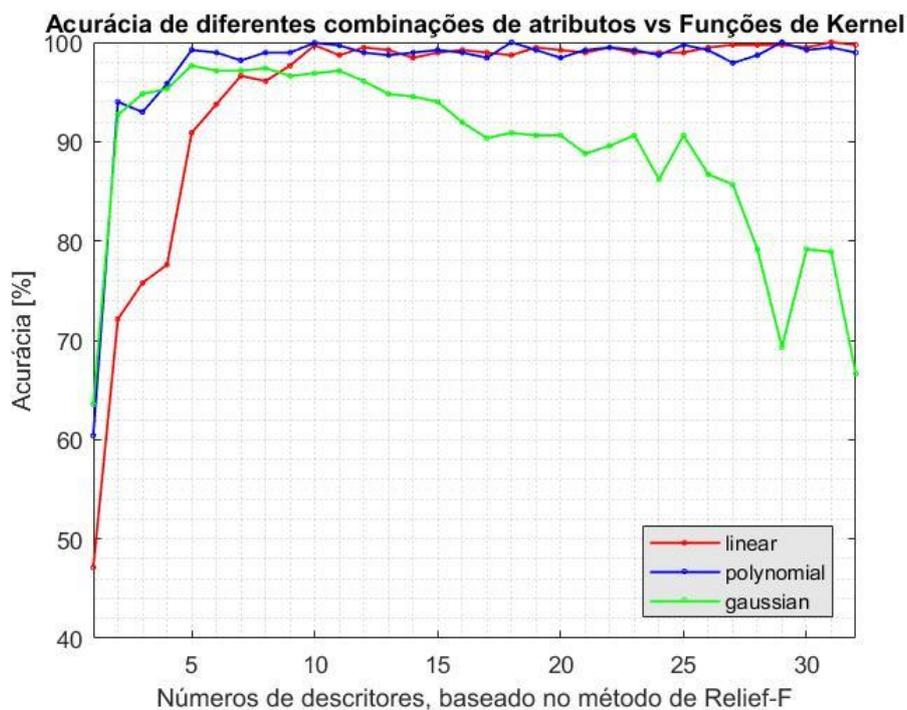
Fonte: próprio autor

Onde “SE” e “E” são os valores de entropia de Shannon e energia indicados à cada nó.

O mesmo procedimento utilizado no domínio tempo foi aplicado ao domínio

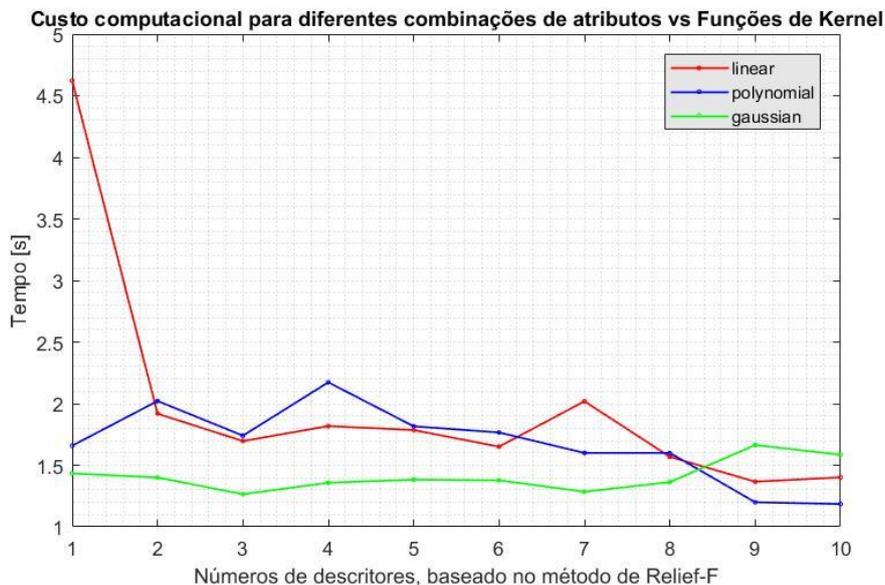
tempo-frequência, resultando nas Figuras 22 e 23. Essas figuras ilustram a relação entre o número de descritores e a acurácia do classificador e o custo computacional. É apresentado na Figura 22 a análise para a seleção de 32 descritores entre os 64 gerados, priorizando os primeiros em ordem de relevância segundo o método Relief-F. Já na Figura 23 o custo computacional para classificar as classes considerando as 10 primeiras combinações de descritores, o que permite avaliar o desempenho em um conjunto menor de parâmetros. Os tempos de treinamento foram calculados de maneira similar ao que foi apresentado na Figura 21.

Figura 22 - Números de descritores e a acurácia para funções de Kernel - Tempo-frequência



Fonte: próprio autor

Figura 23 - Números de descritores e a custo computacional para funções de Kernel - Tempo-frequência



Fonte: próprio autor

É indicado na Figura 22 dois pontos de interesse na relação entre o número de descritores e a acurácia do classificador no domínio tempo-frequência, obtidos com 5 e 10 descritores. No entanto, na Figura 23 é indicado que o custo computacional para classificar as classes é cerca de 60% menor quando se utilizam os 10 descritores mais relevantes. Portanto, para a abordagem no domínio tempo-frequência adotou-se os 10 primeiros descritores e a função de Kernel Polinomial.

É importante salientar que a análise feita para as Figuras 20 e 21 também é válida para essa abordagem, ou seja, não há uma relação diretamente proporcional entre o número de atributos adotados e uma melhor acurácia ou melhor custo computacional.

A Tabela 14 apresenta, no domínio tempo e tempo-frequência, com os parâmetros já apontados o desempenho em acurácia do classificador SVM com o conjunto de dados de treino e de teste.

Tabela 14 - Acurácias para dados de treino e teste em diferentes domínios

Domínio	Função de Kernel	Tipo de dado	Acurácia
TEMPO	Polinomial	Treino	98.70%
TEMPO	Polinomial	Teste	97.92%
TEMPO-FREQUÊNCIA	Polinomial	Treino	100%
TEMPO-FREQUÊNCIA	Polinomial	Teste	100%

Fonte: próprio autor

Quando se trata de modelos de classificação com treinamento supervisionado, é importante salientar que o objetivo é criar um modelo que generalize bem para dados ainda não vistos. Entretanto, durante o processo de treinamento, dois erros comuns podem ocorrer: *Overfitting* e *Underfitting*.

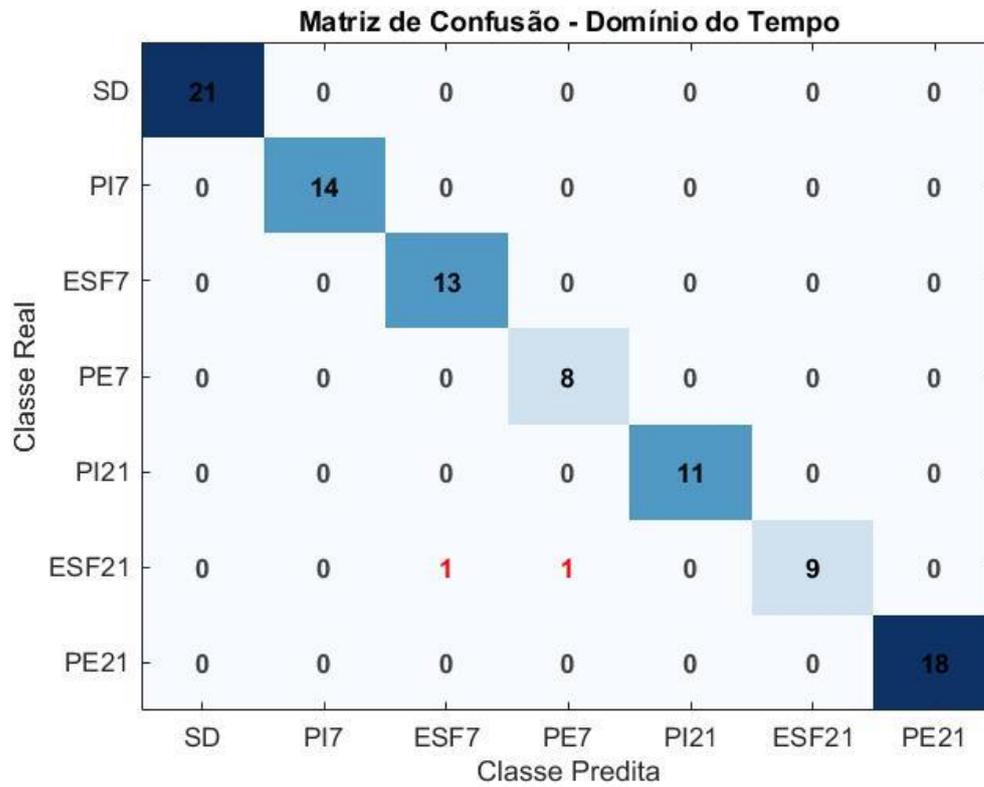
O *Overfitting* ocorre quando o modelo se ajusta muito bem aos dados de treinamento, mas não generaliza bem para novos dados. Isso ocorre porque o modelo aprende ruídos e detalhes irrelevantes dos dados de treinamento, em vez de aprender as características mais importantes que permitem a generalização. Isso pode resultar em uma acurácia muito alta nos dados de treinamento, mas uma acurácia significativamente menor em dados não vistos.

Por outro lado, o *Underfitting* ocorre quando o modelo não é complexo o suficiente para capturar as relações importantes entre as variáveis. Isso pode resultar em uma baixa acurácia nos dados de treinamento e uma baixa acurácia em dados não vistos.

Com base nos resultados apresentados na Tabela 14, é possível afirmar que o modelo de classificação utilizado não apresentou os erros de *Overfitting* e *Underfitting*, dado que não há diferença na acurácia entre a rodada de treino e teste para a abordagem no domínio tempo-frequência e no domínio tempo a diferença entre a acurácia na rodada de treino e teste é por volta de apenas 0,78%. Esses valores indicam que o modelo é bem representativo e não está superajustando aos dados de treinamento (*Overfitting*) nem generalizando de forma insuficiente (*Underfitting*).

Com o intuito de representar a relação entre as classes reais e previstas pelo modelo treinado, foram utilizadas as matrizes de confusão presentes nas Figuras 24 e 25, uma ferramenta amplamente adotada para análise em modelos de classificação.

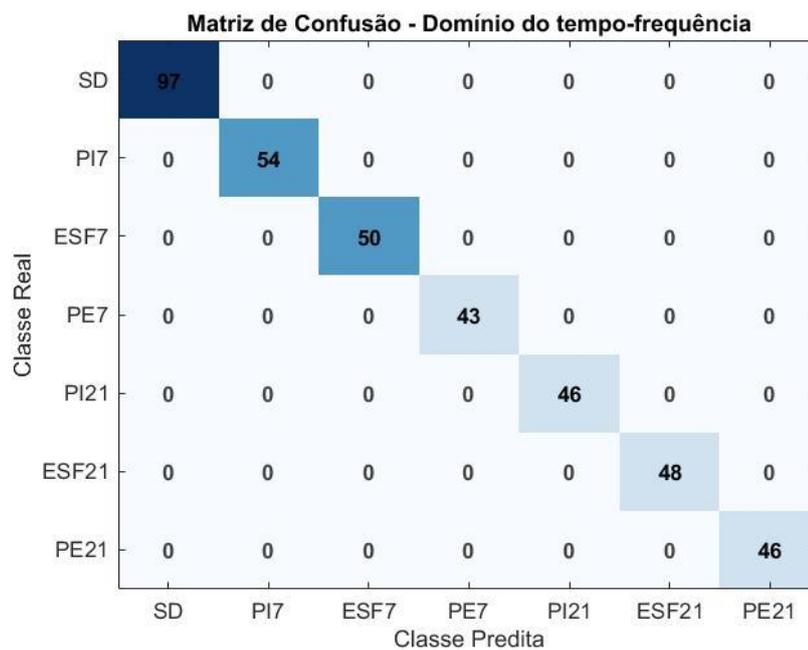
Figura 24 - Matriz de confusão - Domínio Tempo



Fonte: próprio autor

Ao analisar a Figura 24, é possível observar que duas falhas ocorreram na classificação da classe de defeito ESF21, sendo classificada erroneamente como ESF7 e PE7.

Figura 25 - Matriz de confusão - Domínio tempo-frequência



Fonte: próprio autor

A análise da Figura 25 demonstra que o modelo proposto conseguiu classificar todas as classes de maneira correta, corroborando com os resultados apresentados na Tabela 14.

5 CONSIDERAÇÕES FINAIS

Neste trabalho, foram apresentadas duas abordagens para a classificação de falhas em rolamentos esféricos utilizando o modelo SVM, com o objetivo de contribuir para o diagnóstico precoce de falhas em sistemas mecânicos e, conseqüentemente, para a aplicação de técnicas de manutenção preditiva. Os dados utilizados foram cedidos pela CASE WESTERN RESERVE UNIVERSITY e foram manipulados por meio do *software* MATLAB®.

Ambas as abordagens apresentadas neste estudo para a classificação de falhas em rolamentos esféricos mostraram-se eficientes na extração de características discriminantes dos sinais, tanto no domínio tempo quanto no tempo-frequência. No domínio tempo, foram utilizados descritores estatísticos extraídos diretamente do sinal bruto, enquanto no tempo-frequência, foi utilizada a transformada de *wavelet packet* para a extração de valores de energia e entropia de Shannon no nível mais sensíveis da decomposição.

Os resultados obtidos foram promissores, com acurácias altas de 97,92% e 100% para as abordagens no domínio tempo e no tempo-frequência, respectivamente. A alta acurácia obtida indica que as abordagens propostas são capazes de identificar com precisão as condições de falha em rolamentos esféricos.

No entanto, visando uma melhor performance do modelo de classificação e evitando que defeitos menos críticos sejam classificados erroneamente, como foi observado na matriz de confusão da abordagem no domínio tempo, a utilização da abordagem no domínio tempo-frequência mostrou-se mais recomendada. Essa abordagem permite a extração de informações mais precisas e discriminantes dos sinais, considerando as variações no tempo e na frequência, o que pode levar a uma classificação mais acurada e confiável das falhas em rolamentos esféricos.

Dessa forma, a abordagem no domínio tempo-frequência pode ser uma escolha mais adequada para aplicações práticas de diagnóstico e monitoramento de condições em sistemas mecânicos.

A seguir estão presentes algumas sugestões para trabalhos futuros:

- Implementação de um sistema de monitoramento e diagnóstico de falhas em tempo real, utilizando as técnicas desenvolvidas neste trabalho, para auxiliar na tomada de decisões em processos de manutenção preditiva;

- Utilização de outras fontes de dados, além dos sinais de vibração, como dados de temperatura e corrente elétrica, para a detecção de falhas em rolamentos esféricos;
- Investigação de outras técnicas de processamento de sinais, como a análise de componentes principais (PCA);

Utilização de outras técnicas de aprendizado de máquina, como redes neurais artificiais e árvores de decisão, para comparar os resultados obtidos com o algoritmo SVM.

REFERÊNCIAS

AHERWAR, A. E KHALID, S. **Vibration analysis techniques for gearbox diagnostic: A review**. Int. J. Adv. Eng. Technol., 3, 4-12, 2012.

ALFREDSON, R.; MATHEW, J. **Time domain methods for monitoring the condition of rolling element bearings**. NASA STI/Recon Technical Report A, v. 86, p. 102–107, 1985.

ATTO, A. M.; BERTHOUMIEU, Y.; BOLON, P. **2-Dimensional Wavelet Packet Spectrum for Texture Analysis**. International Conference on Image and Signal Processing, 2012, Agadir. Proceedings of International Conference on Image and Signal Processing. Agadir: IEEE, 2012.

BARTLETT, P. L.; WEGKAMP, M. H. **Classification with a Reject Option using a Hinge Loss**. Journal of Machine Learning Research, v. 9, n. 8, 2008.

BEARING DATA CENTER, CASE WESTERN RESERVE UNIVERSITY. Disponível em: <http://csegroups.case.edu/bearingdatacenter/home>. Acesso em: 2 de out. de 2022.

BERRY J. **How to track rolling bearing health with vibration signature analysis, Sound and Vibration**, 1991.

BEZERRA, R. A. **Deteção de falhas em rolamentos por análise de vibração**. 2004. 150p. Tese (doutorado) - Universidade Estadual de Campinas, Faculdade de Engenharia Mecânica, Campinas, SP.

BURGES, C.J.C. **A tutorial on Support Vector Machines for pattern recognition**. Data Mining and Knowledge Discovery, v. 2, p. 121-167, 1998.

CHANG, C. -C., & LIN, C. -J. **LIBSVM: A Library for Support Vector Machines**. ACM Transactions on Intelligent Systems and Technology, 2(3), 27:1–27:27, 2011.

CHEN, Z., DINO, I., AKRAM, N. A. **Unsupervised Real Time Prediction of Faults Using the Support Vector Machine**, 2020.

CORTES, C.; VAPNIK, V. **Support-vector networks**. Machine Learning, v. 20, p. 273-297, 1995.

FACELI, K. et al. **Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina**, volume 1. LTC, Rio de Janeiro. 2011.

GIRDHAR, P. **Practical Machinery Vibration Analysis and Predictive Maintenance**. 1. ed. Oxford: Elsevier, 2004.

GU, B. et al. **Chunk incremental learning for cost-sensitive hinge loss support vector machine**. Pattern Recognition, v. 83, p. 196-208, 2018.

GUPTA, P; PRADHAN, M.K. **Fault detection analysis in rolling element bearing: A review**. **Materials Today: Proceedings**, v.4, n.2, Part A, p.2085-2094, 2017.

JAKKULA, V. **Tutorial on support vector machine (svm)**. School of EECS, Washington State University, v. 37, n. 2.5, p. 3, 2006.

KARDEC, A.; LAFRAIA, J.R.B. **Gestão estratégica e confiabilidade**. São Paulo: Qualitymark, 2002.

KARDEC, A.; NASCIF, J. **Manutenção – Função Estratégica**. 4ª Edição: Rio de Janeiro: Qualitymark Editora, 2013.

KECMAN, V. **Support Vector Machines-an introduction**. Support Vector Machines: theory and applications, v. 77, p. 1-47, 2005.

KECMAN, V. **Support Vector Machines-an introduction**. Support Vector Machines: theory and applications, v. 77, p. 1-47, 2005.

KIRA, K.; RENDELL, L. A. **The Feature Selection Problem: Traditional Methods and a New Algorithm**. In: Proceedings of the Tenth National Conference on Artificial Intelligence. San Jose, California: AAAI Press, p. 129-134, 1992.

LI, X.; TSO, S. K.; WANG, J. **Real-time tool condition monitoring using wavelet transforms and fuzzy techniques**. IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews), v. 30, n. 3, p. 352-357, 2000.

LIU, H.M.; LU, C.; ZHANG, J.C. **Bearing fault diagnosis based on Shannon entropy and wavelet package decomposition**. Vibroengineering PROCEEDIA, v. 4, p. 223-228, 2014.

Ma, J., Wu, J., & Wang, X. **Fault diagnosis method based on wavelet packet-energy entropy and fuzzy kernel extreme learning machine**. Advances in Mechanical Engineering, 10(1), 2018.

MALLAT, S. **A wavelet tour of signal processing**, Academic Press, San Diego, CA. 1999.

MCFADDEN, P.D.; SMITH, J.D. **Vibration monitoring of rolling element bearings by the high-frequency resonance technique - A review**. Tribol Int., v. 17, n. 1, p. 1-10, 1984.

MESQUITA, A.L., SANTIAGO, D.F., BEZERRA, R.A., MIRANDA, U.A., DIAS, M. & PEDERIVA, R. **Detecção De Falhas Em Rolamentos Usando Transformadas Tempo-Frequência – Comparação Com Análise De Envelope**, 2002.

PATLE, A.; CHOUHAN, D.S. **SVM kernel functions for classification**. In Proceedings of the 2013 International Conference on Advances in Technology and Engineering (ICATE), 1-9, 2013.

PRUDHOM, A., ANTONINO-DAVIU, J., RAZIK, H., & CLIMENTE-ALARCON, V. **Time-frequency vibration analysis for the detection of motor damages caused by bearing currents**. Mechanical Systems and Signal Processing, 84, 747-762, 2017.

REMESEIRO, B.; BOLON-CANEDO, V. **A review of feature selection methods in medical applications**. Comput Biol Med., [S.l.], v. 112, p. 103375, 2019.

SANTOS, R. S. **Detecção de falhas em rolamentos de máquinas rotativas utilizando técnicas de processamentos de sinais**. 2017. 189 f. Tese (Doutorado em Engenharia Mecânica) - Universidade Estadual Paulista (Unesp), Faculdade de Engenharia, Guaratinguetá, 2017.

SAWALHI, N.; RANDALL, R. B.; ENDO, H. **The enhancement of fault detection and diagnosis in rolling element bearings using minimum entropy deconvolution combined with spectral kurtosis**. Mechanical Systems and Signal Processing, v. 21, n. 6, p. 2616-2633, 2007.

SHIGLEY, J. E.; MISCHKE, C. R. **Bearings and Lubrication: A Mechanical Designers' Workbook**. McGraw-Hill mechanical designers' workbook series. 1990.

SKODRAS, A. **Discrete Wavelet Transform: An Introduction**, 2015.

SOARES, L.; PINTO, L.; LOBÃO, D. **Aplicação de Machine Learning e Descritores Estatísticos para Diagnóstico de Falhas em Rolamentos de Motores Elétricos Industriais**. Anais do Simpósio Brasileiro de Automação (ASBA), 2(1), 2020.

STOLLNITZ, E.J.; DEROSE, A.D.; SALESIN, D.H. 1995. **Wavelets for computer graphics: a primer 1**. IEEE COMPUTER GRAPHICS AND APPLICATIONS. Seattle. 1995.

VORA, S.; GAIKWAD, J.A.; KULKARNI, J.V. **Advanced Research in Electrical and Electronic Engineering (AREEE)**, v. 2, n. 5, p. 41-46, 2015.

VUJOVI, I. **Analysis of the vibration signal using time-frequency methods**, 2015.

WANG, Z. et al. **Study on Wavelet Packet Energy Characteristics on Friction Signal of Lapping with the Fixed Abrasive Pad.** Micromachines (Basel), v. 13, n. 7, p. 981, jun. 2022.

WEBER, A. J. et al. **Telecurso: profissionalizante de Mecânica: manutenção.** Rio de Janeiro: Fundação Roberto Marinho, 2009.

WESCOAT, E.; et al. **Frequency Energy Analysis in Detecting Rolling Bearing Faults.** Procedia Manufacturing, v. 48, p. 980-991, 2020.

WICKERHAUSER, M. **INRIA lectures on wavelet packet algorithms.** 1991.

YANG, H.; MATHEW, J.; MA, L. **Fault diagnosis of rolling element bearings using basis pursuit.** Mechanical Systems and Signal Processing, v. 19, n. 2, p. 341-356, 2005. ISSN 0888-3270.

ZHAO, L.-Y.; WANG, L.; YAN, R.-Q. **Rolling Bearing Fault Diagnosis Based on Wavelet Packet Decomposition and Multi-Scale Permutation Entropy.** Entropy 2015, 17, 6447-6461.

Zhou, J.; et al. **Experimental Performance Study of a High Speed Oil Lubricated Polymer Thrust Bearing.** Lubricants, v.5, p.40, 2015.