



Instituto Superior de Engenharia

Politécnico de Coimbra

DEPARTAMENTO DE ENGENHARIA QUÍMICA E
BIOLÓGICA

Deteção de falhas em rolamentos através da análise de vibração usando métodos de aprendizagem computacional


Relatório de Trabalho de Projeto para a obtenção do grau de
Mestre em Engenharia e Gestão Industrial

Autor

Daniela Sá Fonseca

Orientadores

Professor Jorge Alexandre Caldeira Gonçalves de Almeida
Professor Mateus Daniel Almeida Mendes



INSTITUTO POLITÉCNICO
DE COIMBRA

INSTITUTO SUPERIOR
DE ENGENHARIA
DE COIMBRA

Coimbra, junho 2025

RESUMO

Este trabalho aborda a deteção de falhas em rolamentos com base na análise de sinais de vibração. Os rolamentos são componentes críticos em máquinas rotativas, sendo a sua degradação responsável por falhas mecânicas dispendiosas e inesperadas. O objetivo deste trabalho é investigar a viabilidade de utilizar o p-valor do teste de raiz unitária ADF (Augmented Dickey-Fuller) como indicador da transição de um regime de funcionamento saudável para um regime com falha. Foram utilizados conjuntos de dados de domínio público contendo sinais de vibração em diferentes cenários experimentais. Através da segmentação em janelas e da análise estatística dos p-valores ao longo do tempo, foi possível identificar padrões associados ao início da falha. Os resultados demonstram que a perda de estacionaridade está correlacionada com o início da degradação nos rolamentos, sugerindo que o método proposto pode ser uma ferramenta útil e não intrusiva na monitorização de condição. Esta abordagem contribui para o desenvolvimento de sistemas preditivos simples, mas eficazes, com potencial de aplicação em manutenção preditiva.

Palavras-chave: rolamentos, análise de vibração, estacionaridade, p-valor

ABSTRACT

This work addresses the detection of bearing faults based on vibration signal analysis. Bearings are critical components in rotating machinery, and their degradation is a major cause of unexpected and costly mechanical failures. The goal of this work is to investigate whether the p-value of the Augmented Dickey-Fuller (ADF) unit root test can be used as an indicator of the transition from a healthy to a faulty operational state. Four publicly available datasets containing vibration signals from various experimental setups were analyzed. By segmenting the signals into windows and tracking the evolution of p-values over time, patterns associated with fault onset were identified. The results show that the loss of stationarity correlates with the beginning of bearing degradation, suggesting that the proposed method can be a useful and non-intrusive tool for condition monitoring. This approach contributes to the development of simple yet effective predictive maintenance systems.

Keywords: bearings, vibration analysis, stationarity, p-value

EPÍGRAFE

Parece sempre impossível até que seja feito.

Nelson Mandela

DEDICATÓRIA

Dedico este trabalho aos meus avôs, que partiram cedo demais para me verem crescer, e muito antes de poderem testemunhar esta etapa da minha vida. A vossa ausência marcou a minha infância, mas a vossa memória acompanhou-me em silêncio ao longo do caminho. Esta conquista é também vossa, porque em mim permanece aquilo que de vós recebi — mesmo sem o saber.

AGRADECIMENTOS

Gostaria de expressar o meu profundo agradecimento a todos aqueles que, direta ou indiretamente, contribuíram para a realização deste trabalho.

Em primeiro lugar, agradeço aos meu orientadores, Professores Jorge Almeida e Mateus Mendes, pela orientação rigorosa, pelas sugestões valiosas, pela confiança depositada ao longo deste percurso e pela motivação indispensável.

À minha família, agradeço pelo apoio incondicional.

Aos meus pais, pelo esforço contínuo de me proporcionarem a educação que sempre sonharam para mim.

Às minhas avós, que sonharam juntamente comigo e que sempre quiseram viver comigo a finalização desta etapa.

À Zora, ao Anant e ao Zian, pela paciência e aconselhamento nas horas mais difíceis.

Ao meu tio Rui, um dos meus maiores fãs e impulsionador na minha vida, uma verdadeira fonte de inspiração para mim.

Às minhas primas, Lara e Matilde, que me levam sempre a querer ser um modelo a seguir e uma pessoa melhor.

À Débora e ao João, por serem um apoio incondicional ao longo desta jornada.

À Inês, por ser a minha âncora e fonte de motivação.

Ao Rui, à Mariana, à Gabriela e ao Diogo, os amigos de sempre, que sempre acreditaram nesta concretização.

Às pessoas que Coimbra me proporcionou, os meus amigos da faculdade, os meus colegas de casa, a todos que levo no coração ao fim destes 5 anos.

ÍNDICE

Resumo	i
Abstract	ii
Epígrafe	iii
Dedicatória	iv
Agradecimentos	v
Índice	1
Índice de tabelas	3
Índice de figuras	4
Lista de abreviaturas	6
Lista de siglas e acrónimos	7
Lista de símbolos	8
1 Introdução	9
2 Revisão da Literatura	11
2.1 Diagnóstico de falhas em rolamentos utilizando Análise de Envelope	11
2.2 Previsão do tempo de vida útil restante de um rolamento utilizando um método de aprendizagem auto-supervisionado	12
2.3 Previsão da Vida Útil Restante de Rolamentos com Base na Fusão de Características de Similaridade e Redes Neurais Convolucionais	14
2.4 Compilação dos Artigos Revistos	16
3 Enquadramento Teórico	18
3.1 Rolamentos	18
3.1.1 Lubrificação de rolamentos	18
3.1.2 Vida Útil dos Rolamentos	19

3.2	Fundamentos de Análise de Séries Temporais	19
3.2.1	Estacionaridade	19
3.2.2	Teste ADF e Cálculo do p-valor	19
3.2.3	Utilização do p-valor como Indicador de Falha	20
4	Datasets	21
4.1	Dataset Ball Bearing Run-to-Failure Dataset	21
4.2	Dataset Machinery Fault Dataset	21
4.3	Dataset Vibration analysis metrics of a ball bearing during different operational states	22
4.4	Dataset NASA Bearing Dataset	23
4.4.1	Dataset NASA Bearing Dataset: Análise	23
4.4.2	Modelo para Detecção de Falhas em Rolamentos	34
5	Discussão de Resultados	50
6	Conclusão	52
	Referências bibliográficas	54

ÍNDICE DE TABELAS

2.1	Compilação dos Artigos Revistos	17
2.2	Comparação técnica entre os métodos de previsão ou deteção de falhas .	17
4.1	Datasets	39
4.2	Estatísticas Antes e Depois da Falha	40
5.1	Comparação dos resultados dos modelos de classificação com diferentes métricas	51

ÍNDICE DE FIGURAS

4.1	1ª Parte Código para importar e analisar estatisticamente os dados	24
4.2	2ª Parte Código para importar e analisar estatisticamente os dados	24
4.3	Resultaos da Análise Estatística	26
4.4	Parte 1 do Código para a Análise Estatística Comparativa	28
4.5	Parte 2 do Código para a Análise Estatística Comparativa	28
4.6	Gráfico Vibração do Rolamento 1	30
4.7	Gráfico Vibração do Rolamento 2	30
4.8	Gráfico Vibração do Rolamento 3	30
4.9	Gráfico Vibração do Rolamento 4	31
4.10	Código para os Gráficos de Vibração dos 4 Rolamentos	31
4.11	Gráfico do p-valor ao longo da série temporal	32
4.12	Código do p-valor ao longo da série temporal	33
4.13	Gráfico do p-valor sobreposto com amplitude de vibração	34
4.14	Código para o gráfico do p-valor sobreposto com amplitude de vibração	35
4.15	Fluxo de preparação, extração de atributos, balanceamento e treino do modelo com base no p-valor.	41
4.16	Matriz de Resultados do Modelo de Classificação Baseado no P-valor do Teste ADF	42
4.17	Matriz de Confusão do Modelo de Classificação Baseado no P-valor do Teste ADF	42
4.18	Parte 1 do Código do Modelo de Classificação Baseado no P-valor do Teste ADF	43
4.19	Parte 2 do Código do Modelo de Classificação Baseado no P-valor do Teste ADF	43
4.20	Fluxo de preparação , extração de atributos e treino do modelo com base na amplitude média.	44
4.21	Matriz de Resultados do Modelo de Classificação Baseado Exclusivamente em Métricas de Amplitude	45
4.22	Matriz de Confusão do Modelo de Classificação Baseado Exclusivamente em Métricas de Amplitude	45
4.23	Parte 1 do Código do Modelo de Classificação Baseado Exclusivamente em Métricas de Amplitude	46

4.24	Parte 2 do Código do Modelo de Classificação Baseado Exclusivamente em Métricas de Amplitude	46
4.25	Fluxo de preparação, extração de atributos e treino do modelo com p-valor e amplitude.	47
4.26	Matriz de Resultados do modelo com combinação de p-valor e amplitude	48
4.27	Matriz de Confusão do modelo com combinação de p-valor e amplitude	48
4.28	Parte 1 do Código do modelo com combinação de p-valor e amplitude .	49
4.29	Parte 2 do Código do modelo com combinação de p-valor e amplitude .	49

LISTA DE ABREVIATURAS

ISEC Instituto Superior de Engenharia de Coimbra

LISTA DE SIGLAS E ACRÓNIMOS

ADF	<i>Augmented Dickey-Fuller</i>
BPFI	<i>Ball Pass Frequency Inner</i>
BPFO	<i>Ball Pass Frequency Outer</i>
BSF	<i>Ball Spin Frequency</i>
CNN	<i>Convolutional Neural Network</i>
FTF	<i>Fundamental Train Frequency</i>
ICP	<i>Integrated Circuit Piezoelectric</i>
IMS	<i>Intelligent Maintenance System</i>
KNN	<i>K-Nearest Neighbor</i>
LOWESS	<i>(Locally Weighted Scatterplot Smoothing)</i>
LSTM	<i>Long Short-Term Memory</i>
MFS	<i>Machinery Fault Simulator</i>
ML	<i>Machine Learning</i>
MAE	<i>Masked Autoencoder</i>
RMS	<i>Root Mean Square</i>
RMSE	<i>Root Mean Square Error</i>
RPM	<i>Rotações por Minuto</i>
RUL	<i>Remaining Useful Life</i>
SMOTE	<i>Synthetic Minority Over-sampling Technique</i>
SVM	<i>Support Vector Machines</i>
TCN	<i>Temporal Convolutional Network</i>

LISTA DE SÍMBOLOS

$^{\circ}C$	Graus Celsius
m/s^2	Metros por Segundo ao quadrado
mm/s^2	Milímetros por Segundo ao quadrado
kHz	Quilohertz

1 INTRODUÇÃO

Os rolamentos são componentes fundamentais em sistemas rotativos, sendo cruciais para o bom funcionamento de diversos equipamentos industriais. Durante a sua operação, estão sujeitos a elevadas cargas e esforços, o que os torna suscetíveis a desgastes e falhas. Em ambientes de produção de grande escala, onde múltiplas máquinas operam em altas rotações, a fiabilidade dos rolamentos torna-se essencial para garantir a eficiência e a continuidade do processo produtivo.

Qualquer falha nos rolamentos pode resultar em paragens não planeadas, aumento dos custos de manutenção e até danos severos noutros componentes do sistema. Por este motivo, é essencial detetar alterações no seu estado de forma precoce, permitindo uma intervenção preventiva e evitando consequências mais graves.

Existem várias técnicas de monitorização da condição de rolamentos, incluindo a medição de ruído acústico, monitorização de temperatura, análise de partículas de desgaste e, de forma mais comum, a análise de vibrações. A análise de sinais de vibração permite identificar anomalias com maior sensibilidade e detalhe, sendo amplamente utilizada em sistemas de manutenção preditiva.

A deteção precoce de falhas só é possível com um processo contínuo de monitorização e uma análise cuidadosa dos dados recolhidos. A identificação de sinais de degradação permite não apenas a deteção da falha iminente, mas também a previsão da Vida útil restante (RUL) do componente. Esta previsão é essencial para o planeamento eficaz da manutenção e para a minimização dos impactos negativos associados a falhas inesperadas.

Neste contexto, esta dissertação tem como objetivo investigar e propor uma abordagem baseada na análise estatística do sinal de vibração, nomeadamente através do teste de estacionaridade ADF (*Augmented Dickey-Fuller*) e do comportamento do respetivo p-valor ao longo do tempo, como um possível indicador da proximidade da falha de um rolamento.

Assim, as principais questões de investigação que esta tese pretende responder são:

- É possível utilizar o p-valor do teste ADF, aplicado a janelas da série temporal de vibração, como um indicador robusto do início da falha num rolamento?
- A vibração demonstra o estado de degradação do rolamento?
- A perda de estacionaridade do sinal de vibração indica o início da falha em rolamentos?

Através desta investigação, pretende-se contribuir para o desenvolvimento de métodos simples, interpretáveis e eficazes de monitorização e prognóstico da condição de rolamentos, com vista à melhoria dos sistemas de manutenção preditiva em ambientes industriais.

2 REVISÃO DA LITERATURA

2.1 Diagnóstico de falhas em rolamentos utilizando Análise de Envelope

Tradicionalmente, a detecção de falhas em rolamentos baseava-se em métodos clássicos como o cálculo de indicadores estatísticos (RMS, curtose) e a análise espectral no domínio da frequência. Embora úteis para detectar anomalias óbvias, essas abordagens apresentam limitações na detecção precoce e na identificação de falhas em condições de funcionamento ruidosas ou complexas. Com o avanço da capacidade computacional e das técnicas de inteligência artificial, surgiram abordagens mais sofisticadas que combinam análise de sinais com algoritmos de aprendizagem automática.

Os autores, González *et al.* [1], abordam o problema da detecção de falhas em rolamentos industriais, que é crucial para a manutenção preditiva e para a gestão de ativos em ambientes de Indústria 4.0. Destacam ainda a importância da previsão do tempo da RUL e do diagnóstico de falhas. Além disso, dão enfoque à dificuldade em detectar falhas em rolamentos, devido à natureza sutil dos sinais das falhas e à necessidade de distinguir entre diferentes tipos de falhas, como danos no anel interno, no anel externo, nas esferas ou na gaiola do rolamento. Demonstram também a importância da manutenção preditiva na prevenção de falhas em equipamentos, como rolamentos, que podem resultar em paragens não planeadas e custos significativos.

É utilizada uma abordagem abrangente que combina análise de vibração no domínio da frequência com técnicas de *Machine Learning* (ML). Primeiramente, realiza-se uma análise detalhada dos sinais de vibração, focada em quatro frequências principais associadas a falhas em rolamentos: BPFO (*Ball Pass Frequency Outer*), BPFI (*Ball Pass Frequency Inner*), BSF (*Ball Spin Frequency*) e FTF (*Fundamental Train Frequency*). Em seguida, os autores utilizam algoritmos de ML, como *K-Nearest Neighbors* (KNN), *Support Vector Machines* (SVM), *Árvores de Decisão* e *Kernel Naive Bayes*, para desenvolver modelos capazes de reconhecer padrões nos sinais de vibração e classificar diferentes tipos de falhas.

São extraídas características dos sinais de vibração, como amplitudes em frequências específicas e são usadas como entradas para esses modelos de ML. Para preparar os dados de vibração para a análise, os autores aplicam técnicas de pré-processamento, incluindo filtragem para remover ruídos indesejados e normalização para garantir que

os dados estejam na mesma escala. Além disso, realizam uma análise estatística preliminar para identificar características relevantes dos sinais de vibração que podem ser úteis para a detecção de falhas em rolamentos. Essas técnicas de pré-processamento são essenciais para garantir a qualidade e a consistência dos dados utilizados na construção dos modelos de ML.

Em [1] os autores conseguiram uma precisão de classificação de 100 por cento para a detecção de falhas nos rolamentos usando modelos de árvore de decisão (Fine Tree) e KNN (*Fine KNN*), ao empregar a amplitude do sinal de envelope como preditor.

2.2 Previsão do tempo de vida útil restante de um rolamento utilizando um método de aprendizagem auto-supervisionado

Em [2], é abordada a previsão da RUL de rolamentos como uma tarefa crucial para a manutenção preditiva de máquinas rotativas. As redes neurais de memória longa e curta (LSTM), as redes convolucionais temporais (TCN) e as suas variantes são identificadas como métodos promissores na criação de modelos de previsão do RUL com base no processamento automático de características e mineração de conhecimento em dados de monitorização. No entanto, esses métodos dependem fortemente de dados rotulados de RUL, que muitas vezes são escassos em sistemas críticos de segurança, levando a uma distribuição desequilibrada de informações de falha e saúde e rótulos esparsos de tempo de falha nos dados usados para previsão do RUL. Isso cria um dilema para os algoritmos de aprendizagem de máquina supervisionados existentes, que são dependentes de rótulos e exigem informações balanceadas.

Para solucionar o problema da escassez de dados rotulados e do desequilíbrio nos dados, foi proposto o uso de um método de aprendizagem auto-supervisionado (SSL) baseado numa arquitetura de rede neuronal convolucional recorrente (CNN-LSTM) para prever a RUL de rolamentos em máquinas rotativas. Os dados de vibração originais dos rolamentos foram submetidos a um pré-processamento, que envolveu o uso da transformação *wavelet* para extrair características relevantes, seguido pela divisão dos dados em segmentos de tempo para análise subsequente. A técnica principal aplicada foi a geração de Pares Contrastivos, utilizando duas abordagens: *Masked Autoencoder* (MAE) e Aprendizagem Contrastiva. O MAE foi utilizado para reconstruir os dados de RUL, mascarando aleatoriamente os sinais e pré-treinando o codificador. Os pares de dados contrastivos foram então gerados, onde cada par consistia numa amostra de vibração num momento de tempo e sua contraparte inversa (positiva e negativa), representando diferentes sequências de degradação.

Além disso, foi utilizada a arquitetura de rede neuronal CNN-LSTM, que combina ca-

redes convolucionais com camadas recorrentes para capturar tanto informações espaciais quanto temporais dos dados de vibração dos rolamentos. As camadas convolucionais foram eficazes na extração de características espaciais relevantes dos dados de entrada, enquanto as camadas recorrentes, como as LSTM, foram capazes de modelar dependências temporais de longo alcance nos dados de série temporal, permitindo uma compreensão mais profunda dos padrões de degradação ao longo do tempo.

Para treinar e testar o modelo, este foi treinado num conjunto de dados que continha uma combinação de dados rotulados e não rotulados, permitindo que aprendesse a reconhecer padrões de degradação nos dados de vibração e a prever a RUL dos rolamentos. Após o treino do modelo proposto, foi essencial testá-lo num conjunto de dados de teste separado para avaliar a sua capacidade de generalização e precisão em condições do mundo real. Neste estudo, o conjunto de dados de teste foi coletado da *PRONOSTIA Bearing Dataset*, uma base de dados amplamente utilizada para avaliar algoritmos de prognóstico da RUL. Durante o teste, o modelo processou os dados de entrada do conjunto de teste e gerou previsões para a RUL dos rolamentos. Essas previsões foram então comparadas com os valores reais de RUL no conjunto de teste para avaliar o desempenho do modelo.

Para avaliar a capacidade de generalização do modelo, foram calculadas métricas de desempenho, como o erro médio quadrático (RMSE), que mede a discrepância média entre as previsões do modelo e os valores reais de RUL. Outras métricas, como a precisão das previsões em intervalos específicos de RUL, também foram calculadas para fornecer uma compreensão mais detalhada do desempenho do modelo em diferentes cenários.

Os resultados demonstraram uma significativa melhoria na precisão da previsão da RUL dos rolamentos em comparação com o modelo de referência (CNN + LSTM), especialmente quando há escassez de dados rotulados disponíveis. Os valores de erro médio quadrático (RMSE) obtidos pelo modelo proposto foram inferiores aos do modelo de referência, indicando uma previsão mais precisa do RUL. Além disso, a análise das previsões do modelo mostrou que este foi capaz de capturar efetivamente informações de degradação e tendências sequenciais, mesmo com uma quantidade limitada de dados rotulados.

Em resumo, os resultados obtidos demonstraram que o modelo proposto foi eficaz na previsão da RUL dos rolamentos e superou o modelo de referência em termos de precisão e capacidade de generalização.

2.3 Previsão da Vida Útil Restante de Rolamentos com Base na Fusão de Características de Similaridade e Redes Neurais Convolucionais

Em [3], os autores propõem uma abordagem inovadora para a previsão da (RUL) de rolamentos, utilizando redes neurais convolucionais (CNN) em conjunto com uma técnica de fusão de características de similaridade.

Os autores fundamentam a escolha exclusiva do conjunto de dados número 2 do *IMS Bearing Dataset* com base em diversas vantagens experimentais e práticas que o distinguem dos restantes conjuntos disponíveis no mesmo conjunto de dados de referência. A estrutura do Set 2 é particularmente adequada à modelação de processos de degradação por apresentar um único ciclo de falha completo, referente à pista externa do rolamento 1, o que garante um percurso limpo desde o estado saudável até à falha, sem a presença de múltiplos modos de falha ou variações abruptas. Este aspeto permite não só uma maior confiabilidade nos dados como também uma menor interferência de ruídos estatísticos, o que é especialmente benéfico no treino de modelos supervisionados e na construção de indicadores de saúde.

Além disso, o *Set 2* é composto por 984 arquivos registados em intervalos regulares de 10 minutos, perfazendo aproximadamente 6,8 dias de operação contínua, o que proporciona uma amostragem suficientemente densa e longa para capturar todo o processo de degradação com boa resolução temporal. Os restantes conjuntos do *IMS Bearing Dataset* apresentam limitações que justificam a sua exclusão neste estudo, tais como a ocorrência de múltiplas falhas simultâneas no caso do Set 1 e a ausência de um comportamento de falha claro e progressivo no caso do Set 3, onde os sinais são mais ruidosos e de menor intensidade.

A metodologia desenvolvida pelos autores baseia-se na extração de características de similaridade entre diferentes janelas temporais dos sinais de vibração, recorrendo à análise de correlação entre atributos estatísticos ao longo do tempo. Para representar o estado de saúde do rolamento, é construído um indicador de saúde contínuo que evolui à medida que o sistema se degrada.

A construção deste indicador inicia-se com a extração de várias características estatísticas dos sinais de vibração, como o valor eficaz, a curtose, a assimetria, o valor de pico, o fator de impulso e o fator de forma, as quais são calculadas em janelas móveis ao longo da série temporal. Cada uma destas características é normalizada individualmente através da técnica *min-max*, garantindo que todas têm a mesma escala e contribuindo de forma equilibrada para o processo de fusão.

Em seguida, os vetores de características obtidos para cada instante de tempo são comparados com um vetor de referência, construído a partir dos primeiros instantes da

operação, nos quais se assume que o rolamento se encontra em bom estado. A métrica utilizada para quantificar a semelhança entre o estado atual e o estado saudável é a correlação de cosseno, cujo valor se aproxima de um quando os vetores são semelhantes e diminui com o avanço da degradação.

O indicador de saúde é então definido como o complemento da similaridade, isto é, um menos a correlação obtida, resultando num valor próximo de zero no início da operação e que tende a aumentar progressivamente até atingir valores próximos de um no momento da falha. Para assegurar uma evolução suave e robusta, os autores aplicam técnicas de suavização aos valores do indicador, como médias móveis, obtendo assim um vetor contínuo que reflete com precisão o grau de degradação em cada instante. Este vetor constitui a entrada do modelo preditivo.

A rede recebe como entrada o vetor de valores do indicador de saúde e produz como saída a estimativa da RUL expressa como uma fração do tempo total de operação até à falha. A principal vantagem desta abordagem reside na capacidade de integrar informação temporal de forma implícita através das convoluções, capturando padrões de degradação de forma mais robusta e generalizável do que métodos baseados apenas em valores instantâneos como o valor eficaz.

Os resultados apresentados no artigo demonstram que a predição da RUL realizada pelo modelo se aproxima significativamente da curva real de falha, validando a eficácia da abordagem proposta. O modelo mostrou-se capaz de acompanhar a progressão do desgaste com boa precisão, mesmo em fases iniciais de degradação. A escolha do *Set 2*, aliada à construção de um indicador de saúde sensível às mudanças no comportamento do rolamento, contribuiu decisivamente para a qualidade da previsão obtida. Esta decisão experimental permite isolar variáveis de confusão e tornar o problema mais tratável do ponto de vista computacional, além de facilitar a avaliação objetiva da performance dos algoritmos.

A partir da abordagem descrita e dos resultados obtidos, é possível enunciar várias questões de investigação relevantes para o desenvolvimento futuro de sistemas de prognóstico baseados em vibração. Uma primeira questão diz respeito à generalização do modelo, ou seja, à sua capacidade de manter a precisão preditiva quando aplicado a conjuntos de dados com outras características, como diferentes tipos de falha ou condições operacionais. Também se coloca a necessidade de avaliar a robustez do indicador de saúde construído, verificando se este se mantém informativo perante variações de carga, temperatura ou ruído de medição. Outra linha de investigação interessante consiste na comparação entre diferentes arquiteturas de redes neuronais, como redes recorrentes ou redes com memória de longo curto prazo, para avaliar a sua capacidade de capturar dinâmicas temporais mais complexas. Além disso, é pertinente explorar a viabilidade da implementação do modelo em sistemas de monitorização em tempo real, o que exige não só precisão, mas também eficiência computacional e baixo tempo

de resposta. Por fim, uma questão crítica relaciona-se com a interpretabilidade do modelo, uma vez que redes convolucionais tendem a comportar-se como caixas negras, o que pode dificultar a sua aceitação em contextos industriais onde a rastreabilidade das decisões é essencial.

2.4 Compilação dos Artigos Revistos

A presente secção tem como objetivo sintetizar os principais trabalhos revistos ao longo do capítulo, destacando os problemas abordados, os métodos utilizados e os resultados obtidos. A Tabela 2.1 apresenta esta compilação de forma estruturada, permitindo uma comparação direta entre as abordagens propostas para a deteção de falhas e a previsão da RUL de rolamentos com base em sinais de vibração.

Complementarmente, a Tabela 2.2 fornece uma comparação técnica das abordagens analisadas, considerando variáveis como o tipo de dados, o nível de supervisão, a extração de características e as métricas de desempenho. Esta tabela permite identificar tendências metodológicas, como o uso crescente de redes neuronais recorrentes e convolucionais, bem como o impacto do tipo de supervisão e do pré-processamento nos resultados obtidos.

Apesar dos avanços na previsão da RUL com redes neuronais, aprendizagem auto-supervisionada e técnicas de fusão de características, observa-se uma escassez de estudos que explorem a utilização de indicadores estatísticos simples, como o p-valor do teste de *Dickey-Fuller* aumentado (ADF), na deteção precoce de falhas. Esta lacuna motiva a abordagem proposta no presente trabalho, que investiga o uso de métricas de estacionaridade como possíveis indicadores primários de degradação em rolamentos, com base em dados reais de vibração.

Tabela 2.1: Compilação dos Artigos Revistos

	Problema	Métodos	Resultados
<i>González et al.</i>	Detecção de falhas em rolamentos industriais	Combinação entre análise de vibração no domínio da frequência e técnicas de ML	Precisão de classificação de 100% para a detecção de falhas
<i>Deng et al.</i>	Previsão do RUL de rolamentos como uma tarefa crucial para a manutenção preditiva de máquinas rotativas	Método de aprendizagem auto-supervisionado (SSL) baseado numa arquitetura de rede neuronal convolucional recorrente (CNN-LSTM)	Os valores de erro médio quadrático (RMSE) obtidos pelo modelo proposto foram inferiores aos do modelo de referência, indicando uma previsão mais precisa do RUL
<i>Lei et al.</i>	Previsão precisa da vida útil restante de rolamentos com base em sinais de vibração	Fusão de características de similaridade extraídas de indicadores de saúde e rede neuronal convolucional unidimensional (1D-CNN)	O modelo conseguiu estimar com elevada precisão a progressão da falha no Set 2 do IMS, com boa concordância entre o HI e a RUL real

Tabela 2.2: Comparação técnica entre os métodos de previsão ou detecção de falhas

Abordagem	Tipo de dados	Supervisão	Extração de características	Métrica de desempenho
<i>González et al.</i> [1] Análise de envelope + ML	Domínio da frequência (vibração)	Supervisionado	Manual: frequências características	Acurácia de classificação: 100%
<i>Deng et al.</i> [2] CNN-LSTM com pares contrastivos	Sinais brutos de vibração	Auto-supervisionado	Automática: convoluções + RNN	RMSE inferior ao modelo de referência
<i>Lei et al.</i> [3] Fusão de características + CNN	Indicadores estatísticos extraídos (vibração)	Supervisionado	Manual: estatísticas normalizadas + similaridade	Alta correlação HI vs RUL real

3 ENQUADRAMENTO TEÓRICO

3.1 Rolamentos

Os rolamentos são componentes essenciais em máquinas rotativas, permitindo o movimento rotacional suave dos eixos em relação à estrutura fixa da máquina. Segundo *Harris e Kotzalas* [4], mais de 90% das máquinas utilizam rolamentos com elementos rolantes, sendo estes elementos críticos para a operação fiável de equipamentos industriais. A falha de um rolamento pode levar à paralisação total da máquina.

Durante a operação, os rolamentos estão sujeitos a cargas pesadas e dinâmicas, geradas pelas próprias máquinas e transmitidas através dos seus componentes. Estas condições exigem alta robustez e eficiência no desempenho. *Randall e Antoni* [5] destacam que os rolamentos são particularmente sensíveis a defeitos mecânicos como fissuras ou falhas nas pistas e esferas, os quais geram padrões de vibração característicos.

Existem diversos tipos de rolamentos: de esferas, de rolos cilíndricos, de agulhas, de rolos cónicos e de rolos esféricos. Cada tipo é otimizado para diferentes cargas e aplicações. Por exemplo, os rolamentos de esferas têm baixo atrito e são ideais para altas rotações, enquanto os de rolos cilíndricos são utilizados em situações com grandes cargas radiais [6].

3.1.1 Lubrificação de rolamentos

A lubrificação é essencial para reduzir o atrito e o desgaste, bem como para proteger contra a corrosão. Segundo *Roylance* [7], a escolha adequada entre graxa e óleo influencia diretamente a temperatura operacional e, conseqüentemente, a vida útil do rolamento.

A condição de lubrificação pode ser quantificada pelo fator k , definido por:

$$k = \frac{v}{v_1} \quad (3.1)$$

Onde v é a viscosidade operacional real do lubrificante e v_1 é a viscosidade nominal, dependente do diâmetro médio e da velocidade de rotação do rolamento. Valores mais altos de k correspondem a melhores condições de lubrificação.

3.1.2 Vida Útil dos Rolamentos

A vida útil dos rolamentos é muitas vezes expressa em termos de vida de rating, ou seja, o número de horas ou ciclos até ocorrer falha. Segundo a norma ISO 281:2007 [8], este valor depende de diversos fatores, incluindo a carga, velocidade e condições de funcionamento.

A vida útil estimada pode ser calculada pela equação:

$$L_h = \frac{K_L \cdot C_r}{P \cdot f_p \cdot f_v \cdot f_\theta \cdot f_A \cdot f_\beta \cdot f_{dK} \cdot f_{Hz}} \quad (3.2)$$

Onde:

- L_h : vida útil estimada (horas);
- K_1 : fator de confiabilidade;
- C_r : capacidade de carga dinâmica do rolamento;
- P : carga equivalente;
- $f_p, f_t, f_o, f_A, f_B, f_{ak}, f_{hz}$: fatores de correção relacionados a rotação, temperatura, lubrificação e carga.

Jardine *et al* [9] reforçam a importância destes parâmetros ao desenvolver modelos preditivos de falha, com foco na *Remaining Useful Life* (RUL).

3.2 Fundamentos de Análise de Séries Temporais

3.2.1 Estacionaridade

Uma série temporal é dita estacionária quando suas propriedades estatísticas, como média, variância e autocorrelação, permanecem constantes ao longo do tempo. A estacionaridade é uma suposição fundamental em muitos métodos de análise e previsão, pois garante a estabilidade do sinal ao longo da observação.

3.2.2 Teste ADF e Cálculo do p-valor

O teste *Augmented Dickey-Fuller* (ADF) é um teste estatístico utilizado para verificar a estacionaridade de uma série temporal. A hipótese nula assume que a série é não estacionária (possui raiz unitária), enquanto a hipótese alternativa assume que a série é estacionária.

A equação estimada pelo teste ADF é:

$$\Delta y_t = \alpha + \beta t + \gamma y_{t-1} + \sum_{i=1}^p \delta_i \Delta y_{t-i} + \varepsilon_t \quad (3.3)$$

Onde:

- y_t : valor da série no tempo t ;
- $\Delta y_t = y_t - y_{t-1}$: diferença de primeira ordem;
- α : constante;
- βt : componente de tendência linear (opcional);
- γ : coeficiente da raiz unitária;
- δ_i : coeficientes das defasagens;
- ε_t : erro branco.

Após estimar o modelo, calcula-se a estatística do teste sobre α , e extrai-se o p-valor correspondente. Um p-valor inferior a 0,05 indica rejeição da hipótese nula, ou seja, a série é considerada estacionária.

O teste ADF é uma extensão do teste *Dickey-Fuller* original, incluindo defasagens adicionais da variável dependente para corrigir autocorrelação serial nos resíduos. Segundo Said e *Dickey* [10], esta abordagem melhora a potência do teste em séries com maior complexidade temporal.

3.2.3 Utilização do p-valor como Indicador de Falha

O p-valor do teste ADF pode ser monitorizado ao longo do tempo como um indicador da degradação do sistema. Sinais que passam de estacionários para não estacionários podem refletir alterações estruturais no funcionamento do rolamento, associadas ao início ou progressão de uma falha.

Apesar da sua simplicidade e robustez, o uso do p-valor como métrica primária é ainda pouco explorado na literatura, especialmente em contextos de dados reais de vibração. Este trabalho visa investigar a sua viabilidade e potencial na deteção precoce de falhas em rolamentos, sem necessidade de modelos de machine learning complexos.

Recentemente, estudos como os de Qiu *et al.* [11] e Lei *et al.* [12] destacaram o potencial de indicadores estatísticos extraídos diretamente dos sinais de vibração para identificar anomalias. Contudo, a maioria destes trabalhos concentra-se em métricas como RMS, curtose ou energia espectral, sendo raros os que aplicam testes formais de estacionaridade. A abordagem proposta neste trabalho — baseada no acompanhamento do p-valor do teste ADF — surge como uma alternativa promissora, especialmente pela sua simplicidade computacional e interpretação estatística direta.

No capítulo seguinte, será apresentada a aplicação prática destes conceitos aos conjuntos de dados analisados, com destaque para a evolução do p-valor ao longo do tempo e a sua relação com o comportamento vibracional dos rolamentos.

4 DATASETS

4.1 Dataset Ball Bearing Run-to-Failure Dataset

O conjunto conjunto de dados analisado neste trabalho foi obtido a partir de um teste de durabilidade de um rolamento de esferas, conduzido até à ocorrência de falha, e encontra-se disponível publicamente na plataforma *Kaggle* [13]. O objetivo do ensaio foi monitorizar o comportamento do rolamento ao longo do tempo através de variáveis relevantes para a deteção de falhas, nomeadamente vibração e temperatura.

Foram registadas quatro variáveis principais: vibração nos eixos X e Y (em g), temperatura do rolamento (em °C) e temperatura atmosférica (em °C). O teste teve uma duração total de 128 horas de operação contínua, sendo conduzido num ciclo repetido de 5 minutos de funcionamento seguidos de 15 minutos de repouso. Os dados foram recolhidos a intervalos de uma hora e armazenados em ficheiros no formato CSV.

A ocorrência de falhas foi confirmada no final do teste. Os critérios utilizados para a deteção da falha incluíram uma temperatura do rolamento superior a 85°C e níveis de vibração superiores a 9mm/s². Após as 128 horas de operação, foi identificada a presença de falhas nas pistas interna e externa do rolamento, bem como trincas e danos nas esferas, sendo estas patologias confirmadas posteriormente por meio de análise por raios-X.

4.2 Dataset Machinery Fault Dataset

O segundo conjunto de dados considerado neste trabalho foi obtido a partir do *Machinery Fault Simulator* (MFS) da empresa *SpectraQuest*, um equipamento utilizado para gerar e estudar diferentes tipos de falhas em motores elétricos. O conjunto de dados encontra-se disponível publicamente na plataforma *Kaggle* [14] e contém medições de vibração e sinal de rotação, registadas sob diversas condições de funcionamento e falha.

Foram registadas oito variáveis principais: frequência de rotação do motor, vibração nos eixos axial, radial e tangencial em dois pontos distintos do sistema (*underhang* e *overhang*), bem como o sinal de um microfone, utilizado para capturar anomalias acústicas durante o funcionamento da máquina. Os rolamentos *underhang* estão posicionados entre o rotor e o motor, enquanto os rolamentos *overhang* se localizam na extremidade oposta do veio, com o rotor entre o motor e o rolamento.

Os dados foram adquiridos a uma frequência de amostragem de 50 kHz, em janelas de 5 segundos por sequência. No total, foram recolhidas 1951 sequências, o que corresponde a aproximadamente 162 minutos de operação em diferentes condições. As condições experimentais abrangem tanto funcionamento normal (49 sequências) como várias situações de falha: desbalanceamento (333 sequências), desalinhamento horizontal (197 sequências), desalinhamento vertical (301 sequências), falhas nos rolamentos *underhang* (558 sequências) e falhas nos rolamentos *overhang* (513 sequências). As falhas nos rolamentos incluem defeitos típicos como danos na gaiola, na pista externa e nas esferas.

4.3 Dataset Vibration analysis metrics of a ball bearing during different operational states

O terceiro conjunto de dados utilizado neste trabalho foi disponibilizado através da plataforma *Zenodo* [15] e contém medições de parâmetros de vibração e temperatura obtidas em testes experimentais com rolamentos de esferas do tipo 6204 2RS. As medições foram realizadas com recurso a um sensor de vibração IFM VVB001, com uma frequência de aquisição de dois minutos entre leituras.

O sistema experimental foi constituído por um motor *Bonfiglioli BN80B4 FD* de 0,75kW e 1450rpm, acoplado a um redutor com relação de transmissão $i=80$, ligado por meio de um acoplador a um veio onde foi montado o rolamento sob análise. O objetivo do ensaio foi estudar o comportamento do rolamento em três condições distintas associadas ao nível de massa lubrificante: (1) rolamento selado com a quantidade recomendada de massa lubrificante industrial, (2) rolamento não selado e sem massa lubrificante, e (3) rolamento não selado com excesso de massa lubrificante.

Foram registadas as seguintes variáveis:

- *v-RMS*, valor eficaz da velocidade de vibração, utilizado como indicador da carga total na máquina rotativa;
- *a-RMS*, valor eficaz da aceleração, indicador de contacto mecânico entre componentes;
- *a-Peak*, valor máximo da aceleração (em m/s^2), associado a choques ou impactos;
- Fator de crista, definido como a razão entre o valor de pico e o valor RMS, útil para a caracterização de falhas incipientes;
- Temperatura, medida em graus Celsius.

As etiquetas associadas a cada amostra indicam o estado de lubrificação do rolamento durante a medição, permitindo a análise do impacto do nível de lubrificante no comportamento vibracional e térmico do sistema.

4.4 Dataset NASA Bearing Dataset

O quarto conjunto de dados utilizado neste trabalho foi fornecido pelo *Center for Intelligent Maintenance Systems* (IMS) da Universidade de *Cincinnati*, e está disponível publicamente através da plataforma *Kaggle* [16]. Este dataset contém registos experimentais de vibração adquiridos em testes de durabilidade realizados em rolamentos até à ocorrência de falha. Para isso, foram instalados quatro rolamentos num veio em rotação constante a 2000 RPM, ao qual foi aplicada uma carga radial de 6000 lbs por meio de um sistema de mola. Os rolamentos, modelo *Rexnord ZA-2115*, foram lubrificados à força durante toda a experiência.

A monitorização foi realizada com acelerómetros ICP de quartzo de alta sensibilidade (modelo PCB 353B33). No primeiro conjunto de dados, foram utilizados dois acelerómetros por rolamento, posicionados nos eixos X e Y; nos conjuntos de dados 2 e 3, foi utilizado um acelerómetro por rolamento. Os dados encontram-se organizados em três conjuntos experimentais distintos, cada um representando um ensaio contínuo até à falha. Os sinais de vibração foram registados em ficheiros individuais, correspondentes a janelas de 1 segundo de aquisição (20.480 amostras a 20 kHz), com intervalos de gravação de 10 minutos, exceto nos primeiros registos do primeiro conjunto, que foram gravados a cada 5 minutos. Os ficheiros estão em formato de texto e foram disponibilizados num pacote comprimido designado *IMS-Rexnord Bearing Data.zip*.

O primeiro conjunto de dados abrange o período entre 22 de outubro e 25 de novembro de 2003, totalizando 2156 ficheiros e oito canais de aquisição, dois por rolamento. Neste ensaio, foram registadas falhas na pista interna do rolamento 3 e no elemento rolante do rolamento 4. O segundo conjunto, com gravações de 12 a 19 de fevereiro de 2004, inclui 984 ficheiros distribuídos por quatro canais, um por rolamento, e apresenta uma falha na pista externa do rolamento 1. Já o terceiro conjunto de dados, obtido entre 4 de março e 4 de abril de 2004, contém 4448 ficheiros e também quatro canais, tendo sido registada uma falha na pista externa do rolamento 3.

4.4.1 Dataset NASA Bearing Dataset: Análise

O conjunto 2 do dataset descrito na secção 4.1 foi importado para *Python* através do código apresentado nas Figuras 4.1 e 4.2.

Análise Estatística

O mesmo código executa também uma análise estatística dos dados do dataset, ilustrada na Figura 4.3.

O número total de registos de cada rolamento é de 20.152.320.

A média dos valores para os rolamentos é negativa, o que sugere que as medições, em

```
C:\Users\danie\OneDrive\Ambiente de Trabalho\TESE\python-teste01\loading-v1.py
001-loading-v1.py X
1 import pandas as pd
2 import os
3
4 # Caminho do diretório onde estão os arquivos
5 diretorio = r"C:\Users\danie\OneDrive\Ambiente de Trabalho\TESE\python-teste01\20
6
7 # Alterar para o diretório onde estão os arquivos
8 os.chdir(diretorio)
9
10 # Verificar se o diretório foi alterado corretamente
11 print(f"O diretório atual é: {os.getcwd()}")
12
13 # Listar todos os arquivos no diretório
14 arquivos = os.listdir(diretorio)
15
16 # Lista para armazenar os DataFrames de cada arquivo lido
17 lista_dataframes = []
18
19 # Loop para ler cada arquivo
20 for arquivo in arquivos:
21     caminho_completo = os.path.join(diretorio, arquivo)
22
23     if arquivo.endswith('.39'):
24         try:
25             # Ler arquivo .39 com separador de tabulação
26             df = pd.read_csv(caminho_completo, delimiter='|', header=None)
27             lista_dataframes.append(df)
28             print(f"Lido arquivo .39: {arquivo}")
29         except Exception as e:
30             print(f"Erro ao ler arquivo {arquivo}: {e}")
31     else:
32         print(f"Arquivo ignorado (formato não suportado): {arquivo}")
33
34 # Concatenar todos os DataFrames
35 if lista_dataframes:
36     df_concatenado = pd.concat(lista_dataframes, ignore_index=True)
37
38 # Exibir estatísticas descritivas gerais
39 estatisticas = df_concatenado.describe()
40 print(estatisticas)
```

Figura 4.1: 1ª Parte Código para importar e analisar estatisticamente os dados

```
21     caminho_completo = os.path.join(diretorio, arquivo)
22
23     if arquivo.endswith('.39'):
24         try:
25             # Ler arquivo .39 com separador de tabulação
26             df = pd.read_csv(caminho_completo, delimiter='|', header=None)
27             lista_dataframes.append(df)
28             print(f"Lido arquivo .39: {arquivo}")
29         except Exception as e:
30             print(f"Erro ao ler arquivo {arquivo}: {e}")
31     else:
32         print(f"Arquivo ignorado (formato não suportado): {arquivo}")
33
34 # Concatenar todos os DataFrames
35 if lista_dataframes:
36     df_concatenado = pd.concat(lista_dataframes, ignore_index=True)
37
38 # Exibir estatísticas descritivas gerais
39 estatisticas = df_concatenado.describe()
40 print(estatisticas)
41 else:
42     print("Nenhum arquivo .39 foi lido com sucesso.")
43
44
```

Figura 4.2: 2ª Parte Código para importar e analisar estatisticamente os dados

geral, estavam abaixo do ponto de referência. Os valores negativos de aceleração são comuns em sistemas mecânicos e podem refletir desacelerações ou variações no movimento para trás em relação ao ponto de referência. Esses valores indicam momentos em que o rolamento não está a acelerar, mas pode estar a desacelerar ou a oscilar em torno do estado de equilíbrio.

O Rolamento 4 apresenta uma média mais negativa (-0.00296), sugerindo que pode ter operado sob condições ligeiramente mais adversas em comparação com os outros. O Rolamento 1 (que falhou no final) tem a segunda maior média negativa, o que pode estar relacionado ao processo de degradação que ocorreu ao longo do tempo.

O desvio padrão indica a variação das medições em relação à média. Um desvio padrão relativamente alto pode ser sinal de flutuações nas condições de operação dos rolamentos, sugerindo que, em certos momentos, as vibrações estavam muito acima ou abaixo da média.

O Rolamento 1 apresenta o maior desvio padrão (0.121), indicando uma maior variabilidade nas medições. Isso sugere que as condições de operação do Rolamento 1 foram as mais instáveis ao longo do tempo, o que é coerente com o fato de que foi o rolamento que falhou.

Em contrapartida, o Rolamento 4 apresenta o menor desvio padrão, indicando menor variabilidade, o que pode significar que operou nas condições mais estáveis.

O valor mínimo registrado fornece informações sobre os níveis extremos de vibração que o rolamento enfrentou.

O Rolamento 1 apresenta um valor mínimo muito mais baixo (-5.000), o que é uma indicação de eventos extremos ou anormais. Isto pode estar relacionado com o processo de falha da pista externa que ocorreu no final da experiência. Os outros rolamentos têm mínimos consideravelmente mais altos, sugerindo que não enfrentaram a mesma gravidade de eventos anómalos.

O primeiro quartil indica que 25% dos dados ficaram abaixo desse valor. Os valores do primeiro quartil são relativamente próximos entre os rolamentos, com pequenas variações. O Rolamento 4 tem um valor um pouco mais alto (-0.042), indicando que 25% das suas medições estão acima deste valor, o que sugere uma operação um pouco mais estável em comparação com os outros rolamentos.

O segundo quartil, ou mediana, representa o ponto médio dos dados, sugerindo que metade das medições está abaixo desse valor. A mediana é idêntica para todos os rolamentos (-0.002), indicando que o ponto médio das medições é o mesmo, o que sugere que, apesar das variações nas médias e desvios padrões, o comportamento central das medições foi semelhante.

O terceiro quartil indica que 75% dos dados estão abaixo desse valor. Os valores do

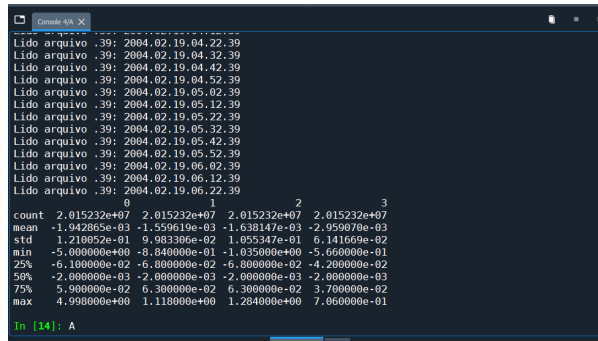


Figura 4.3: Resultados da Análise Estatística

terceiro quartil mostram que os Rolamentos 2 e 3 têm medições ligeiramente mais altas no topo dos dados. Já o Rolamento 4 tem o menor valor (0.037), o que sugere que suas medições raramente atingem níveis elevados de vibração ou pressão, indicando uma operação mais estável.

O valor máximo indica o nível mais alto da recolha dos dados.

O Rolamento 1 apresenta um valor máximo significativamente mais alto (4.998), o que indica picos extremos de vibração ou pressão, possivelmente ligados à falha da pista externa. Esse valor é muito superior aos máximos dos outros rolamentos, cujos valores permanecem dentro de um intervalo mais estável e controlado.

O Rolamento 4, em particular, tem o menor valor máximo (0.706), sugerindo que operou dentro de limites muito mais estáveis em comparação aos demais.

Estes parâmetros estatísticos não só resumem as medições que se recolheram, mas também oferecem insights sobre a performance e a saúde dos rolamentos ao longo da recolha dos dados.

Análise Estatística Comparativa Antes e Depois da Falha

Os dados estatísticos antes e depois da falha dos rolamentos estão representados na Tabela 4.2.

A análise comparativa entre os dados antes e depois da falha revela insights importantes sobre o comportamento dos rolamentos ao longo do tempo. A partir das tabelas de estatísticas descritivas, é possível observar diferenças claras no padrão de operação, principalmente no Rolamento 1 — o único que sofreu falha — em contraste com os restantes.

Os valores registados representam acelerações de vibração, com sinais positivos e negativos. Valores positivos indicam aceleração numa direcção do eixo de medição, enquanto os negativos indicam aceleração no sentido oposto. Em sistemas vibratórios como os rolamentos, essas oscilações são naturais. No entanto, amplitudes elevadas — tanto positivas como negativas — são indicativas de maior intensidade vibracional,

Deteção de falhas em rolamentos através da análise de vibração usando métodos de ...

que pode estar associada a desgaste ou falha.

Embora as médias de todos os rolamentos permaneçam negativas, o Rolamento 1 apresenta uma média mais negativa após o início da falha, sugerindo uma tendência para acelerações mais intensas no sentido negativo. Este comportamento pode refletir uma mudança estrutural no rolamento, que passou a vibrar com maior intensidade ou frequência irregular.

Mais relevante ainda é o aumento do desvio padrão no Rolamento 1: de 0.121 antes da falha para 0.134 após a falha. Este acréscimo indica que os dados se tornaram mais dispersos em torno da média, refletindo maior instabilidade e variabilidade nas medições. Este comportamento não é observado nos outros rolamentos, que mantêm desvios padrão praticamente constantes, reforçando a ideia de que o Rolamento 1 passou a operar em regime anormal.

Os valores mínimos do Rolamento 1 mantêm-se extremamente baixos mesmo após a falha, o que indica a ocorrência contínua de eventos vibratórios extremos em direção negativa. Estes eventos podem representar impactos mecânicos, folgas excessivas ou danos na pista externa — exatamente o tipo de comportamento que seria esperado após o início de uma falha.

Já os valores máximos também se mantêm altos, demonstrando que a vibração se intensificou em ambas as direções. A persistência desses valores elevados, tanto positivos quanto negativos, demonstra que a falha não só provocou um aumento da amplitude das vibrações, como manteve o sistema num estado de agitação mecânica crítica.

Os quartis e a mediana do Rolamento 1 mantêm-se relativamente estáveis, sugerindo que os valores centrais dos dados não se alteraram drasticamente. Isso significa que a maior parte dos dados ainda se concentra próxima ao centro da distribuição anterior — no entanto, é nas extremidades (picos) que a mudança é mais acentuada. A falha parece não ter alterado o “centro” da operação, mas ampliou consideravelmente os extremos e a variabilidade.

Enquanto os outros rolamentos — especialmente o Rolamento 4 — apresentam comportamento estável, com baixos desvios padrão e limites máximos e mínimos controlados, o Rolamento 1 destaca-se pela instabilidade crescente após a falha. A alteração significativa no desvio padrão e a manutenção de picos extremos em ambos os sentidos são marcas claras de degradação. Essa evolução está em perfeita coerência com o comportamento esperado de um componente em falência, onde a estrutura interna degradada já não consegue amortecer ou dissipar energia de forma eficaz.

O conjunto dos dados mostra uma clara deterioração no comportamento do Rolamento 1, refletida por maiores amplitudes, maior dispersão e persistência de picos extremos após a falha. Os valores negativos e positivos elevados indicam uma vibração intensa e irregular, compatível com falha física no rolamento. Os demais rolamentos mantêm um

```

import pandas as pd
import numpy as np
import os

# Função para carregar dados
def carregar_dados():
    pasta_dados = r"C:\Users\danie\OneDrive\Ambiente de Trabalho\TESE\python-teste\01\test'
    dados = []

    for arquivo in os.listdir(pasta_dados):
        if arquivo.endswith('.39'):
            caminho_arquivo = os.path.join(pasta_dados, arquivo)
            try:
                df_temp = pd.read_csv(caminho_arquivo, delimiter=';', header=None)
                dados.append(df_temp)
            except Exception as e:
                print(f'Erro ao carregar {arquivo}: {e}')

    df_final = pd.concat(dados, ignore_index=True)

    # Mostrar informações sobre o DataFrame
    print("Informações do DataFrame:")
    print(df_final.info()) # Informações do DataFrame
    print(f"Primeiras linhas dos dados carregados")
    print(df_final.head()) # Mostra as 5 primeiras linhas

    return df_final

# Calcular o índice da falha
def calcular_indice_falha(df, linear=0.05):
    diferencas = np.diff(df[0])
    indice_falha = np.argmax(diferencas > linear) + 1 # +1 para ajustar o índice
    return indice_falha

# Obter estatísticas
def obter_estatisticas(df, indice_falha):
    dados_antes_falha = df.iloc[:indice_falha] # Antes da falha
    dados_depois_falha = df.iloc[indice_falha:] # Depois da falha

    # Debug: exibir número de linhas e colunas
    print(f"Número de linhas antes da falha: {dados_antes_falha.shape[0]} (Colunas: {dados_antes_falha.shape[1]})")

```

Figura 4.4: Parte 1 do Código para a Análise Estatística Comparativa

```

print(f"Número de linhas depois da falha: {dados_depois_falha.shape[0]} (Colunas: {dados_depois_falha.shape[1]})")
# Filtrando para manter apenas as primeiras 4 colunas
dados_antes_falha = dados_antes_falha.iloc[:, :4] # Mantém apenas 4 colunas
dados_depois_falha = dados_depois_falha.iloc[:, :4] # Mantém apenas 4 colunas

estatisticas_antes = pd.DataFrame({
    'mean': np.mean(dados_antes_falha, axis=0),
    'std': np.std(dados_antes_falha, axis=0),
    'min': np.min(dados_antes_falha, axis=0),
    '25%': np.percentile(dados_antes_falha, 25, axis=0),
    '50%': np.median(dados_antes_falha, axis=0),
    '75%': np.percentile(dados_antes_falha, 75, axis=0),
    'max': np.max(dados_antes_falha, axis=0)
})

estatisticas_depois = pd.DataFrame({
    'mean': np.mean(dados_depois_falha, axis=0),
    'std': np.std(dados_depois_falha, axis=0),
    'min': np.min(dados_depois_falha, axis=0),
    '25%': np.percentile(dados_depois_falha, 25, axis=0),
    '50%': np.median(dados_depois_falha, axis=0),
    '75%': np.percentile(dados_depois_falha, 75, axis=0),
    'max': np.max(dados_depois_falha, axis=0)
})

return estatisticas_antes, estatisticas_depois

# Execução do código
df = carregar_dados() # Carregar os dados
indice_falha = calcular_indice_falha(df) # Calcular o índice de falha
estatisticas_antes, estatisticas_depois = obter_estatisticas(df, indice_falha) # Obter as estatísticas

# Imprimir resultados
print("Estatísticas Antes da Falha:")
print(estatisticas_antes)
print("Estatísticas Depois da Falha:")
print(estatisticas_depois)

```

Figura 4.5: Parte 2 do Código para a Análise Estatística Comparativa

perfil estável, o que evidencia que o comportamento anômalo é localizado e específico. Estes resultados sustentam a conclusão de que a análise estatística é eficaz para detetar sinais de falha precoce, especialmente quando se observa um aumento repentino da variabilidade e da amplitude dos sinais.

O código utilizado para gerar estes dados estatísticos antes e depois da falha está representado nas Figura 4.4 e 4.5.

Análise Gráfica

Com base nos gráficos individuais de vibração, conseguidos com o código ilustrado na Figura 4.10, após a aplicação da suavização LOWESS (*Locally Weighted Scatterplot Smoothing*) às séries temporais dos quatro rolamentos, é possível observar e comparar visualmente os comportamentos dinâmicos ao longo do tempo.

Para tornar o processamento computacional viável, especialmente devido ao elevado volume de dados do conjunto analisado, aplicou-se uma subamostragem à série temporal original. Esse procedimento consistiu em selecionar uma amostra a cada 100 pontos da série, o que reduziu significativamente o número de observações. Apesar dessa redução, a estrutura global do sinal – nomeadamente as tendências e padrões principais

de vibração – foi preservada, garantindo uma visualização eficaz da evolução temporal dos dados após a aplicação do filtro LOWESS.

No Rolamento 1, cujos respectivos dados estão ilustrados na Figura 4.6, destaca-se um crescimento contínuo na amplitude da vibração ao longo do tempo, com uma acentuação clara nos momentos finais da série. Este padrão sugere um processo de degradação progressiva, em que a vibração vai-se intensificando, o que pode ser interpretado como um possível indício do início de falha. A suavização permitiu evidenciar essa tendência, removendo oscilações locais e revelando a elevação consistente do sinal.

O Rolamento 2, Figura 4.7, por outro lado, apresenta uma série de vibração com maior irregularidade ao longo de toda a série, mas sem que se note uma tendência de crescimento sustentado. As flutuações observadas parecem estar distribuídas de forma mais aleatória, o que sugere um comportamento mais estável e sem sinais evidentes de deterioração acentuada.

No caso do Rolamento 3, na Figura 4.8, observa-se também um padrão flutuante, com variações de baixa magnitude, mas sem uma tendência visivelmente crescente ou decrescente. A vibração suavizada oscila em torno de um valor relativamente constante, o que é indicativo de operação sob condições estáveis.

Já o Rolamento 4, como podemos observar na Figura 4.9, revela um comportamento com ligeira variação ao longo da série, com algumas oscilações mais amplas distribuídas em pontos isolados, particularmente na parte final. No entanto, estas oscilações não seguem uma tendência crescente clara. A vibração parece manter-se dentro de uma faixa aceitável, sem alterações bruscas que evidenciem degradação progressiva.

De forma geral, a análise gráfica sugere que apenas o Rolamento 1 apresenta sinais evidentes de deterioração ao longo do tempo. A aplicação do método LOWESS mostrou-se adequada para destacar padrões de tendência nos sinais de vibração, eliminando flutuações de alta frequência que poderiam mascarar comportamentos relevantes. Esta abordagem gráfica constitui uma etapa essencial de exploração inicial dos dados, permitindo observar de forma intuitiva a evolução das condições operacionais dos rolamentos ao longo do tempo.

Análise de Estacionaridade

A análise de estacionaridade foi conduzida com base na amplitude absoluta do sinal de vibração do Rolamento 1, medida ao longo do tempo. O uso do valor absoluto da amplitude visa representar a intensidade da vibração de forma unificada, independentemente da direção do movimento. Esta abordagem é comum na análise de falhas mecânicas, uma vez que os defeitos introduzem aumento na energia vibracional e não necessariamente alterações de fase ou direção [17]. O valor absoluto permite realçar esses aumentos energéticos de forma mais evidente, funcionando como uma aproxi-




Figura 4.6: Gráfico Vibração do Rolamento 1




Figura 4.7: Gráfico Vibração do Rolamento 2




Figura 4.8: Gráfico Vibração do Rolamento 3

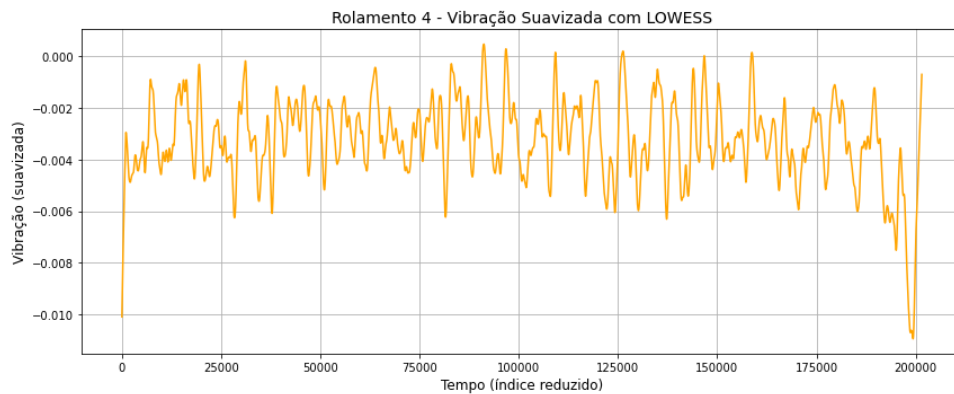


Figura 4.9: Gráfico Vibração do Rolamento 4

```
temp.py X
1 import os
2 import pandas as pd
3 import matplotlib.pyplot as plt
4 from statsmodels.nonparametric.smoothers_lowess import lowess
5
6 # Caminho para os arquivos
7 diretorio = r'C:\Users\danie\OneDrive\Ambiente de Trabalho\TESE\python-teste01\2nd_test'
8
9 # Carregar e concatenar os dados
10 lista_dataframes = []
11 for arquivo in os.listdir(diretorio):
12     if arquivo.endswith('.39'):
13         caminho_completo = os.path.join(diretorio, arquivo)
14         df_temp = pd.read_csv(caminho_completo, delimiter='|t', header=None)
15         lista_dataframes.append(df_temp)
16
17 df = pd.concat(lista_dataframes, ignore_index=True)
18
19 # Subamostragem para reduzir carga computacional
20 passo = 100
21 df_reduzido = df.iloc[:, :].reset_index(drop=True)
22
23 # Informações dos rolamentos
24 cores = ['red', 'blue', 'green', 'orange']
25 labels = ['Rolamento 1', 'Rolamento 2', 'Rolamento 3', 'Rolamento 4']
26
27 # Geração dos gráficos separados
28 for i in range(4):
29     plt.figure(figsize=(12, 5))
30     y = df_reduzido[i].values
31     x = df_reduzido.index.values
32     y_smooth = lowess(y, x, frac=0.01, return_sorted=False)
33
34     plt.plot(x, y_smooth, color=cores[i], linewidth=1.5)
35     plt.title(f'Rolamento {i+1} - Vibração Suavizada com LOWESS', fontsize=14)
36     plt.xlabel('Tempo (índice reduzido)', fontsize=12)
37     plt.ylabel('Vibração (suavizada)', fontsize=12)
38     plt.grid(True)
39     plt.tight_layout()
40     plt.show()
41
```

Figura 4.10: Código para os Gráficos de Vibração dos 4 Rolamentos

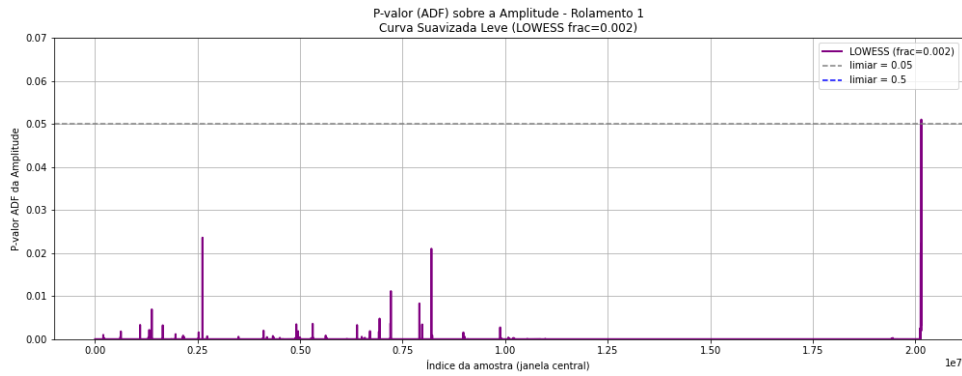


Figura 4.11: Gráfico do p-valor ao longo da série temporal

mação ao envelope do sinal.

Para investigar a estacionaridade local da série, utilizou-se o teste de *Dickey-Fuller Aumentado* (ADF), que testa a hipótese nula de que a série possui raiz unitária, ou seja, não é estacionária. A aplicação do teste foi feita sobre janelas deslizantes de 1000 amostras, sem sobreposição. Essa segmentação permite observar como a estacionaridade do sinal evolui ao longo do tempo, o que é particularmente relevante em sistemas degradantes, como rolamentos em processo de falha [18].

Como a série de p-valores obtidos pode ser ruidosa, foi aplicada a técnica de suavização LOWESS (*Locally Weighted Scatterplot Smoothing*), que ajusta localmente regressões ponderadas, revelando tendências de forma mais clara sem supor um modelo paramétrico global [16]. Foram utilizados dois níveis de suavização: um leve ($\text{frac} = 0.002$) e outro mais forte ($\text{frac} = 0.01$), para observar tanto flutuações locais como o comportamento geral da série.

O gráfico resultante, Figura 4.11, obtido através do código na Figura 4.12 mostra que a maior parte do sinal de amplitude permanece estacionária (com p-valores inferiores a 0.05), o que é esperado para componentes operando normalmente. No entanto, observa-se um aumento significativo do p-valor na parte final da série, sugerindo perda de estacionaridade, que coincide com o período previamente identificado como o início da falha. Este comportamento está alinhado com estudos como os de Qiu *et al.* [19], que demonstram a utilidade de métricas estatísticas para acompanhar a degradação de rolamentos.

Assim, esta abordagem baseada na amplitude absoluta, janelas móveis e teste ADF revela-se eficaz na identificação do início de alterações significativas no comportamento vibracional do sistema, sendo uma ferramenta promissora para a estimação da RUL de rolamentos.

Para complementar esta análise, a Figura 4.13 obtida através do código ilustrado na Figura 4.14, apresenta uma visualização combinada, onde a evolução do p-valor do teste ADF é sobreposta à curva suavizada da amplitude média do sinal de vibração. Esta

```
temp.py* X
import os
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from statsmodels.tsa.stattools import adfuller
from statsmodels.nonparametric.smoothers_lowess import lowess

# Caminho para os arquivos .39
diretorio = r'C:\Users\daniel\OneDrive\Ambiente de Trabalho\TESE\python-teste01\2nd_test'

# Leitura dos arquivos
lista_dataframes = []
for arquivo in os.listdir(diretorio):
    if arquivo.endswith('.39'):
        caminho_completo = os.path.join(diretorio, arquivo)
        df_temp = pd.read_csv(caminho_completo, delimiter='t', header=None)
        lista_dataframes.append(df_temp)

# Concatenar todos os DataFrames
df = pd.concat(lista_dataframes, ignore_index=True)

# Calcular a amplitude de vibração do Rolamento 1 (coluna 0)
amplitude = df[0].abs()

# Parâmetros da janela
tamanho_janela = 1000
passo = 1000
pvalores = []
indices = []

# Cálculo do p-valor por janela
for i in range(0, len(amplitude) - tamanho_janela, passo):
    janela = amplitude.iloc[i:i + tamanho_janela]
    try:
        p_val = adfuller(janela)[1]
    except:
        p_val = np.nan
    pvalores.append(p_val)
    indices.append(i + tamanho_janela // 2)

# Suavizações com LOWESS
lowess_suave = lowess(pvalores, indices, frac=0.002, return_sorted=False)
lowess_forte = lowess(pvalores, indices, frac=0.01, return_sorted=False)

# Gráfico 1 - Suavização leve
plt.figure(figsize=(14, 10))

plt.subplot(2, 1, 1)
plt.plot(indices, lowess_suave, color='purple', linewidth=2, label='LOWESS (frac=0.002)')
plt.axhline(0.05, color='gray', linestyle='--', label='limiar = 0.05')
plt.axhline(0.5, color='blue', linestyle='--', label='limiar = 0.5')
plt.ylim(0, 0.07)
plt.title('P-valor (ADF) sobre a Amplitude - Rolamento 1\nCurva Suavizada Leve (LOWESS frac=0.002)')
plt.xlabel('Índice da amostra (janela central)')
plt.ylabel('P-valor ADF da Amplitude')
plt.legend()
plt.grid(True)

plt.tight_layout()
plt.show()
```

Figura 4.12: Código do p-valor ao longo da série temporal




Figura 4.13: Gráfico do p-valor sobreposto com amplitude de vibração

abordagem permite observar, de forma mais integrada, como a perda de estacionariedade está correlacionada com o aumento progressivo da vibração.

Nota-se que a amplitude média, representada pela linha cinzenta, mantém-se relativamente estável na maior parte da série, o que é indicativo de operação normal. Contudo, à medida que nos aproximamos do final da série, observa-se um crescimento acentuado na amplitude, acompanhado simultaneamente de um aumento nos p-valores (curva roxa), que ultrapassam o limiar de significância de 0.05 (linha vermelha tracejada). Esta correspondência entre aumento de amplitude e perda de estacionariedade reforça a interpretação de que o sistema está a entrar num regime de falha.

A sobreposição dos sinais suavizados demonstra a vantagem de se combinar métricas estatísticas (como o p-valor) com métricas físicas (como a amplitude) para monitorização da condição do rolamento. Esta correlação direta entre intensidade vibracional e comportamento não-estacionário constitui um indício robusto da degradação, validando a utilização de ambas as abordagens em conjunto como suporte à tomada de decisão em manutenção preditiva.

4.4.2 Modelo para Detecção de Falhas em Rolamentos

Avaliação de um Modelo de Classificação Baseado no P-valor do Teste ADF

Neste subcapítulo, explora-se a viabilidade de utilizar o p-valor do teste de raiz unitária de ADF como variável preditora para detetar falhas em rolamentos. O objetivo é verificar se esta métrica estatística, frequentemente usada para avaliar a estacionariedade de séries temporais, pode também refletir alterações associadas ao início e progressão de uma falha mecânica.

A abordagem experimental baseou-se em dois conjuntos de dados reais recolhidos em bancada de ensaio, referentes ao dataset analisado no Capítulo 4.4. O conjunto 2 corresponde ao rolamento 1 com falha conhecida na pista externa, cujo início visualmente identificado ocorre por volta do índice 19800. O conjunto 3, também referente ao rolamento 1, foi considerado como estado "normal", assumindo-se que não existem falhas

```

temp.py x
1 import os
2 import pandas as pd
3 import numpy as np
4 import matplotlib.pyplot as plt
5 from statsmodels.tsa.stattools import adfuller
6 from statsmodels.nonparametric.smoothers_lowess import lowess
7
8 # Caminho para os arquivos .39
9 diretorio = r'C:\Users\danie\OneDrive\Ambiente de Trabalho\TESE\python-teste01\2nd_test'
10
11 # Leitura dos arquivos
12 lista_dataframes = []
13 for arquivo in os.listdir(diretorio):
14     if arquivo.endswith('.39'):
15         caminho_completo = os.path.join(diretorio, arquivo)
16         df_temp = pd.read_csv(caminho_completo, delimiter='t', header=None)
17         lista_dataframes.append(df_temp)
18
19 # Concatenar todos os DataFrames
20 df = pd.concat(lista_dataframes, ignore_index=True)
21
22 # Calcular a amplitude de vibração do Rolamento 1 (coluna 0)
23 amplitude = df[0].abs()
24
25 # Parâmetros da janela
26 tamanho_janela = 1000
27 passo = 200 # mais denso que antes
28 pvalores = []
29 amplitudes_janela = []
30 indices = []
31
32 # Cálculo do p-valor e da média da janela
33 for i in range(0, len(amplitude) - tamanho_janela, passo):
34     janela = amplitude.iloc[i:i + tamanho_janela]
35     media_amp = janela.mean()
36     try:
37         p_val = adfuller(janela)[1]
38     except:
39         p_val = np.nan
40     amplitudes_janela.append(media_amp)
41     pvalores.append(p_val)
42     indices.append(i + tamanho_janela // 2)
43
44 # Suavização com LOWESS
45 lowess_amp = lowess(amplitudes_janela, indices, frac=0.01, return_sorted=False)
46 lowess_pval = lowess(pvalores, indices, frac=0.002, return_sorted=False)
47
48 # Gráfico combinado
49 fig, ax1 = plt.subplots(figsize=(16, 6))
50
51 # Eixo 1 - Amplitude
52 ax1.plot(indices, lowess_amp, color='gray', label='Amplitude média (LOWESS)', linewidth=2)
53 ax1.set_ylabel('Amplitude média da janela', color='gray')
54 ax1.tick_params(axis='y', labelcolor='gray')
55
56 # Eixo 2 - P-valor
57 ax2 = ax1.twinx()
58 ax2.plot(indices, lowess_pval, color='purple', label='p-valor LOWESS (frac=0.01)', linewidth=1.5)
59 ax2.axhline(0.05, color='red', linestyle='--', label='limiar = 0.05')
60 ax2.set_ylabel('P-valor ADF', color='purple')
61 ax2.tick_params(axis='y', labelcolor='purple')
62 ax2.set_ylim(0, 0.07)
63
64 # Legenda e título
65 plt.title('Sinal de Vibração (Amplitude) vs. P-valor (ADF)', fontsize=14)
66 fig.legend(loc="upper right", bbox_to_anchor=(1, 1), bbox_transform=ax1.transAxes)
67 plt.grid(True)
68 plt.tight_layout()
69 plt.show()
70
71
72

```

Figura 4.14: Código para o gráfico do p-valor sobreposto com amplitude de vibração

presentes nesse período.

Para a preparação dos dados, foram extraídas janelas deslizantes de 1000 amostras com passo de 200, e sobre cada janela foi aplicado o teste ADF. O p-valor obtido em cada janela foi armazenado, juntamente com a média da amplitude do sinal nessa mesma janela. As janelas do conjunto 2 com índice superior ou igual a 19800 foram rotuladas como classe 1 (falha), enquanto as restantes, incluindo todas as do conjunto 3, foram rotuladas como classe 0 (normal).

O dataset resultante revelou um forte desbalanceamento de classes, com um número significativamente inferior de amostras com falha. Para mitigar este problema, foi aplicado o método de oversampling SMOTE (*Synthetic Minority Over-sampling Technique*), de forma a equilibrar o número de exemplos de cada classe antes da divisão em treino e teste.

A seguir, os dados foram divididos em conjuntos de treino (70%) e teste (30%) com estratificação, e normalizados com a técnica *MinMaxScaler*, utilizando apenas o conjunto de treino para o ajuste do escalonador (*fitfit*). Em seguida, foi construído um modelo de rede neuronal simples com três camadas densas (8-4-1 neurónios), função de ativação ReLU nas camadas ocultas e sigmoide na saída, treinado durante 30 épocas.

Este procedimento está ilustrado num diagrama, na Figura 4.15.

Apesar do equilíbrio obtido com SMOTE, os resultados revelaram um desempenho insatisfatório. O modelo não foi capaz de aprender a distinguir eficazmente entre os estados normal e com falha, como evidenciado pela matriz de confusão e pelas métricas de classificação, ilustradas nas Figuras 4.17 e 4.16, resultados do código representado nas Figuras 4.18 e 4.19.

A matriz de confusão revela um padrão de classificação enviesada: dos 28635 exemplos reais da classe 0 (normal), apenas 187 foram corretamente classificados, enquanto os restantes 28448 foram incorretamente atribuídos à classe 1 (falha). Por outro lado, dos 28634 exemplos com falha, 28492 foram corretamente classificados, e apenas 142 foram incorretamente rotulados como normais. Este desequilíbrio nas previsões ilustra a forte tendência do modelo para classificar a maioria dos exemplos como falha, independentemente da sua verdadeira classe.

Para interpretar estes resultados, é relevante analisar as métricas de desempenho:

- A precisão (*precision*) mede a proporção de previsões corretas entre todos os exemplos classificados como pertencentes a uma classe.
- A revocação (*recall*) indica a capacidade do modelo em identificar corretamente os exemplos daquela classe.
- O f1-score é a média harmónica entre precisão e revocação, e reflete o equilíbrio entre ambas.

No caso da classe 0 (normal), o modelo apresentou uma precisão de 0.57, mas um *recall* de apenas 0.01, o que significa que praticamente todos os exemplos normais foram classificados erroneamente como falha. Esta discrepância resultou num *f1-score* de apenas 0.01. Em contraste, a classe 1 (falha) teve um *recall* de 1.00 (todos os exemplos com falha foram corretamente identificados), mas com uma precisão de apenas 0.50, indicando que metade das previsões de falha eram, na verdade, dados normais.

Desempenho de um Modelo Baseado Exclusivamente em Métricas de Amplitude

Após a análise do modelo baseado exclusivamente no p-valor do teste ADF, foi testada uma nova abordagem recorrendo apenas à amplitude média do sinal de vibração como variável de entrada, obtido através do código representado nas Figuras 4.23 e 4.24. Esta escolha justifica-se pelas observações feitas nas análises gráficas e na evolução temporal dos dados, onde se verificou que a amplitude tende a aumentar com a degradação do rolamento, refletindo alterações energéticas associadas ao aparecimento e propagação de falhas.

Com o objetivo de contornar o desequilíbrio de classes presente no conjunto de dados, foi adotada uma abordagem de amostragem real, em que se selecionou o mesmo número de amostras com e sem falha. A classe de falha foi representada pelas janelas extraídas a partir do momento identificado como início da falha (após o índice 19800) no conjunto 2, enquanto a classe normal foi composta por um subconjunto de igual tamanho proveniente do conjunto 3, contendo apenas funcionamento normal. Desta forma, evitou-se a necessidade de aplicação de técnicas de *oversampling* sintético como o SMOTE, permitindo manter a integridade dos dados reais.

O modelo de rede neuronal utilizado manteve-se inalterado na sua estrutura: uma rede simples com duas camadas ocultas (com 8 e 4 neurónios, respetivamente) e uma camada de saída com ativação sigmoide. A base de treino foi normalizada com *MinMaxScaler*, ajustado apenas com os dados de treino.

Este procedimento está ilustrado num diagrama, na Figura 4.20.

Os resultados obtidos foram os seguintes, ilustrados também na Figura 4.21:

- *Accuracy*: 67
- *Precision* (classe 0): 0.61
- *Recall* (classe 0): 0.98
- *Precision* (classe 1): 0.95
- *Recall* (classe 1): 0.36

A matriz de confusão, Figura 4.22, revela que o modelo foi altamente eficaz na identificação dos exemplos da classe normal (291 de 296 corretamente classificados), mas teve mais dificuldades na deteção das amostras com falha (apenas 106 de 295). O elevado

número de falsos negativos compromete a capacidade de deteção precoce de falhas, o que é particularmente crítico em contextos industriais.

Combinação de P-valor e Amplitude na Otimização do Modelo de Classificação

Dado o fraco desempenho observado no modelo anterior, baseado unicamente no p-valor do teste ADF, foi considerada a possibilidade de enriquecer o conjunto de atributos com uma métrica adicional. A escolha recaiu sobre a amplitude média do sinal de vibração em cada janela, uma vez que esta pode refletir variações energéticas no sinal associadas à degradação do rolamento, como se observou nas análises exploratórias.

O mesmo procedimento de pré-processamento foi mantido: o sinal foi dividido em janelas deslizantes de 1000 amostras com um passo de 200, sendo calculada a média da amplitude absoluta para cada janela. As amostras foram rotuladas como falha ou normal com base no índice `indice_falha = 19800`, e foi feita uma amostragem equilibrada real, utilizando o mesmo número de exemplos normais e com falha.

Na etapa de preparação, as duas *features* consideradas foram: o p-valor do teste de estacionaridade ADF e a amplitude média da janela. Os dados foram divididos em treino e teste com a função `train_test_split`, preservando a proporção entre as classes. Para garantir uma normalização adequada, o `MinMaxScaler` foi ajustado apenas sobre o conjunto de treino (`fit_transform`) e depois aplicado ao conjunto de teste (`transform`), evitando fuga de informação.

O modelo utilizado manteve a arquitetura anterior: uma rede neuronal simples com duas camadas escondidas (8 e 4 unidades, respetivamente) com ativação ReLU, e uma camada de saída com ativação sigmoide para classificação binária.

Este procedimento está ilustrado num diagrama, na Figura 4.25.

Os resultados da avaliação do modelo, ilustrados na matriz de confusão, na Figura 4.27 e no relatório de classificação, Figura 4.26, revelaram uma melhoria significativa face à abordagem anterior. A matriz de confusão demonstra que o modelo foi capaz de identificar corretamente 281 amostras normais (classe 0) e 135 amostras com falha (classe 1), num total de 591 amostras de teste. A classe normal apresentou uma precisão de 0.64 e um *recall* de 0.95, enquanto a classe com falha obteve uma precisão de 0.90 e um *recall* de 0.46. O valor de *accuracy* foi de 70%, com uma média ponderada de f1-score de 0.68.

Tabela 4.1: Datasets

	Duração da recolha dos dados	Nº de variáveis	Falhas	Nº de Exemplos
1º Dataset	1 mês cada um dos três conjuntos de dados	4	1º conjunto: Defeito na pista interna do rolamento 3 e defeito no elemento rolante do rolamento 4; 2º conjunto: Falha na pista externa do rolamento 1; 3º conjunto: Falha na pista externa do rolamento 3	4 falhas diferentes
2º Dataset	128 horas de operação contínua	Vibração no eixo x Vibração no eixo y Temperatura do rolamento Temperatura atmosférica	falhas nas pistas interna e externa	1 falha no rolamento que foi observado
3º Dataset	162 minutos	Sinal do conta-rotações Vibração no eixo axial no rolamento underhang Vibração no eixo radial no rolamento underhang Vibração no eixo tangencial no rolamento underhang Vibração no eixo axial no rolamento overhang Vibração no eixo radial no rolamento overhang Vibração no eixo tangencial no rolamento overhang Sinal do microfone	falha na gaiola, na pista externa, na esfera	Posição underhang: 558 sequências Posição overhang: 513 sequências
4º Dataset	286 horas	Valor efetivo da velocidade de vibração Valor efetivo da aceleração Valor máximo da aceleração Fator de Crista ³⁹ Temperatura	rolamento não selado e sem quantidade de massa lubrificante rolamento não selado com excesso de massa lubrificante	2636 registos em que o rolamento não estava selado e estava sem quantidade de massa lubrificante 2637 registos em que o rolamento não estava selado e estava com excesso de massa lubrificante

Tabela 4.2: Estatísticas Antes e Depois da Falha

Antes da Falha							
Rolamento	mean	std	min	25%	50%	75%	max
1	-0.0584	0.054393	-0.129	-0.090	-0.081	-0.012	0.020
2	-0.2600	0.038215	-0.325	-0.269	-0.254	-0.244	-0.208
3	0.0106	0.080154	-0.105	-0.010	0.010	0.012	0.146
4	-0.0122	0.036869	-0.078	-0.027	0.010	0.012	0.022
Depois da Falha							
Rolamento	mean	std	min	25%	50%	75%	max
1	-0.117912	0.099786	-0.869	-0.181	-0.117	-0.054	0.454
2	-0.116352	0.092857	-0.835	-0.176	-0.117	-0.056	0.547
3	-0.117404	0.092411	-0.579	-0.178	-0.117	-0.054	0.237
4	-0.117803	0.076570	-0.652	-0.168	-0.117	-0.068	0.281

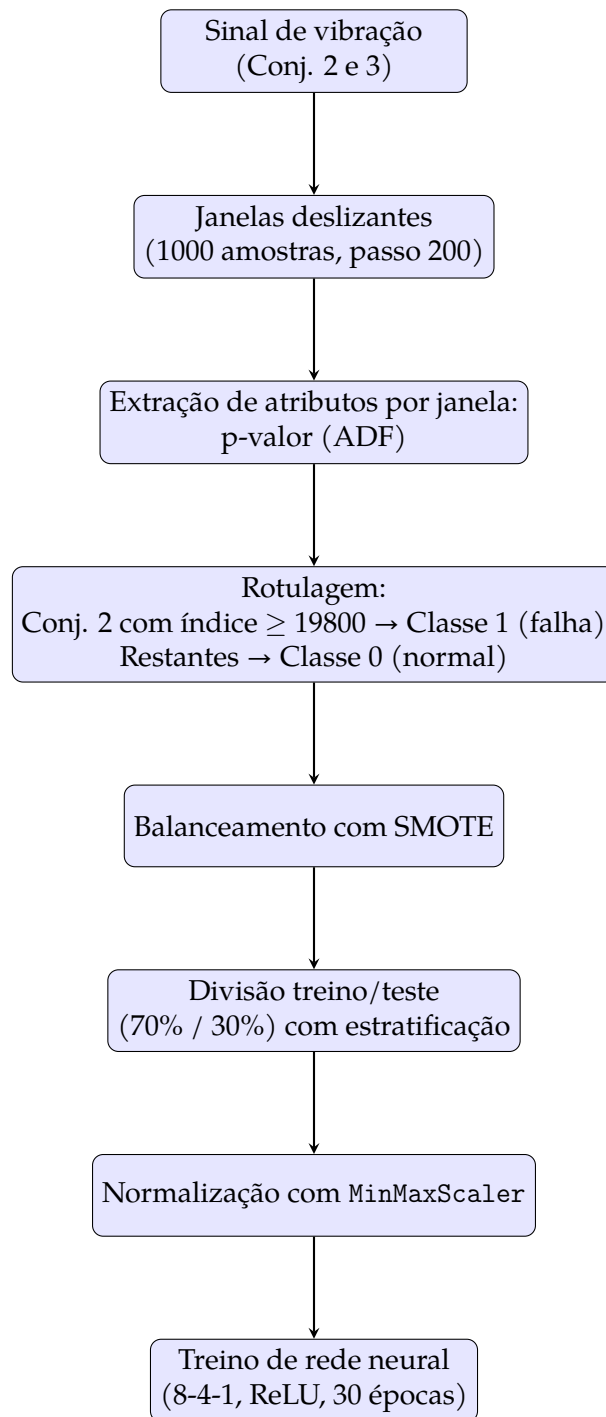


Figura 4.15: Fluxo de preparação, extração de atributos, balanceamento e treino do modelo com base no p-valor.

```

=== Relatório de Classificação ===
              precision    recall  f1-score   support

     0       0.57         0.01         0.01    28635
     1       0.50         1.00         0.67    28634

 accuracy              0.50    57269
 macro avg              0.53    57269
 weighted avg           0.53    57269
    
```

Figura 4.16: Matriz de Resultados do Modelo de Classificação Baseado no P-valor do Teste ADF




Figura 4.17: Matriz de Confusão do Modelo de Classificação Baseado no P-valor do Teste ADF

```

temp.py x
1 import os
2 import pandas as pd
3 import numpy as np
4 from statsmodels.tsa.stattools import adfuller
5 from sklearn.model_selection import train_test_split
6 from sklearn.preprocessing import MinMaxScaler
7 from sklearn.metrics import classification_report, confusion_matrix
8 from tensorflow.keras.models import Sequential
9 from tensorflow.keras.layers import Dense
10 from imblearn.over_sampling import SMOTE
11 import matplotlib.pyplot as plt
12 import seaborn as sns
13
14 # == Caminhos ==
15 caminho_falha = r'C:\Users\daniel\OneDrive\Ambiente de Trabalho\TESE\python-teste0112nd_test'
16 caminho_normal = r'C:\Users\daniel\OneDrive\Ambiente de Trabalho\TESE\python-teste0113rd_test'
17 extensoes_validas = ['.17', '.20', '.46', '.53', '.55', '.57']
18 tamanho_janela = 1000
19 passo = 200
20 indice_falha = 19800
21
22 # == Função ==
23 def processar_dados(diretorio, rotulo, considerar_falha=False):
24     pvalores, indices, amplitudes = [], [], []
25     for arquivo in sorted(os.listdir(diretorio)):
26         if arquivo.endswith('.39') or any(arquivo.endswith(ext) for ext in extensoes_validas):
27             caminho = os.path.join(diretorio, arquivo)
28             df = pd.read_csv(caminho, delimiter='t', header=None)
29             sinal = df[0].abs()
30             for i in range(0, len(sinal) - tamanho_janela, passo):
31                 janela = sinal.iloc[i:i + tamanho_janela]
32                 try:
33                     p_val = adfuller(janela)[1]
34                     media_amp = janela.mean()
35                 except:
36                     continue
37                 pvalores.append(p_val)
38                 indices.append(i + tamanho_janela // 2)
39                 amplitudes.append(media_amp)
40     df_resultado = pd.DataFrame({
41         'Indice': indices,
42         'Amplitude media': amplitudes,
43         'P_valor': pvalores,
44         'Label': rotulo
45     })
46     if considerar_falha:
47         df_resultado['Label'] = df_resultado['Indice'].apply(lambda x: 1 if x >= indice_falha else 0)
48     return df_resultado
49
50 # == Processamento ==
51 df_falha = processar_dados(caminho_falha, 1, considerar_falha=True)
52 df_normal = processar_dados(caminho_normal, 0)
53 df_total = pd.concat([df_falha, df_normal, ignore_index=True).dropna()
54
55 # == Preparar ==
56 X = df_total[['P_valor']].values
57 y = df_total[['Label']].values
58 X = MinMaxScaler().fit_transform(X)
59
60 # == SMOTE para balanceamento ==
61 X_res, y_res = SMOTE(random_state=42).fit_resample(X, y)
62
63 # == Dividir ==
64 X_train, X_test, y_train, y_test = train_test_split(X_res, y_res, test_size=0.3, stratify=y_res, random_state=42)
65
66 # == Modelo ==
67 model = Sequential([
68     Dense(8, activation='relu', input_shape=(1,)),
69     Dense(4, activation='relu'),
70     Dense(1, activation='sigmoid')
71 ])
72 model.compile(optimizer='adam', loss='binary_crossentropy', metrics=['accuracy'])
73 model.fit(X_train, y_train, epochs=30, batch_size=32, validation_data=(X_test, y_test))
74
75 # == Avaliar ==
76 y_pred = (model.predict(X_test) > 0.5).astype(int)
77 print("\n== Relatório de Classificação ==")
78 print(classification_report(y_test, y_pred))
79

```

Figura 4.18: Parte 1 do Código do Modelo de Classificação Baseado no P-valor do Teste ADF

```

# == Modelo ==
model = Sequential([
    Dense(8, activation='relu', input_shape=(1,)),
    Dense(4, activation='relu'),
    Dense(1, activation='sigmoid')
])
model.compile(optimizer='adam', loss='binary_crossentropy', metrics=['accuracy'])
model.fit(X_train, y_train, epochs=30, batch_size=32, validation_data=(X_test, y_test))

# == Avaliar ==
y_pred = (model.predict(X_test) > 0.5).astype(int)
print("\n== Relatório de Classificação ==")
print(classification_report(y_test, y_pred))

# == Matriz de Confusão ==
cm = confusion_matrix(y_test, y_pred)
sns.heatmap(cm, annot=True, fmt='d', cmap='Blues', xticklabels=['Normal', 'Falha'], yticklabels=['Normal', 'Falha'])
plt.xlabel('Previsto')
plt.ylabel('Real')
plt.title('Matriz de Confusão - Modelo com SMOTE (Conj. 2 e 3, Rol. 1)')
plt.tight_layout()
plt.show()

```

Figura 4.19: Parte 2 do Código do Modelo de Classificação Baseado no P-valor do Teste ADF

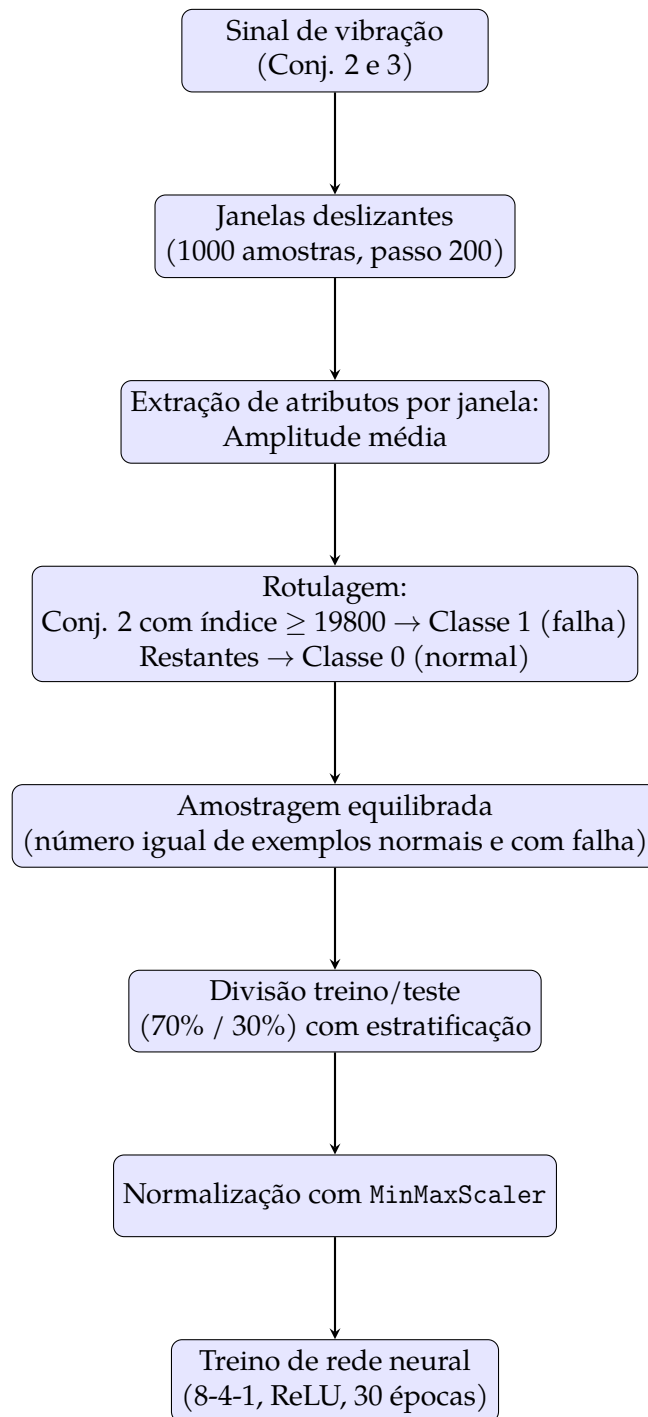


Figura 4.20: Fluxo de preparação , extração de atributos e treino do modelo com base na amplitude média.

```
=== Relatório de Classificação ===
              precision    recall  f1-score   support

     0         0.61         0.98         0.75         296
     1         0.95         0.36         0.52         295

 accuracy          0.67         0.67         0.67         591
 macro avg          0.78         0.67         0.64         591
 weighted avg       0.78         0.67         0.64         591
```

Figura 4.21: Matriz de Resultados do Modelo de Classificação Baseado Exclusivamente em Métricas de Amplitude




Figura 4.22: Matriz de Confusão do Modelo de Classificação Baseado Exclusivamente em Métricas de Amplitude

```

temp.py X
1  import os
2  import pandas as pd
3  import numpy as np
4  from statsmodels.tsa.stattools import adfuller
5  from sklearn.model_selection import train_test_split
6  from sklearn.preprocessing import MinMaxScaler
7  from sklearn.metrics import classification_report, confusion_matrix
8  from tensorflow.keras.models import Sequential
9  from tensorflow.keras.layers import Dense
10 import matplotlib.pyplot as plt
11 import seaborn as sns
12
13 # === Caminhos ===
14 caminho_falha = r'C:\Users\danie\OneDrive\Ambiente de Trabalho\TESE\python-teste01\2nd_test'
15 caminho_normal = r'C:\Users\danie\OneDrive\Ambiente de Trabalho\TESE\python-teste01\3rd_test'
16 extensoes_validas = ['.17', '.20', '.46', '.53', '.55', '.57']
17 tamanho_janela = 1000
18 passo = 200
19 indice_falha = 19800
20
21 # === Função para processar os dados ===
22 def processar_dados(diretorio, rotulo, considerar_falha=False):
23     pvalores, indices, amplitudes = [], [], []
24     for arquivo in sorted(os.listdir(diretorio)):
25         if arquivo.endswith('.39') or any(arquivo.endswith(ext) for ext in extensoes_validas):
26             caminho = os.path.join(diretorio, arquivo)
27             df = pd.read_csv(caminho, delimiter='|', header=None)
28             sinal = df[0].abs()
29             for i in range(0, len(sinal) - tamanho_janela, passo):
30                 janela = sinal.iloc[i:i + tamanho_janela]
31                 try:
32                     _ = adfuller(janela) # apenas para manter consistência
33                     media_amp = janela.mean()
34                     amplitudes.append(media_amp)
35                     indices.append(i + tamanho_janela // 2)
36                 except:
37                     continue
38             df_resultado = pd.DataFrame({
39                 'Indice': indices,
40                 'Amplitude_media': amplitudes,
41                 'Label': rotulo
42             })
43             if considerar_falha:
44                 df_resultado['Label'] = df_resultado['Indice'].apply(lambda x: 1 if x >= indice_falha else 0)
45             return df_resultado
46
47 # === Processar os dados ===
48 df_falha = processar_dados(caminho_falha, 1, considerar_falha=True)
49 df_normal = processar_dados(caminho_normal, 0, considerar_falha=False)
50
51 # === Amostragem equilibrada ===
52 n_falhas = len(df_falha[df_falha['Label'] == 1])
53 df_normal_eq = df_normal.sample(n=n_falhas, random_state=42)
54 df_falha_eq = df_falha[df_falha['Label'] == 1]
55 df_total = pd.concat([df_falha_eq, df_normal_eq, ignore_index=True]).dropna()
56

```

Figura 4.23: Parte 1 do Código do Modelo de Classificação Baseado Exclusivamente em Métricas de Amplitude

```

# === Separar X e y (apenas amplitude) ===
X = df_total[['Amplitude_media']].values
y = df_total['Label'].values

# === Dividir e normalizar ===
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3, stratify=y, random_state=42)
scaler = MinMaxScaler()
X_train = scaler.fit_transform(X_train)
X_test = scaler.transform(X_test)

# === Modelo ===
model = Sequential([
    Dense(8, activation='relu', input_shape=(1,)),
    Dense(4, activation='relu'),
    Dense(1, activation='sigmoid')
])
model.compile(optimizer='adam', loss='binary_crossentropy', metrics=['accuracy'])
model.fit(X_train, y_train, epochs=30, batch_size=32, validation_data=(X_test, y_test))

# === Avaliação ===
y_pred = (model.predict(X_test) > 0.5).astype(int)
print("\n=== Relatório de Classificação ===")
print(classification_report(y_test, y_pred))

# === Matriz de Confusão ===
cm = confusion_matrix(y_test, y_pred)
sns.heatmap(cm, annot=True, fmt='d', cmap='Blues', xticklabels=['Normal', 'Falha'], yticklabels=['Normal', 'Falha'])
plt.xlabel('Previsto')
plt.ylabel('Real')
plt.title('Matriz de Confusão - Modelo com Amplitude')
plt.tight_layout()
plt.show()

```

Figura 4.24: Parte 2 do Código do Modelo de Classificação Baseado Exclusivamente em Métricas de Amplitude

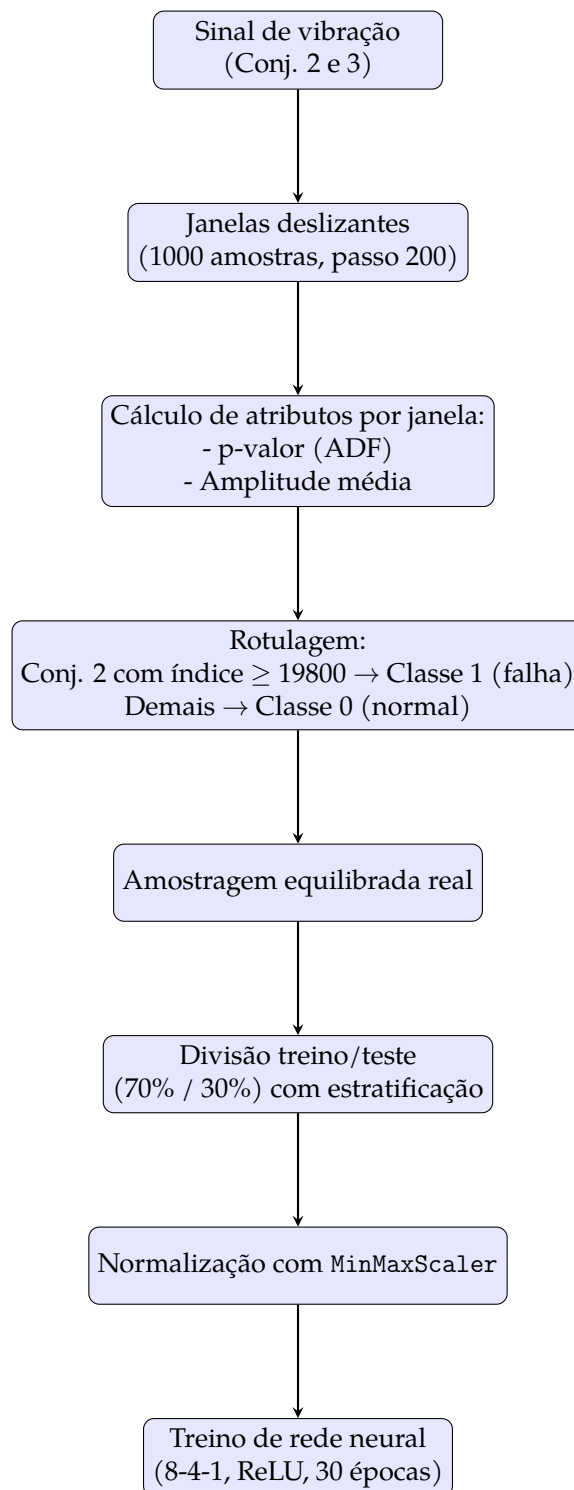


Figura 4.25: Fluxo de preparação, extração de atributos e treino do modelo com p-valor e amplitude.

```

=== Relatório de Classificação ===
      precision    recall  f1-score   support

     0       0.64       0.95       0.76       296
     1       0.90       0.46       0.61       295

 accuracy          0.70       591
 macro avg          0.77       0.70       0.68       591
 weighted avg       0.77       0.70       0.68       591
    
```

Figura 4.26: Matriz de Resultados do modelo com combinação de p-valor e amplitude




Figura 4.27: Matriz de Confusão do modelo com combinação de p-valor e amplitude

```

temp.py x
1 import os
2 import pandas as pd
3 import numpy as np
4 from statsmodels.tsa.stattools import adfuller
5 from sklearn.model_selection import train_test_split
6 from sklearn.preprocessing import MinMaxScaler
7 from sklearn.metrics import classification_report, confusion_matrix
8 from tensorflow.keras.models import Sequential
9 from tensorflow.keras.layers import Dense
10 import matplotlib.pyplot as plt
11 import seaborn as sns
12
13 # === Caminhos ===
14 caminho_falha = r'C:\Users\danie\OneDrive\Ambiente de Trabalho\TESE\python-teste01\2nd_test'
15 caminho_normal = r'C:\Users\danie\OneDrive\Ambiente de Trabalho\TESE\python-teste01\3rd_test'
16 extensoes_validas = ['.17', '.20', '.46', '.53', '.55', '.57']
17 tamanho_janela = 1000
18 passo = 200
19 indice_falha = 19800
20
21 def processar_dados(diretorio, rotulo, considerar_falha=False):
22     pvalores, indices, amplitudes = [], [], []
23     for arquivo in sorted(os.listdir(diretorio)):
24         if arquivo.endswith('.39') or any(arquivo.endswith(ext) for ext in extensoes_validas):
25             caminho = os.path.join(diretorio, arquivo)
26             df = pd.read_csv(caminho, delimiter='|', header=None)
27             sinal = df[0].abs()
28             for i in range(0, len(sinal) - tamanho_janela, passo):
29                 janela = sinal.iloc[i:i + tamanho_janela]
30                 try:
31                     p_val = adfuller(janela)[1]
32                     media_amp = janela.mean()
33                     pvalores.append(p_val)
34                     indices.append(i + tamanho_janela // 2)
35                     amplitudes.append(media_amp)
36                 except:
37                     continue
38             df_resultado = pd.DataFrame({
39                 'Indice': indices,
40                 'Amplitude_media': amplitudes,
41                 'P_valor': pvalores,
42                 'Label': rotulo
43             })
44             if considerar_falha:
45                 df_resultado['Label'] = df_resultado['Indice'].apply(lambda x: 1 if x >= indice_falha else 0)
46             return df_resultado
47
48 # === Processamento ===
49 df_falha = processar_dados(caminho_falha, 1, considerar_falha=True)
50 df_normal = processar_dados(caminho_normal, 0, considerar_falha=False)
51
52 # === Equilíbrio ===
53 n_falhas = len(df_falha[df_falha['Label'] == 1])
54 df_normal_eq = df_normal.sample(n=n_falhas, random_state=42)
55 df_falha_eq = df_falha[df_falha['Label'] == 1]
56 df_total = pd.concat([df_falha_eq, df_normal_eq], ignore_index=True).dropna()
57

```

Figura 4.28: Parte 1 do Código do modelo com combinação de p-valor e amplitude

```

# === Features ===
X = df_total[['P_valor', 'Amplitude_media']].values
y = df_total['Label'].values

# === Split & Normalização ===
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3, stratify=y, random_state=42)
scaler = MinMaxScaler()
X_train = scaler.fit_transform(X_train)
X_test = scaler.transform(X_test)

# === Modelo ===
model = Sequential([
    Dense(8, activation='relu', input_shape=(2,)),
    Dense(4, activation='relu'),
    Dense(1, activation='sigmoid')
])
model.compile(optimizer='adam', loss='binary_crossentropy', metrics=['accuracy'])
model.fit(X_train, y_train, epochs=30, batch_size=32, validation_data=(X_test, y_test))

# === Avaliação ===
y_pred = (model.predict(X_test) > 0.5).astype(int)
print("\n=== Relatório de Classificação ===")
print(classification_report(y_test, y_pred))

# === Matriz de Confusão ===
cm = confusion_matrix(y_test, y_pred)
sns.heatmap(cm, annot=True, fmt='d', cmap='Blues', xticklabels=['Normal', 'Falha'], yticklabels=['Normal', 'Falha'])
plt.xlabel('Previsto')
plt.ylabel('Real')
plt.title('Matriz de Confusão - Modelo com P-valor + Amplitude')
plt.tight_layout()
plt.show()

```

Figura 4.29: Parte 2 do Código do modelo com combinação de p-valor e amplitude

5 DISCUSSÃO DE RESULTADOS

A Tabela 5.1 resume o desempenho dos três modelos de classificação desenvolvidos com base em diferentes métricas extraídas do sinal de vibração: p-valor do teste ADF, amplitude média e a combinação de ambos. Esta análise comparativa permite refletir sobre os contributos individuais e combinados de cada métrica na capacidade do modelo distinguir entre estados de funcionamento normal e com falha do rolamento.

O modelo baseado exclusivamente no p-valor do teste ADF revelou-se pouco eficaz na tarefa de classificação. Apesar de o dataset ter sido equilibrado com recurso à técnica SMOTE, os resultados obtidos mostraram-se fortemente enviesados, com o modelo a classificar quase todos os exemplos como pertencendo à classe de falha. A precisão, o recall e o f1-score da classe 0 (normal) foram praticamente nulos, o que evidencia a limitação do p-valor enquanto métrica isolada para este fim. Estes resultados já tinham sido antecipados na análise dos sinais ao longo do tempo, onde se observava que o p-valor, embora sinalizasse perda de estacionaridade, não apresentava um comportamento suficientemente distintivo para suportar decisões de classificação robustas.

Com a utilização da amplitude média como única *feature*, observou-se uma melhoria significativa em relação ao modelo anterior. O modelo passou a identificar corretamente a maior parte dos exemplos da classe normal, refletido por um elevado *recall* (0.98) e *f1-score* (0.75) para a classe 0. No entanto, a capacidade de detetar falhas continuou limitada, com um recall de apenas 0.36 na classe 1. Estes resultados sugerem que a amplitude do sinal transporta informação relevante sobre o estado do rolamento, especialmente no funcionamento normal, mas, ainda assim, não é suficiente para uma deteção eficaz de todos os casos de falha.

A combinação do p-valor com a amplitude conduziu ao melhor desempenho global. O modelo conseguiu manter um equilíbrio mais consistente entre as duas classes, com valores de *f1-score* de 0.76 e 0.61 para as classes 0 e 1, respetivamente. O aumento da sensibilidade à classe de falha (*recall* = 0.46) revela que o uso conjunto de métricas associadas à estacionaridade e à energia do sinal proporciona uma representação mais completa das dinâmicas de degradação. A integração destas duas fontes de informação parece colmatar as limitações individuais, permitindo ao modelo capturar alterações tanto na forma estatística do sinal como na sua intensidade.

Do ponto de vista computacional, destaca-se que o tempo de execução do processo completo (desde a leitura dos ficheiros, cálculo das métricas, treino e avaliação do modelo) é considerável, especialmente no caso da métrica baseada no p-valor, devido à

Deteção de falhas em rolamentos através da análise de vibração usando métodos de ...

aplicação repetida do teste ADF em janelas móveis. Esta limitação torna-se relevante em contextos de monitorização em tempo real, podendo comprometer a viabilidade da aplicação prática sem otimizações adicionais.

Tabela 5.1: Comparação dos resultados dos modelos de classificação com diferentes métricas

Modelo	Precisão (Classe 0)	Recall (Classe 0)	F1- score (Classe 0)	Precisão (Classe 1)	Recall (Classe 1)	F1- score (Classe 1)
P-valor (ADF)	0.57	0.01	0.01	0.50	1.00	0.67
Amplitude Média	0.64	0.92	0.76	0.95	0.36	0.52
P-valor + Amplitude	0.64	0.95	0.76	0.90	0.46	0.61

6 CONCLUSÃO

Este trabalho teve como principal objetivo investigar a possibilidade de utilizar métricas extraídas de sinais de vibração, nomeadamente o p-valor do teste de ADF, como indicadores robustos para a deteção precoce de falhas em rolamentos. Para tal, foram desenvolvidos e avaliados modelos de classificação binária, com base em dados reais de vibração obtidos de rolamentos em funcionamento sob condições laboratoriais controladas, procurando simular um cenário de degradação progressiva de um rolamento.

Inicialmente, procedeu-se à análise da estacionaridade do sinal ao longo do tempo, utilizando o teste ADF aplicado a janelas deslizantes da série temporal. Os resultados demonstraram que o p-valor tende a aumentar à medida que o rolamento se degrada, o que indica perda de estacionaridade — fenómeno coerente com a evolução da falha. No entanto, ao utilizar apenas o p-valor como input para um modelo de classificação, observou-se um desempenho insatisfatório: o modelo não conseguiu distinguir eficazmente entre os estados normal e com falha, classificando erroneamente quase todas as amostras como falhas. Este resultado evidenciou que, embora o p-valor seja útil na monitorização da degradação, a sua utilização isolada não é suficientemente discriminativa para modelos automáticos de classificação.

Como alternativa, explorou-se o uso da amplitude média do sinal, que se revelou uma métrica mais informativa, especialmente para a classe normal. O modelo baseado apenas na amplitude apresentou melhor desempenho global do que o modelo com p-valor, mas ainda mostrou limitações na deteção das falhas.

A verdadeira melhoria surgiu com a integração de ambas as métricas — p-valor e amplitude — que resultou num modelo mais equilibrado, com melhor *f1-score* nas duas classes e maior capacidade para capturar as mudanças no sinal associadas ao processo de falha.

Esta comparação entre os modelos desenvolvidos evidenciou a importância de utilizar métricas complementares. A amplitude permitiu capturar variações na energia do sinal, enquanto o p-valor refletiu alterações na estrutura estatística. A sua combinação revelou-se eficaz para caracterizar o estado do rolamento de forma mais completa.

Adicionalmente, discutiu-se no Capítulo 5 a limitação relacionada com o tempo de execução dos algoritmos, particularmente no cálculo do p-valor do teste ADF. Esta limitação levanta questões quanto à escalabilidade da abordagem em contextos de monitorização em tempo real, reforçando a necessidade de explorar soluções mais eficientes no futuro.

Por fim, as questões de investigação propostas foram abordadas ao longo do trabalho:

- O p-valor do teste ADF, isoladamente, não se mostrou um indicador suficientemente robusto para a deteção automática de falhas, embora demonstre utilidade como métrica de apoio na monitorização da degradação;
- A vibração, analisada através de métricas adequadas, revelou-se eficaz para descrever o estado de saúde dos rolamentos, validando o seu potencial como sinal-chave em sistemas de diagnóstico;
- A perda de estacionaridade é um sinal potencialmente relevante de falha, mas o seu valor discriminativo aumenta consideravelmente quando combinada com outras métricas, como a amplitude.

Em suma, este trabalho confirmou o potencial da análise da estacionaridade e da amplitude do sinal de vibração na deteção de falhas em rolamentos. Contudo, mostrou também que nenhuma métrica isolada é suficiente para garantir um desempenho robusto. Assim, reforça-se a importância de abordagens multivariadas e integradas, com base em múltiplos indicadores extraídos do sinal.

Como trabalho futuro, propõe-se a avaliação de outras *features* do domínio do tempo e frequência, a experimentação com arquiteturas mais complexas (como redes neuronais convolucionais ou recorrentes), e a validação em cenários industriais reais, com maior diversidade de condições operacionais e tipos de falhas. A análise do desempenho em tempo real e a otimização dos tempos de execução também constituem aspetos fundamentais a aprofundar.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] M. González, V. Díaz, B. Pérez, B. C. G-Bustelo, and J. Anzola, "Bearing fault diagnosis with envelope analysis and machine learning approaches using cwru dataset," Los Libertadores University Foundation, Bogotá, Tech. Rep., jun 2023.
- [2] W. Deng, K. T. P. Nguyen, K. Medjaher, C. Gogu, and J. Morio, "Bearings rul prediction based on contrastive self-supervised learning," Université de Toulouse, Tech. Rep., 2023.
- [3] a. L. Z. Lei, Nie, X. Shiyi, C. Wentao, and Y. Haoming, "Remaining useful life prediction for rolling bearings based on similarity feature fusion and convolutional neural network," Journal of the Brazilian Society of Mechanical Sciences and Engineering, Tech. Rep., 2022.
- [4] T. A. Harris and M. N. Kotzalas, "Rolling bearing analysis," CRC Press, Tech. Rep., 2006.
- [5] R. B. Randall and J. Antoni, "Rolling element bearing diagnostics - a tutorial," Mechanical Systems and Signal Processing, Tech. Rep., 2011.
- [6] S. Group, "Skf rolling bearings catalogue," SKF, Tech. Rep., 2018.
- [7] B. J. Roylance, "Lubrication and lubricants in tribology," Wiley, Tech. Rep., 2005.
- [8] I. 281:2007, "Rolling bearings — dynamic load ratings and rating life," International Organization for Standardization, Tech. Rep., 2007.
- [9] A. K. S. Jardine, D. Lin, and D. Banjevic, "A review on machinery diagnostics and prognostics implementing condition-based maintenance," Mechanical Systems and Signal Processing, Tech. Rep., 2006.
- [10] J. D. Hamilton, "Time series analysis," Princeton University Press, Princeton, Tech. Rep., 1994.
- [11] H. Qiu, J. Lee, J. Lin, and G. Yu, "Wavelet filter-based weak signature detection method and its application on rolling element bearing prognostics," University of Cincinnati, Tech. Rep., 2006.
- [12] Y. Lei, N. Li, L. Guo, N. Li, T. Yan, and J. Lin, "Machinery health prognostics: A systematic review from data acquisition to rul prediction," National University of Defense Technology, China, Tech. Rep., 2018.

- [13] S. Kapadnis, "Ball bearing run-to-failure dataset," Kaggle, Tech. Rep., 2023, disponível em: <https://www.kaggle.com/datasets/sujaykapadnis/ball-bearing-run-to-failure-dataset>.
- [14] Josh101, "Machinery fault database – induction motor fault," Kaggle, Tech. Rep., 2023, disponível em: <https://www.kaggle.com/datasets/josh101/machinery-fault-database-induction-motor-fault>.
- [15] S. Gonçalves, D. Pereira, M. Cardoso, P. Lopes, and F. J. G. Silva, "Dataset for ball bearing lubrication conditions monitoring," Zenodo, Tech. Rep., 2023, disponível em: <https://zenodo.org/records/7589904>.
- [16] W. S. Cleveland, "Robust locally weighted regression and smoothing scatter-plots," Journal of the American Statistical Association, Tech. Rep., 1979.
- [17] N. Tandon and A. Choudhury, "A review of vibration and acoustic measurement methods for the detection of defects in rolling element bearings," Tribology International, Tech. Rep., 1999.
- [18] T. Wang and J. Yu, "A review of statistical methods for health monitoring of rolling element bearings," Journal of Sound and Vibration, Tech. Rep., 2020.
- [19] L. J. L. J. Y. G. Qiu, H., "Bearing performance degradation assessment using distance analysis," Mechanical Systems and Signal Processing, Tech. Rep., 2006.



**Instituto Superior
de Engenharia**

Politécnico de Coimbra