



**UNIVERSIDADE ESTADUAL DE CAMPINAS**  
Faculdade de Engenharia Mecânica

**IAGO OLIVEIRA DE ALMEIDA**

**Análise comparativa de modelos  
substitutos aplicados a mancais  
hidrodinâmicos para identificação de  
defeitos em sistemas rotativos**

CAMPINAS  
2022

IAGO OLIVEIRA DE ALMEIDA

# **Análise comparativa de modelos substitutos aplicados a mancais hidrodinâmicos para identificação de defeitos em sistemas rotativos**

Dissertação de mestrado apresentada à Faculdade de Engenharia Mecânica da Universidade Estadual de Campinas como parte dos requisitos exigidos para obtenção do título de Mestre em Engenharia Mecânica, na Área de Mecânica dos Sólidos e Projeto Mecânico.

Orientador: Prof. Dr Gregory Bregion Daniel.

ESTE TRABALHO CORRESPONDE À VERSÃO FINAL DA DISSERTAÇÃO DEFENDIDA PELO ALUNO IAGO OLIVEIRA DE ALMEIDA, E ORIENTADO PELO PROF. DR GREGORY BREGION DANIEL.

**CAMPINAS  
2022**

Ficha catalográfica  
Universidade Estadual de Campinas  
Biblioteca da Área de Engenharia e Arquitetura  
Rose Meire da Silva - CRB 8/5974

AL64a Almeida, Iago Oliveira de, 1997-  
Análise comparativa de modelos substitutos aplicados a mancais hidrodinâmicos para identificação de defeitos em sistemas rotativos / Iago Oliveira de Almeida. – Campinas, SP : [s.n.], 2022.

Orientador: Gregory Bregion Daniel.  
Dissertação (mestrado) – Universidade Estadual de Campinas, Faculdade de Engenharia Mecânica.

1. Mancais. 2. Hidrodinâmica. 3. Rotores - Dinâmica. I. Daniel, Gregory Bregion, 1984-. II. Universidade Estadual de Campinas. Faculdade de Engenharia Mecânica. III. Título.

Informações para Biblioteca Digital

**Título em outro idioma:** Comparative analysis of surrogate models applied to journal bearings for identification of defects in rotating systems

**Palavras-chave em inglês:**

Bearings

Hydrodynamic

Rotordynamics

**Área de concentração:** Mecânica dos Sólidos e Projeto Mecânico

**Titulação:** Mestre em Engenharia Mecânica

**Banca examinadora:**

Gregory Bregion Daniel [Orientador]

Aldemir Aparecido Cavalini Junior

Helio Fiori de Castro

**Data de defesa:** 08-03-2022

**Programa de Pós-Graduação:** Engenharia Mecânica

**Identificação e informações acadêmicas do(a) aluno(a)**

- ORCID do autor: <https://orcid.org/0000-0002-0629-5407>

- Currículo Lattes do autor: <http://lattes.cnpq.br/6837372546121005>

Agência: CAPES

nº do Proc.: 88887.499811/2020-00

UNIVERSIDADE ESTADUAL DE CAMPINAS  
FACULDADE DE ENGENHARIA MECÂNICA

DISSERTAÇÃO DE MESTRADO ACADÊMICO

**Análise comparativa de modelos substitutos aplicados a mancais hidrodinâmicos para identificação de defeitos em sistemas rotativos**

Autor: Iago Oliveira de Almeida

Orientador: Prof. Dr. Gregory Bregion Daniel

A Banca Examinadora composta pelos membros abaixo aprovou esta Dissertação:

---

**Prof. Dr. Gregory Bregion Daniel, Presidente**  
**DSI/FEM/UNICAMP**

---

**Prof. Dr. Aldemir Aparecido Cavalini Junior**  
**FEMEC/UFU**

---

**Prof. Dr. Helio Fiori de Castro**  
**DSI/FEM/UNICAMP**

A Ata de Defesa com as respectivas assinaturas dos membros encontra-se no SIGA/Sistema de Fluxo de Dissertação/Tese e na Secretaria do Programa da Unidade.

Campinas, 8 de março de 2022.

## **Dedicatória**

Dedico este trabalho à memória de minha avó, Maria. A Laidés, minha avó, ao Antonio e Arlindo, meus avôs. Aos meus pais, Ivo e Marli. Ao Pedro e Igor, meus irmãos. À Beatriz, minha companheira.

## **Agradecimentos**

Aos meus pais, Ivo e Marli, por todo apoio incondicional em todas as escolhas e etapas da minha vida.

Ao meu orientador Gregory, pela forma paciente e objetiva que orientou este trabalho, sempre com confiança, compreensão e incentivo.

A todos os colegas do LAMAR, por terem compartilhado suas experiências e conhecimento mesmo a distância.

À minha namorada, companheira e amiga Beatriz Reis por estar ao meu lado durante está caminhada.

A Universidade Estadual de Campinas e a Faculdade de Engenharia Mecânica e seu corpo docente por proporcionar uma formação de qualidade.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

## Resumo

O funcionamento saudável de máquinas rotativas está associado ao desempenho adequado dos mancais, devido à influência significativa deste componente no comportamento do rotor. A análise do comportamento do filme lubrificante é realizada convencionalmente resolvendo a equação de Reynolds pelo método dos volumes finitos, no qual as forças hidrodinâmicas são calculadas integrando o campo de pressão no domínio do mancal. Entretanto, este tipo de solução possui um alto custo computacional, visto que se trata de um método de solução numérica. Neste contexto, este trabalho avalia a aplicação de modelos substitutos para calcular as forças hidrodinâmicas em mancais cilíndricos, comparando seus desempenhos em um problema de classificação de defeitos de desbalanceamento em rotores suportados por esses mancais. Para tanto, diferentes modelos substitutos foram investigados neste trabalho, tais como interpolação linear, interpolação cúbica, interpolação *spline* e rede neural artificial. As forças hidrodinâmicas resultantes dos modelos substitutos foram comparadas com os resultados obtidos através da solução numérica da equação de Reynolds pelo método dos volumes finitos. Em seguida, os modelos substitutos foram aplicados para sintetizar artificialmente bancos de dados contendo sinais de vibração com defeitos de desbalanceamento do rotor. Estes bancos são usados no treinamento das redes neurais convolucionais para a classificação de dados em três classes diferentes de desbalanceamento. Por fim, os resultados de classificação via redes neurais convolucionais são obtidos aplicando um banco de teste com diferentes níveis de ruído gaussiano branco. Estes resultados são analisados e comparados para diferentes conjuntos de dados. Com base nas análises realizadas neste trabalho pode-se concluir que os modelos substitutos apresentam resultados promissores com relação a precisão e redução do custo computacional, sendo assim uma ferramenta viável para substituir os modelos numéricos usados na solução de mancais hidrodinâmicos cilíndricos.

*Palavras-chave:* Modelos substitutos, Mancais hidrodinâmicos, Forças hidrodinâmicas, Dinâmica de rotores.

## **Abstract**

The healthy functioning of rotating machines is associated with the adequate performance of the bearings, due to the significative influence of this component on the rotor's behavior. The analysis of the behavior of the lubricating film is performed conventionally solving the Reynolds equation by the finite volume method, in which the hydrodynamic forces are calculated integrating the pressure field in the bearing domain. However, this type of solution has a high computational cost, given that it is a numerical solution method. In this context, this work evaluates the application of surrogate models to calculate the hydrodynamic forces in cylindrical bearings, comparing their performance in a problem of classification of unbalance defects in rotors supported by these bearings. For that, different surrogate models were investigated in this work, such as linear interpolation, cubic interpolation, spline interpolation and artificial neural network. The hydrodynamic forces resulting from the surrogate models were compared with the results obtained through the numerical solution of the Reynolds equation using the finite volume method. Then the surrogate models were applied to artificially sinter databases containing vibration signals with rotor unbalance defects. These databases are used to train convolutional neural networks to classify data into three different classes of unbalance. Finally, classification results via convolutional neural networks are obtained by applying a test database with different levels of white gaussian noise. These results are analyzed and compared for different data sets. Based on the analyzes carried out in this work, it can be concluded that the surrogate models present promising results in terms of accuracy and computational cost reduction, thus being a viable tool to replace the numerical models used in for the solution in journal bearings.

*Keywords:* Surrogate models, Journal bearings, Hydrodynamic forces, Rotordynamics.

## Lista de Figuras

Figura 3-1: Representação de um mancal cilíndrico. ....	28
Figura 3-2: Definição de malha computacional genérica para determinar a pressão. .....	31
Figura 3-3: Esquema ilustrativo da curva de lócus. ....	35
Figura 3-4: Modelo físico de um mancal hidrodinâmico. ....	36
Figura 3-5: Configuração típica de um sistema rotativo. ....	39
Figura 3-6: Esquema de montagem da matriz global. ....	42
Figura 3-7: Conjunto de dados gerado com o método a) <i>grid</i> retangular, b) Hipercubo Latino. ....	45
Figura 3-8: Modelo de neurônio artificial ( <i>perceptron</i> ). ....	46
Figura 3-9: Comparação da saturação das funções de ativação sigmóides e suas derivadas. ....	48
Figura 3-10: Arquitetura de uma rede MLP. ....	49
Figura 3-11: Ilustração da interpolação linear. ....	53
Figura 3-12: Comparação de ajuste de curvas por interpolação cúbica e <i>spline</i> cúbico. .....	56
Figura 3-13: Ilustração do cálculo do <i>ERMFR</i> . ....	57
Figura 3-14: Típica rede neural convolucional. ....	60
Figura 3-15: Exemplo de convolução 2-D. ....	61
Figura 3-16: Processo de convolução 2-D (Kernel 2x2, <i>stride</i> = 2, com <i>zero padding</i> ). .....	62
Figura 3-17: Exemplo de agrupamento 2-D ( <i>max-pooling</i> 2x2, <i>stride</i> = 2, sem <i>padding</i> ). .....	63
Figura 3-18: Processo de montagem da imagem de vibração. ....	64
Figura 3-19: Matriz de confusão binária. ....	65
Figura 4-1: Testes de convergência de malha. ....	69
Figura 4-2: Campo de pressão estimado. ....	70
Figura 4-3: Rotor discretizado em elementos finitos. ....	70
Figura 4-4: Coeficientes equivalentes de rigidez. ....	72
Figura 4-5: Coeficientes equivalentes de amortecimento. ....	72
Figura 4-6: Diagrama de Campbell do rotor flexível. ....	73
Figura 4-7: Diagrama de Campbell do rotor rígido. ....	73

Figura 4-8: Análise da dinâmica do rotor para definição dos limites dos bancos de dados de treinamento ou interpolação e de teste.....	75
Figura 4-9: Fluxograma da aplicação dos modelos substitutos.....	78
Figura 4-10: Comparação das forças hidrodinâmicas adimensionais na direção .....82	82
Figura 4-11: Comparação das forças hidrodinâmicas adimensionais na direção $Y$ . .82	82
Figura 4-12: Imagens de vibração dos sinais gerados com rótulos.....	87
Figura 4-13: Imagens de vibração dos sinais gerados com adição de ruídos em diferentes níveis SNR.....	89
Figura 4-14: Fluxograma da classificação de defeitos. ....	91

## Lista de Tabelas

Tabela 4-1: Características do mancal cilíndrico.....	68
Tabela 4-2: Dimensões dos rotores (unidades em milímetros). ....	71
Tabela 4-3: Propriedades dos materiais e dimensões do disco rígido. ....	71
Tabela 4-4: Atributos do mancal hidrodinâmico. ....	75
Tabela 4-5: Características dos bancos de dados para treinamento ou interpolação dos modelos substitutos. ....	76
Tabela 4-6: Comparação dos resultados do <i>RMSE</i> da força na direção <i>X</i> entre os modelos substitutos utilizados com diferentes números de amostras de treinamento ou interpolação.....	79
Tabela 4-7: Comparação dos resultados do <i>RMSE</i> da força na direção <i>Y</i> entre os modelos substitutos utilizados com diferentes números de amostras de treinamento ou interpolação.....	79
Tabela 4-8: Comparação dos resultados do <i>ERMFR</i> entre os modelos substitutos utilizados com diferentes números de amostras de treinamento ou interpolação. ....	79
Tabela 4-9: Comparação dos resultados do coeficiente de determinação <i>R2</i> da força na direção <i>X</i> entre os modelos substitutos utilizados com diferentes números de amostras de treinamento ou interpolação. ....	80
Tabela 4-10: Comparação dos resultados do coeficiente de determinação <i>R2</i> da força na direção <i>Y</i> entre os modelos substitutos utilizados com diferentes números de amostras de treinamento ou interpolação. ....	80
Tabela 4-11: Tempos para efetuar as estimativas e o treinamento da rede neural com diferentes números de amostras de treinamento. ....	83
Tabela 4-12: Tempos para efetuar uma estimativa nas três interpolações com diferentes números de amostras de interpolação.....	83
Tabela 4-13: Definição das classes de defeitos. ....	85
Tabela 4-14: Conjuntos de defeitos analisados.....	85
Tabela 4-15: Limites dos atributos para os bancos de baixa rotação.....	86
Tabela 4-16: Limites dos atributos para os bancos de elevada rotação.....	86
Tabela 4-17: Número de amostras por variável dos bancos de dados para treinamento e teste das redes neurais convolucionais.....	88
Tabela 4-18: Características da estrutura da rede neural convolucional.....	89

Tabela 4-19: Comparação das acurácias na classificação de defeitos para o rotor flexível em baixa rotação com banco de dados natural de 1200 amostras. ....	92
Tabela 4-20: Comparação das acurácias na classificação de defeitos para o rotor flexível em baixa rotação com banco de dados aumentado de 7200 amostras. ....	92
Tabela 4-21: Comparação das acurácias na classificação de defeitos para o rotor flexível em baixa rotação com banco de dados natural 2400 amostras. ....	93
Tabela 4-22: Comparação das acurácias na classificação de defeitos para o rotor flexível em baixa rotação com banco de dados aumentado de 14400 amostras. ....	94
Tabela 4-23: Comparação das acurácias na classificação entre os diferentes bancos de dados de treinamento para o rotor flexível em baixa rotação. ....	95
Tabela 4-24: Comparação das acurácias na classificação de defeitos para o rotor flexível em elevada rotação com banco de dados natural de 1200 amostras. ....	96
Tabela 4-25: Comparação das acurácias na classificação de defeitos para o rotor flexível em elevada rotação com banco de dados aumentado de 7200 amostras. ...	97
Tabela 4-26: Comparação das acurácias na classificação de defeitos para o rotor flexível em elevada rotação com banco de dados natural de 2400 amostras. ....	97
Tabela 4-27: Comparação das acurácias na classificação de defeitos para o rotor flexível em elevada rotação com banco de dados aumentado de 14400 amostras. .	98
Tabela 4-28: Comparação das acurácias na classificação entre os diferentes bancos de dados de treinamento para o rotor flexível em elevada rotação. ....	98
Tabela 4-29: Comparação das acurácias na classificação de defeitos para o rotor rígido em baixa rotação com banco de dados natural de 1200 amostras. ....	99
Tabela 4-30: Comparação das acurácias na classificação de defeitos para o rotor rígido em baixa rotação com banco de dados aumentado de 7200 amostras. ....	100
Tabela 4-31: Comparação das acurácias na classificação de defeitos para o rotor rígido em baixa rotação com banco de dados natural de 2400 amostras. ....	101
Tabela 4-32: Comparação das acurácias na classificação de defeitos para o rotor rígido em baixa rotação com banco de dados aumentado de 14400 amostras. ....	101
Tabela 4-33: Comparação das acurácias na classificação entre os diferentes bancos de dados de treinamento para o rotor rígido em baixa rotação. ....	102
Tabela 4-34: Comparação das acurácias na classificação de defeitos para o rotor rígido em elevada rotação com banco de dados natural de 1200 amostras. ....	103
Tabela 4-35: Comparação das acurácias na classificação de defeitos para o rotor rígido em elevada rotação com banco de dados aumentado de 7200 amostras. ...	104

Tabela 4-36: Comparação das acurácias na classificação de defeitos para o rotor rígido em elevada rotação com banco de dados natural de 2400 amostras. ....	104
Tabela 4-37: Comparação das acurácias na classificação de defeitos para o rotor rígido em elevada rotação com banco de dados aumentado de 14400 amostras. .	105
Tabela 4-38: Comparação das acurácias na classificação entre os diferentes bancos de dados de treinamento para o rotor rígido em elevada rotação. ....	106

## SUMÁRIO

1 Introdução .....	15
2 Revisão Bibliográfica .....	20
3 Metodologia .....	27
3.1 Características do mancal hidrodinâmico cilíndrico .....	27
3.2 Equação de Reynolds .....	29
3.3 Solução Numérica da Equação de Reynolds .....	30
3.4 Cálculo dos coeficientes equivalentes de rigidez e amortecimento .....	36
3.5 Modelagem de sistemas rotativos pelo método dos elementos finitos .....	38
3.6 Modelos substitutos .....	44
3.6.1 Amostragem .....	44
3.6.2 Redes Neurais Artificiais .....	46
3.6.3 Interpolação .....	52
3.6.4 Métricas de avaliação dos modelos substitutos .....	56
3.7 Classificação de defeitos com aprendizado profundo .....	58
3.7.1 Redes neurais convolucionais .....	59
3.7.2 Imagem de vibração .....	63
3.7.3 Aumento de dados .....	64
3.7.4 Métricas de avaliação de classificação .....	65
4 Resultados e Discussões .....	68
4.1 Características do sistema rotor-mancais .....	68
4.2 Banco de dados dos modelos substitutos .....	74
4.3 Treinamento e testes com os modelos substitutos .....	76
4.4 Classificação de defeitos .....	84
4.4.1 Análise da classificação do rotor flexível em baixa rotação .....	91
4.4.2 Análise da classificação do rotor flexível em elevada rotação .....	96
4.4.3 Análise da classificação do rotor rígido em baixa rotação .....	99
4.4.4 Análise da classificação do rotor rígido em elevada rotação .....	103
5 Conclusão .....	107
5.1 Sugestões para trabalhos futuros .....	109

## 1 INTRODUÇÃO

As máquinas rotativas constituem uma classe de máquinas amplamente utilizadas em diversos ramos da indústria mecânica, como na aviação e na produção de energia elétrica. Além disso, o funcionamento das máquinas rotativas envolve diversas áreas de estudo da engenharia, como dinâmica de sistemas mecânicos e análises de vibrações. Dessa maneira, as pesquisas científicas têm sido cada vez mais conduzidas neste tema, com o intuito de desenvolver tecnologias para garantir maior confiabilidade e eficiência durante a operação das máquinas rotativas, por meio de modelos matemáticos cada vez mais representativos.

A dinâmica de rotores é um ramo de sistemas dinâmicos que trata de dispositivos nos quais pelo menos uma parte, geralmente definida como rotor, gira com momento angular significativo (GENTA, 2005). Assim, pode-se definir um rotor como um corpo apoiado em um conjunto de mancais que o permitem girar livremente em torno de um eixo fixo no espaço. Um dos elementos fundamentais para o funcionamento dos rotores são os mancais hidrodinâmicos, pois possuem uma alta capacidade de carga e um baixo coeficiente de atrito. Diferente dos outros mancais existentes, os mancais hidrodinâmicos formam um acoplamento entre a parte girante e a estática através de um filme lubrificante, aumentando a eficiência por consequência do notável baixo coeficiente de atrito.

Em geral, os trabalhos envolvendo os mancais hidrodinâmicos buscam simular computacionalmente o comportamento dinâmico deste componente por meio de modelos matemáticos, com intuito de avaliar a sua influência no comportamento dinâmico do rotor. Devido às próprias condições de operação, os mancais hidrodinâmicos operam a partir da sua geometria e da rotação do rotor, onde cria-se um campo de pressão que por sua vez resulta nas forças hidrodinâmicas atuantes no sistema. A inserção das forças hidrodinâmicas na análise da equação de movimento do sistema rotativo permite que as simulações sejam mais condizentes com o comportamento real da máquina. Portanto, o conhecimento sobre os mancais hidrodinâmicos colabora para o projeto de máquinas com maior estabilidade, confiabilidade e eficiência.

Em virtude da importância da aplicação de mancais hidrodinâmicos em rotores, fica evidente a necessidade de desenvolver modelos matemáticos capazes de representar o comportamento dinâmico desses componentes. Entretanto, quanto

maior a complexidade do modelo, maior é o seu custo computacional. Assim, a inserção de efeitos como cavitação e a variação da viscosidade do fluido lubrificante acarretam um significativo custo computacional, demandando um alto tempo de simulação para determinar as forças hidrodinâmicas (SICCHIERI, 2019).

Devido ao elevado custo computacional quando modelado convencionalmente através de métodos numéricos, surge então a necessidade de obter modelos alternativos capazes de representar o comportamento dinâmico não linear das forças hidrodinâmicas nesses mancais. Em geral, esses modelos substitutos devem ajustar funções analíticas simples para representar os modelos computacionais de custo elevado. Entre os modelos substitutos que mais têm se destacado nos últimos anos estão o método Kriging e as redes neurais artificiais (SICCHIERI, 2019; KORVAEV et al., 2017). No entanto, existem diferentes modelos substitutos que podem ser adequados para esta aplicação, exigindo uma avaliação criteriosa para identificar as vantagens e limitações dos métodos mais recomendados (SIMPSON et al., 2001). Por fim, é importante destacar que o uso de modelos de baixo custo computacional permite o desenvolvimento de novas abordagens para o monitoramento de máquinas rotativas, seja através de métodos baseado em modelo no domínio do tempo, ou ainda, através de técnicas de aprendizagem de máquina a partir da viabilidade em obter elevados bancos de dados.

A análise de vibração apresenta um imenso potencial para elevar a confiabilidade e a disponibilidade de máquinas rotativas, reduzindo as paradas não programadas. A partir da aquisição e processamento dos sinais de vibração, pode-se então analisar o comportamento dessas máquinas e, conseqüentemente, detectar e diagnosticar defeitos incipientes. Uma vez que paradas de máquinas não programadas podem ocorrer devido as falhas, perdas financeiras consideráveis podem ser acarretadas caso os sistemas de monitoramento não sejam capazes de detectar tais defeitos.

A fim de melhor entender a caracterização de falha ou defeito no contexto de monitoramento de máquinas, torna-se relevante então definir esses conceitos. Defeitos são anomalias que não impedem a máquina de cumprir a função requerida, enquanto falhas são anomalias que impedem que essas máquinas cumpram a sua função requerida (NBR 5462, 1994). As falhas são decorrentes da evolução de defeitos, que pode ser lenta (semanas, meses ou anos) ou rápida (horas ou dias).

Alguns defeitos provocam distribuições não uniformes de massa ou fluxo de líquidos e gases no rotor, gerando assim forças de desbalanceamento. Outros defeitos, tais como empenamento ou desalinhamento dos eixos, folgas anormais nos mancais e alterações das rigidezes da estrutura de suporte, são também exemplos que causam alterações no comportamento dinâmico de máquinas rotativas. Quando ocorrem em elevados níveis, estes defeitos podem provocar danos e desgastes aos mancais com consequente falha.

A confiabilidade das máquinas rotativas é de extrema relevância para conferir a maior disponibilidade possível do equipamento. No entanto, o envelhecimento natural dessas máquinas aumenta a probabilidade de ocorrência de falhas, as quais podem ter consequências catastróficas. Em agosto de 2009, um dos hidrogeradores da usina hidrelétrica de Sayano-Sheshenskaya colapsou, causando a inundação da casa de força, destruindo 3 unidades geradoras, danificando severamente outras 6 e causando a perda de 75 vidas humanas (HAMILL, 2010). Logo, a detecção e diagnóstico de defeitos são essenciais para aumentar disponibilidade destas máquinas, evitar perdas financeiras e garantir a segurança das vidas envolvidas.

Recentemente, muitos pesquisadores começaram a aplicar novas técnicas para detecção de defeitos em máquinas rotativas, com base em técnicas de aprendizado de máquina e aprendizado profundo (JEONG et al., 2016; ALVES et al., 2020). O crescimento acelerado da aplicação deste tipo de técnica deve-se a dois fatores cruciais do mundo contemporâneo, o aumento constante da quantidade e disponibilidade de dados de todos os tipos e o desenvolvimento significativo de *hardware* capaz de permitir o treinamento de estruturas massivas.

O aprendizado profundo tem sido aplicado com sucesso em diversos problemas de classificação envolvendo o reconhecimento de sons e imagens (SALAMON e BELLO, 2017; WANG e PEREZ, 2017). Devido ao elevado potencial dessa técnica, pesquisadores tem avaliado sua aplicação em problemas de classificação de defeitos em máquinas rotativas. Uma das vantagens a ser destacada é que neste tipo de técnica podem ser empregados dados brutos do problema, o que elimina um estágio de pré-processamento e extração de atributos. Sendo assim, inserindo um banco de dados de treinamento na entrada, o modelo deve aprender a solucionar o problema através de diferentes níveis de representação.

Os bancos de dados de treinamento podem ser coletados em campo ou em bancadas de ensaios. Entretanto, em ambos os casos, este procedimento pode gerar

elevados custos e, portanto, inviabilizar esta abordagem de monitoramento. Diante disso, modelos matemáticos utilizados para simular o comportamento dinâmico do rotor no domínio do tempo sob condições defeituosas podem ser aplicados para gerar um grande conjunto de dados de treinamento, mostrando-se, portanto, como uma alternativa mais viável. Para isso, ressalta-se a necessidade de utilizar modelos matemáticos com baixo custo computacional, de forma a permitir a realização de um elevado número de simulações em tempo hábil de execução. Conseqüentemente, o uso e aplicação de modelos substitutos tem se mostrado uma alternativa promissora para atender essas demandas.

Dentro deste contexto, esta dissertação visa avaliar diferentes tipos de modelos substitutos de mancal hidrodinâmico em problemas de classificação de defeitos de sistemas rotativos. O uso de modelos substitutos para o mancal hidrodinâmico se justifica pela importância deste componente no comportamento dinâmico do sistema rotativo e por representar um componente cuja solução numérica é demasiadamente custosa. Como resultado deste trabalho, busca-se então avaliar a precisão e o custo computacional dos modelos substitutos no cálculo das forças hidrodinâmicas com relação ao modelo de solução numérica. Ainda, determinar quais configurações e tipos de modelos substitutos são capazes de garantir as melhores acurácias no processo de classificação de defeito do rotor. Entre os diferentes modelos substitutos investigados neste trabalho estão a interpolação linear, interpolação cúbica, interpolação *spline* e rede neural artificial.

O presente trabalho refere-se ao manuscrito da dissertação de mestrado em engenharia mecânica, cujo tema de pesquisa é uma análise comparativa entre diferentes modelos substitutos aplicados em mancais hidrodinâmicos cilíndricos para identificação de defeitos. Este manuscrito foi estruturado em 5 capítulos. O primeiro capítulo foi responsável pela contextualização do tema e as principais motivações que levaram ao desenvolvimento deste trabalho. O capítulo 2 traz a revisão da literatura existente sobre os modelos matemáticos de mancais hidrodinâmicos, o desenvolvimento de modelos substitutos e algumas das suas aplicações no âmbito da engenharia, por fim, os métodos de aprendizado de máquina aplicados na detecção e diagnóstico de defeitos.

O capítulo 3 apresenta os conceitos básicos de mancais hidrodinâmicos e a equação de Reynolds, descreve a implementação da solução numérica da equação de Reynolds adimensional pelo método de volumes finitos, a determinação dos

coeficientes equivalentes lineares para estimar as forças hidrodinâmicas e da equação de movimento do sistema pelo método dos elementos finitos, assim como as condições de contorno aplicadas ao problema. Ainda, são apresentados os principais modelos substitutos aplicados neste trabalho, abordando de forma sucinta as etapas de modelagem. É também apresentada a formulação da rede neural artificial e das interpolações aplicadas neste trabalho. Por fim, as técnicas aplicadas para identificação de defeitos são explanadas.

O capítulo 4 apresenta os resultados obtidos, em que as hipóteses adotadas para construção dos modelos substitutos são apresentadas, juntamente com a apresentação e discussão dos resultados numéricos de teste e validação dos modelos substitutos propostos. Em seguida, os bancos de dados defeituosos gerados com os modelos substitutos são preparados e classificados, cujos resultados obtidos são comparados e discutidos. Por fim, as conclusões e as sugestões para trabalhos futuros são descritas no capítulo 5.

## 2 REVISÃO BIBLIOGRÁFICA

A lubrificação hidrodinâmica é um fenômeno físico que ocorre quando duas superfícies estão em movimento relativo e são separadas por um filme de fluido lubrificante. A teoria dos mecanismos de lubrificação foi originada no período entre 1883 e 1886 quando o russo Nikolai Pavlovich Petrov (1836 - 1920) e os dois britânicos Beauchamp Tower (1845 - 1904) e Osborne Reynolds (1842 - 1912) estabeleceram solidamente seus fundamentos. Os três perceberam que o processo de lubrificação não era devido à interação mecânica de superfícies sólidas, mas à dinâmica do filme de fluido que as separava (HARNOY, 2002).

Este conceito de lubrificação hidrodinâmica começou por meio dos experimentos realizados por Petrov sobre o atrito em mancais. Ele postulou que a propriedade mais importante da relação de um fluido com o atrito não era sua densidade, mas sim a sua viscosidade. Em seu artigo Petrov (1883) estabeleceu uma relação funcional entre o torque requerido para cisalhar o filme lubrificante e os parâmetros do mancal, que é utilizada até a atualidade. No entanto, Petrov falhou ao estender seu estudo à análise da relação entre a força de atrito e a capacidade de carga dos mancais (NORTON, 2013).

Neste mesmo período, Tower (1883) estava investigando experimentalmente o atrito em mancais lubrificados para a indústria de ferrovia. A descoberta fundamental da presença de pressão hidrodinâmica em filmes de fluidos lubrificantes em mancais ocorreu após um incidente ocorrido durante uma série de experimentos (STACHOWIAK e BATCHELOR, 2005). Tower investigou em detalhe as pressões no filme lubrificante no intervalo de 180° do mancal (NORTON, 2013).

Embora os esforços de Petrov e Tower tenham sido fundamentais para o desenvolvimento do conceito de lubrificação hidrodinâmica, estes fundamentos foram desenvolvidos apenas de forma experimental. Foi apenas com Reynolds (1886) que os resultados experimentais de Tower foram descritos de forma matemática dando uma base científica sólida à teoria moderna de lubrificação.

Em seu artigo, Reynolds (1886) demonstrou que quando as superfícies estão completamente separadas por um filme lubrificante, o atrito é proporcional a viscosidade do fluido lubrificante, que tende a reduzir juntamente com o aumento da temperatura. O autor observou também que ocorre uma queda de pressão após o filme atingir a pressão máxima, levando a valores menores do que a pressão

atmosférica causando a ruptura do filme lubrificante. E ainda, estabeleceu que o limite de carga segura para uma lubrificação completa seria metade da diferença entre o raio do eixo e o raio do mancal, ou seja, metade da folga radial.

Ainda em seu artigo, Reynolds (1886) analisou um simples filme lubrificante entre superfícies planas ligeiramente inclinadas entre si. Ele idealizou que o lubrificante se adere à ambas as superfícies e, assim, será carregado pela superfície em movimento com velocidade para dentro de um espaço convergente em forma de cunha, gerando uma pressão no fluido com intensidade suficiente para suportar a carga do mancal. Esse fenômeno representa o princípio de funcionamento dos mancais hidrodinâmicos. Reynolds (1886) utilizou as equações de Navier-Stokes e a equação de continuidade para determinar a equação clássica de Reynolds, que se refere a uma equação diferencial parcial não homogênea capaz de descrever o comportamento do fluido lubrificante nas coordenadas circunferencial e axial do mancal, sendo a base fundamental para a teoria clássica da lubrificação.

A equação de Reynolds possui difícil solução devido as suas características. Uma das primeiras tentativas de solução analítica da equação partiu do próprio Reynolds considerando mancais infinitamente longos na forma de séries, porém o autor não obteve sucesso (NORTON, 2013).

Em seu único artigo publicado na área de lubrificação, o físico alemão Arnold Sommerfeld (1863 - 1951) desenvolveu uma solução analítica para a equação de Reynolds considerando o mancal infinitamente longo, onde supõe-se a inexistência de fluxo de óleo nas extremidades do mancal (SOMMERFELD, 1904). Esta solução analítica é conhecida como solução para o mancal infinitamente longo ou solução de Sommerfeld, porém, para pequenas razões de comprimento por diâmetro do mancal, as vazões de óleo nas extremidades devem ser consideradas (NORTON, 2013).

Os autores Ocvirk et al. publicaram quatro notas técnicas onde foram apresentadas uma nova solução analítica para a equação de Reynolds e investigações experimentais comparando os resultados analíticos com experimentais (DUBOIS; OCVIRK, 1955; DUBOIS et al., 1955; OCVIRK, 1952; DUBOIS; OCVIRK, 1953). Esta solução analítica é conhecida como solução para mancal curto ou solução de Ocvirk, onde supõe-se que o fluxo de óleo na direção circunferencial ao redor do mancal pode ser negligenciado em comparação com o fluxo de óleo na direção axial (NORTON, 2013).

Os autores Pinkus e Lynn (1956) foram os precursores no uso de métodos numéricos para a solução da equação de Reynolds considerando mancais de comprimento finito. A partir do método de diferenças finitas, os resultados obtidos são apresentados para diferentes tipos de mancais, com diferentes geometrias e condições de operação. Posteriormente, Raimondi e Boyd (1958) apresentaram diversos gráficos dessa solução numérica variando as características dos mancais, com intuito de facilitar a aplicação desses mancais hidrodinâmicos.

Com o avanço da tecnologia, os modelos de mancais hidrodinâmicos se tornaram cada vez mais completos. Este progresso permitiu um grande avanço na compreensão dos fenômenos físicos envolvidos, tais como os efeitos de cavitação (JAKOBSSON, 1957; OLSSON, 1965; FLOBERG, 1973), os efeitos térmicos (DOWSON, 1962; PARANJPE e HAN, 1990; 1995), análise termohidrodinâmica (THD) (CAMERON, 1951; BOUARD et al., 1996), interferência da rugosidade nas superfícies (PATIR e CHANG, 1978; 1979), considerações da elasticidade dos corpos no mancal (DOWSON et al., 1977; ZHANG, 1987), entre outros. Com isso, os modelos numéricos de mancais hidrodinâmicos ficaram ainda mais complexos, a fim de melhor representar esses efeitos e os parâmetros que influenciam a operação do mancal hidrodinâmico. Todavia, o aumento da complexidade dos modelos numéricos causa um aumento significativo no custo computacional da resolução numérica do problema, o que inviabiliza o seu emprego em diversas aplicações.

Desta forma, os modelos substitutos tendem a ganhar cada vez mais espaço dentro das análises dos mancais hidrodinâmicos, uma vez que estes modelos podem se ajustar a partir de um conjunto de amostras de um modelo original, garantindo a maior representatividade possível com um baixo custo computacional. As principais vantagens da aplicação de modelos substitutos em problemas computacionais complexos com enfoque na otimização dos projetos foram apresentadas por Wang et al. (2008). Neste trabalho, os autores mostraram a viabilidade da aplicação de métodos de otimização para obtenção dos melhores parâmetros de projeto.

O trabalho desenvolvido por Simpson et al. (2001) fez uma revisão de diferentes modelos substitutos aplicados a modelagem computacional determinística, destacando o Kriging, a rede neural artificial, a superfície de resposta e o aprendizado indutivo. Os métodos foram comparados, sobre a discussão das vantagens e desvantagens de cada método em sua escolha, indicando os cenários mais indicados para suas aplicações.

De acordo com Alpaydin (2014), as redes neurais artificiais são modelos computacionais não paramétricos utilizados para classificação e regressão. Elas são compostas de múltiplas unidades de processamento, denominadas neurônios artificiais, interligadas segundo um padrão de conexões inspirados pelo sistema nervoso central dos seres humanos. Segundo Haykin (2009), as redes neurais são adequadas para solução de problemas não lineares e com alto número de variáveis de entrada devido a sua capacidade de alterar os pesos sinápticos dentro dos neurônios para se adaptar ao ambiente.

O neurônio *perceptron* foi desenvolvido e publicado por Rosenblatt (1962). O algoritmo apresentado pelo autor é considerado o primeiro a descrever uma rede neural artificial. No entanto, a ideia de uma rede neural artificial foi proposta por McCulloch e Pitts (1943), com o primeiro modelo algébrico de um neurônio artificial, o qual é um caso particular do neurônio *perceptron* cujas entradas são binárias e a função de ativação é do tipo degrau.

Sinanoglu et al. (2004) apresentaram uma análise da variação do campo de pressão em mancais cilíndricos utilizando uma rede neural artificial. Os autores realizaram o treinamento da rede neural artificial com base nos resultados experimentais da diferença de pressão ao longo da circunferência do mancal, considerando o fluido lubrificante em diferentes temperaturas de operação e diferentes velocidades de rotação. Os autores concluíram que a rede neural apresentou um ajuste muito eficiente dos conjuntos de dados e que o modelo tem grande potencial para ser aplicado em mancais hidrodinâmicos.

Durak et al. (2008) avaliaram o efeito de um óleo com aditivo no coeficiente de atrito de mancais cilíndricos utilizando uma rede neural artificial. O conjunto de dados para treinamento da rede neural foi baseado em experimentos, tendo o carregamento aplicado, a velocidade de rotação e a concentração do aditivo no óleo como parâmetros de entrada, e o coeficiente de atrito como sendo a saída. A rede neural obteve um erro muito baixo com relação aos dados de treinamento e permitiu que os autores fizessem a análise do aditivo inserido no óleo do mancal cilíndrico por meio de predições.

Kornaev et al. (2017) compararam métodos para calcular as forças hidrodinâmicas e a resposta dinâmica do rotor com mancais cilíndricos. Os autores abordaram três métodos para solucionar a equação de Reynolds dependendo da posição e das velocidades de oscilação do centro do rotor: o método de trajetória, o

método de linearização e o método das redes neurais artificiais. Os autores consideraram que os métodos de linearização e a rede neural reduziram o custo computacional, no entanto a rede neural apresentou um melhor desempenho dos resultados.

As técnicas de aprendizado de máquina apresentam-se como uma ferramenta poderosa na detecção e diagnóstico de defeitos em máquinas rotativas baseados nos sinais de vibração (ZHANG et al., 2020). Um dos ramos de pesquisa que vem se destacando dentro desta área são técnicas de aprendizado profundo, as quais incorporam as redes neurais convolucionais. Estes algoritmos são uma expansão das redes neurais artificiais e foram criados com o intuito de realizar a classificação de sons e imagens.

Assim como as redes neurais artificiais, a inspiração da estrutura e funcionamento das redes neurais convolucionais estão relacionados ao funcionamento do cérebro animal (BISHOP, 2006). O conceito para aplicação do reconhecimento de padrões de imagens foi estabelecido por Fukushima (1980), onde o modelo *neocognitron* foi introduzido. Esta arquitetura de processamento de imagens inspiradas no córtex visual de mamíferos se tornou a base para as redes neurais convolucionais modernas (GOODFELLOW, 2016).

Um grande marco na história das redes neurais convolucionais é decorrente da introdução da arquitetura *LeNet-5*, apresentada por LeCun et al. (1998). A arquitetura da rede desenvolvida apresentava características conhecidas de redes neurais como, redes totalmente conectadas com funções de ativação sigmóides, no entanto, foi introduzido o conceito de camadas convolucionais e camadas de agrupamento construídas de forma hierárquica (BISHOP, 2006).

Segundo Géron (2019), graças ao aumento do poder computacional e a quantidade de dados disponível, as redes neurais convolucionais têm amadurecido cada vez mais para alcançar desempenho sobre-humano em algumas tarefas visuais complexas. De forma sucinta, as redes neurais convolucionais são redes neurais especializadas em processamento de dados em forma de grade, como uma imagem 2-D (GOODFELLOW et al., 2016).

Recentemente, muitos pesquisadores apresentaram excelentes resultados na detecção de defeitos utilizando as redes neurais convolucionais. Janssens et al. (2016) realizaram uma comparação entre uma rede neural convolucional e algoritmos de aprendizado de máquina convencionais para classificação que envolvem a

extração e seleção de atributos dos sinais de vibração. Dentre todos os algoritmos testados, a rede neural convolucional foi que obteve a maior taxa de acurácia.

Jeong et al. (2016) apresentaram uma rede neural convolucional capaz de reconhecer padrões do formato de órbitas de deslocamento. Neste trabalho, o algoritmo de aprendizado profundo foi treinado com um banco de dados de imagens adquirido experimentalmente em uma bancada de ensaios. Os dados de treinamento são formados por imagens de órbitas de deslocamento do centro do eixo em relação ao centro do mancal, contendo cinco classes diferentes. Os resultados obtidos apresentaram uma excelente acurácia com relação aos dados de teste, demonstrando a capacidade do reconhecimento de formas e padrões das redes neurais convolucionais.

Hoang e Kang (2018) avaliaram uma rede neural convolucional aplicada para realizar o diagnóstico de defeitos em mancais de rolamento utilizando imagens de vibração. Os autores converteram sinais de vibração de um banco de dados em imagens de vibração em escala cinza. O banco de dados contém sinais de vibração de mancais de rolamento em condições normais, com defeitos na esfera, com defeitos na pista interna e externa, sob diferentes intensidades totalizando 2024 imagens para treinamento e 400 para teste. A acurácia final das redes neurais convolucionais são comparadas com outros dois métodos e apresentam resultados excelentes.

Alves et al. (2020) aplicaram uma rede neural convolucional para realizar o diagnóstico de mancais hidrodinâmicos com ovalização. Os autores geraram dados sintetizados artificialmente para realizar o treinamento do algoritmo. Ainda, os dados gerados foram aumentados adicionando ruído branco gaussiano em 5 níveis de razão sinal-ruído. O aumento significativo do banco de dados com a adição de ruído elevou a acurácia na classificação de 76% para 96%.

Com base nos estudos disponíveis na literatura, é possível verificar os significativos avanços relacionados ao desenvolvimento de modelos substitutos obtidos nos últimos anos. Paralelamente, destacam-se também as crescentes conquistas realizadas na aplicação de técnicas de aprendizado de máquinas para a diagnose de falha em sistemas rotativos. Neste contexto, os desenvolvimentos obtidos nessas áreas devem ser avaliados em conjunto, a fim de estabelecer as melhores condições e abordagens para o monitoramento de máquinas rotativas. Como já sabido, não há banco de dados disponíveis para todos os tipos de defeitos em máquinas rotativas. Além disso, a construção desses bancos de dados através de

testes experimentais mostra-se também muito custoso, levando então a obtenção de dados via simulação computacional. Diante disso, o uso de modelos substitutos representa uma alternativa muito promissora, pois tende a reduzir o custo computacional envolvido nas simulações computacionais. Entretanto, não há uma definição estabelecida na literatura sobre quais métodos devem ser utilizados nos diferentes tipos de defeitos e tamanho dos bancos de dados e, conseqüentemente, o impacto dessas escolhas na acurácia da classificação dos defeitos nas máquinas. Por esse motivo, a presente pesquisa visa analisar comparativamente o desempenho de diferentes modelos substitutos para detecção de defeitos na aplicação em mancais hidrodinâmicos radiais, de forma a destacar as principais vantagens e desvantagens e, ainda, indicar qual modelo substituto mostra-se mais adequado com base no tamanho das amostras disponíveis.

### 3 METODOLOGIA

Este capítulo descreve os métodos e técnicas utilizados na fundamentação teórica do presente trabalho. Para tanto, são apresentadas as principais características dos mancais hidrodinâmicos cilíndricos e as considerações adotadas para a solução da equação de Reynolds adimensional pelo método dos volumes finitos e o cálculo das forças hidrodinâmicas por coeficientes equivalentes. Ademais, os conceitos básicos e a modelagem dinâmica de sistemas rotativos utilizando o método dos elementos finitos são também explanados. Ainda, são descritos os modelos substitutos via rede neural artificial, interpolação linear, cúbica e *spline* aplicados neste trabalho. Por fim, a classificação de defeitos em máquinas rotativas aplicando aprendizado profundo são abordados.

#### 3.1 Características do mancal hidrodinâmico cilíndrico

A Figura 3-1 ilustra uma seção de um conjunto mancal-eixo, apresentando algumas dimensões e referências importantes para a compreensão do funcionamento do mancal hidrodinâmico. Nesta figura,  $XYZ$  representa o referencial inercial localizado no centro do mancal  $O_M$ ,  $O_E$  representa o centro do eixo,  $e$  é a excentricidade, que é distância entre os centros do mancal e do eixo,  $\varphi$  é o ângulo de atitude, que é ângulo formado entre a linha de centros e o eixo vertical,  $\Omega$  é a velocidade de rotação e  $L$  é o comprimento axial (largura) do mancal.

Assim, para um conjunto em que o mancal tem um raio  $R_M$  e o eixo tem um raio  $R$ , a folga radial  $C_r$  é obtida conforme apresentada na Eq. (3.1).

$$C_r = R_M - R, \quad (3.1)$$

A partir da excentricidade do rotor ( $e$ ), pode-se então obter a razão de excentricidade como mostrado na Eq. (3.2).

$$\varepsilon = \frac{e}{C_r}. \quad (3.2)$$

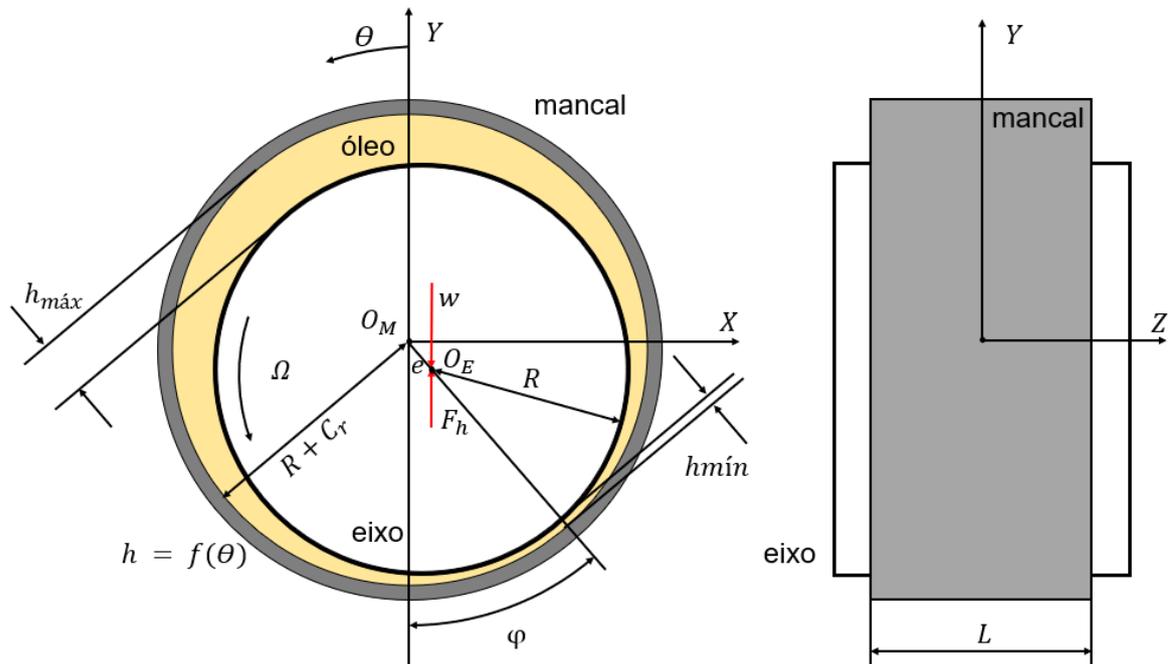


Figura 3-1: Representação de um mancal cilíndrico.

Fonte: Adaptado de Norton (2013).

Conforme descrito por Frene et al. (1997), a Eq. (3.3) apresenta a expressão para o cálculo da espessura do filme de óleo a partir da posição do eixo nas direções  $x$  e  $y$ .

$$h(\theta) = C_r + e_x \operatorname{sen} \theta - e_y \cos \theta, \quad (3.3)$$

onde  $e_x$  e  $e_y$  são as excentricidades do eixo nas direções  $X$  e  $Y$ , respectivamente. O valor de espessura máxima ( $h_{máx}$ ), se dá quando a coordenada circunferencial  $\theta$  é igual ao ângulo de atitude  $\varphi$ , enquanto o valor mínimo da espessura ( $h_{mín}$ ) ocorre no extremo oposto da linha entre centros. A variação da espessura do filme lubrificante no tempo pode ser obtida derivando a Eq. (3.3) no tempo, obtendo então:

$$\frac{\partial h}{\partial t} = \dot{e}_x \operatorname{sen} \theta - \dot{e}_y \cos \theta, \quad (3.4)$$

onde  $\dot{e}_x$  e  $\dot{e}_y$  são as velocidades das excentricidades nas direções  $X$  e  $Y$ , respectivamente.

### 3.2 Equação de Reynolds

O funcionamento saudável de máquinas rotativas pode ser associado a um desempenho adequado dos mancais, devido à forte influência deste componente no comportamento do rotor. Logo, a representação matemática do comportamento do fluido lubrificante no mancal tem grande importância para as simulações desenvolvidas das máquinas rotativas. A modelagem matemática de Reynolds permitiu avaliar a distribuição do campo de pressão ao longo do mancal, tornando possível determinar as forças hidrodinâmicas atuantes.

Para elaborar um modelo matemático, Reynolds se baseou em algumas considerações e hipóteses, tais como (SOMEYA, 1989):

- a) O lubrificante é um fluido Newtoniano;
- b) As forças de inércia do fluido podem ser negligenciadas;
- c) O fluido é incompressível;
- d) A viscosidade dinâmica do fluido é constante por todo o filme (filme isotérmico);
- e) A pressão não varia na direção radial, ou seja, através da espessura de filme;
- f) Não existe deslizamento nas interfaces fluido-sólido;
- g) O fluxo é laminar;
- h) O efeito da curvatura é assumido desprezível devido a pequena espessura do filme (NORTON, 2013).

Com base nessas hipóteses, Reynolds (1886) determinou a Eq. (3.5) conhecida como equação clássica de Reynolds, que se trata de uma equação diferencial parcial não homogênea cuja solução resulta no campo de pressão em função das coordenadas circunferencial e axial do mancal. Esta equação representa a base fundamental da teoria clássica de lubrificação.

$$\frac{\partial}{\partial x} \left( h^3 \frac{\partial P}{\partial x} \right) + \frac{\partial}{\partial z} \left( h^3 \frac{\partial P}{\partial z} \right) = 6\mu U \frac{\partial h}{\partial x} + 12\mu \frac{\partial h}{\partial t}, \quad (3.5)$$

onde  $\mu$  indica a viscosidade dinâmica do fluido lubrificante,  $h$  é a espessura do filme,  $P$  é a pressão hidrodinâmica desenvolvida no mancal,  $U$  é a velocidade linear na superfície do eixo e  $(x, z)$  são as coordenadas circunferencial e axial, respectivamente.

### 3.3 Solução Numérica da Equação de Reynolds

A equação de Reynolds possui solução analítica mesmo em sua forma completa para mancais que possuem razão  $L/D$  entre 0,25 e 4, conforme proposto por Sfyris e Chasalevris (2012). No entanto, esta abordagem propõem uma solução de elevada complexidade, em que a equação de Reynolds é dividida em quatro equações diferenciais ordinárias lineares de segunda ordem com coeficientes não constantes, sendo que três equações possuem formas diretas de solução analítica e na última delas deve ser empregado o método de séries de potências. Além disso, essa solução não considera os efeitos de cavitação no filme de óleo, resultando em uma distribuição de pressão com picos antissimétricos, sendo que o pico de pressão negativo deve ser então assumido como nulo a posteriori. Desta forma, essa abordagem de alta complexidade, juntamente com a simplificação de cavitação imposta na resolução, justifica ainda a utilização de métodos numéricos em trabalhos recentes da literatura (RAMOS, 2019).

De forma geral, existem duas principais soluções numéricas empregadas atualmente para resolver a equação de Reynolds: Método dos Volumes Finitos (MVF) e o Método das Diferenças Finitas (MDF). Segundo Kolditz (2002), o MVF possui duas vantagens em relação ao MDF. A primeira vantagem é que ele impõe a conservação de quantidades de níveis discretizados, como massa e energia, já a segunda vantagem é que o MVF tem um desempenho melhor para resolver malhas arbitrárias de geometrias complexas quando comparado com o MDF. Neste trabalho, foi utilizado o MVF para resolver a equação de Reynolds, tomando como base o trabalho realizado por Cunha (2019).

Para obter a solução da equação de Reynolds pelo MVF é necessário dividir o domínio do mancal em um número finito de volumes de controle, conforme apresentado na Figura 3-2. O domínio do mancal é dividido em  $N_x$  volumes de comprimento  $\Delta x$  na coordenada circunferencial  $x$ , cujo comprimento total é de  $2\pi R$ , e em  $N_z$  volumes de comprimento  $\Delta z$  na coordenada axial  $z$ , cujo comprimento total é de  $L$ . A resolução da Eq. (3.5) é realizada através da integração em um volume de controle genérico  $P$ , conforme indicado pela Figura 3-2.

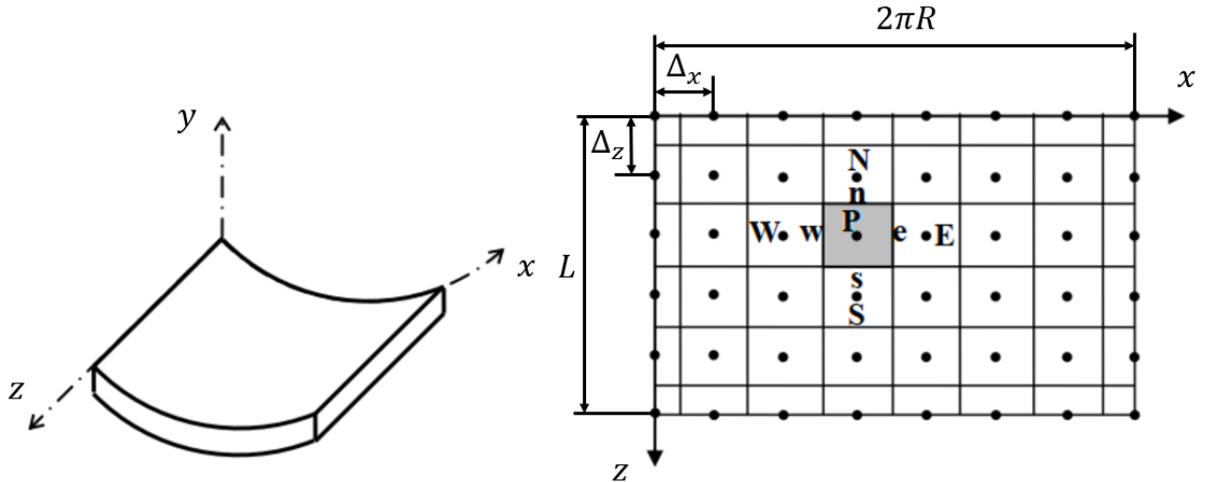


Figura 3-2: Definição de malha computacional genérica para determinar a pressão.

Fonte: Adaptado de Daniel (2012).

Nesta figura, os pontos representam os centros de cada volume de controle. Como mostrado na Figura 3-2 cada volume interior possui quatro volumes vizinhos ( $W, E, S, N$ ) e são limitados por quatro fronteiras ( $w, e, s, n$ ). Essas notações  $W, E, S$  e  $N$  indicam as direções oeste, leste, sul e norte, respectivamente. A Eq. (3.5) é resolvida considerando como condição de contorno a pressão atmosférica (pressão ambiente) nas fronteiras laterais do mancal, ou seja, pressão hidrodinâmica nula nessas laterais, e a condição de circularidade do domínio do mancal, ou seja, a última coluna da malha é igual a primeira.

Neste trabalho, será realizado a adimensionalização da equação de Reynolds, assumindo então:

$$\bar{h} = \frac{h}{C_r} \quad (3.6)$$

$$\bar{x} = \frac{x}{2\pi R} \quad (3.7)$$

$$\bar{z} = \frac{z}{L} \quad (3.8)$$

$$\bar{t} = t\Omega \quad (3.9)$$

$$\Delta\bar{x} = \frac{\Delta x}{2\pi R} \quad (3.10)$$

$$\Delta\bar{z} = \frac{\Delta z}{L} \quad (3.11)$$

$$\bar{P} = \frac{P}{\mu\Omega} \left(\frac{C_r}{R}\right)^2 \quad (3.12)$$

$$\bar{e}_x = \frac{\dot{e}_x}{C_r\Omega} \quad (3.13)$$

$$\bar{e}_y = \frac{\dot{e}_y}{C_r\Omega} \quad (3.14)$$

Este procedimento será adotado para obter algumas vantagens na solução da equação de Reynolds, tal como a não dependência da viscosidade dinâmica do óleo. Aplicando as Eq. (3.6) - (3.12) na Eq. (3.5), obtém-se a Eq. (3.15) na forma adimensional. Apenas para facilitar o desenvolvimento da solução pelo método dos volumes finitos, a equação de Reynolds adimensional é reescrita dividindo-a em 4 termos:

$$\underbrace{\left(\frac{1}{48\pi^2}\right) \frac{\partial}{\partial\bar{x}} \left[\bar{h}^3 \frac{\partial\bar{P}}{\partial\bar{x}}\right]}_A + \underbrace{\left(\frac{R^2}{12L^2}\right) \frac{\partial}{\partial\bar{z}} \left[\bar{h}^3 \frac{\partial\bar{P}}{\partial\bar{z}}\right]}_B = \underbrace{\frac{1}{4\pi} \frac{\partial\bar{h}}{\partial\bar{x}}}_C + \underbrace{\frac{\partial\bar{h}}{\partial\bar{t}}}_D \quad (3.15)$$

Primeiramente, integrando o termo  $A$  da Eq. (3.15) para um volume genérico  $\bar{P}$ , tem-se:

$$\int_s^n \int_w^e \left(\frac{1}{48\pi^2}\right) \frac{\partial}{\partial\bar{x}} \left(\bar{h}^3 \frac{\partial\bar{P}}{\partial\bar{x}}\right) d\bar{x} d\bar{z} = \left(\frac{1}{48\pi^2}\right) \int_s^n \left[ \left(\bar{h}_e^3 \frac{\partial\bar{P}}{\partial\bar{x}}\right)_e - \left(\bar{h}_w^3 \frac{\partial\bar{P}}{\partial\bar{x}}\right)_w \right] d\bar{z}, \quad (3.16)$$

$$\left(\frac{1}{48\pi^2}\right) \int_s^n \left[ \left(\bar{h}_e^3 \frac{\partial\bar{P}}{\partial\bar{x}}\right)_e - \left(\bar{h}_w^3 \frac{\partial\bar{P}}{\partial\bar{x}}\right)_w \right] d\bar{z} = \left(\frac{\Delta\bar{z}}{48\pi^2}\right) \left[ \bar{h}_e^3 \frac{\partial\bar{P}}{\partial\bar{x}}\right)_e - \bar{h}_w^3 \frac{\partial\bar{P}}{\partial\bar{x}}\right)_w \right] \quad (3.17)$$

A variação da pressão nas fronteiras do volume  $\bar{P}$  pode ser aproximada pelo método de diferença central:

$$\left. \frac{\partial \bar{P}}{\partial \bar{x}} \right|_e = \frac{\bar{P}_E - \bar{P}_P}{\Delta \bar{x}}; \quad \left. \frac{\partial \bar{P}}{\partial \bar{x}} \right|_w = \frac{\bar{P}_P - \bar{P}_W}{\Delta \bar{x}}; \quad \left. \frac{\partial \bar{P}}{\partial \bar{z}} \right|_n = \frac{\bar{P}_N - \bar{P}_P}{\Delta \bar{z}}; \quad \left. \frac{\partial \bar{P}}{\partial \bar{z}} \right|_s = \frac{\bar{P}_P - \bar{P}_S}{\Delta \bar{z}} \quad (3.18)$$

Substituindo a Eq. (3.18) na Eq. (3.17), obtêm-se:

$$\begin{aligned} \int_s^n \int_w^e \left( \frac{1}{48\pi^2} \right) \frac{\partial}{\partial \bar{x}} \left( \bar{h}^3 \frac{\partial \bar{P}}{\partial \bar{x}} \right) d\bar{x} d\bar{z} \\ = -\frac{\bar{P}_P}{48\pi^2} \left( \bar{h}_e^3 \frac{\Delta \bar{z}}{\Delta \bar{x}} + \bar{h}_w^3 \frac{\Delta \bar{z}}{\Delta \bar{x}} \right) + \frac{\bar{P}_E}{48\pi^2} \bar{h}_e^3 \frac{\Delta \bar{z}}{\Delta \bar{x}} + \frac{\bar{P}_W}{48\pi^2} \bar{h}_w^3 \frac{\Delta \bar{z}}{\Delta \bar{x}} \end{aligned} \quad (3.19)$$

Analogamente, para os termos  $B, C$  e  $D$  obtêm-se, respectivamente:

$$\begin{aligned} \int_w^e \int_s^n \left( \frac{1}{48\pi^2} \right) \frac{\partial}{\partial \bar{z}} \left( \bar{h}^3 \frac{\partial \bar{P}}{\partial \bar{z}} \right) d\bar{z} d\bar{x} \\ = -\frac{\bar{P}_P R^2}{12L^2} \left( \bar{h}_n^3 \frac{\Delta \bar{x}}{\Delta \bar{z}} + \bar{h}_s^3 \frac{\Delta \bar{x}}{\Delta \bar{z}} \right) + \frac{\bar{P}_N R^2}{12L^2} \bar{h}_n^3 \frac{\Delta \bar{x}}{\Delta \bar{z}} + \frac{\bar{P}_S R^2}{12L^2} \bar{h}_s^3 \frac{\Delta \bar{x}}{\Delta \bar{z}} \end{aligned} \quad (3.20)$$

$$\int_s^n \int_w^e \frac{1}{4\pi} \frac{\partial \bar{h}}{\partial \bar{x}} d\bar{x} d\bar{z} = \frac{\Delta \bar{z}}{4\pi} (\bar{h}_e - \bar{h}_w) \quad (3.21)$$

$$\int_s^n \int_w^e \frac{\partial \bar{h}}{\partial \bar{t}} d\bar{x} d\bar{z} = (\bar{e}_x \sin(\varphi) - \bar{e}_y \cos(\varphi)) \Delta \bar{x} \Delta \bar{z} \quad (3.22)$$

Reagrupando as Eq. (3.19) - (3.22) na Eq. (3.15), obtêm-se:

$$\begin{aligned} -\frac{\bar{P}_P}{48\pi^2} \left( \bar{h}_e^3 \frac{\Delta \bar{z}}{\Delta \bar{x}} + \bar{h}_w^3 \frac{\Delta \bar{z}}{\Delta \bar{x}} \right) + \frac{\bar{P}_E}{48\pi^2} \bar{h}_e^3 \frac{\Delta \bar{z}}{\Delta \bar{x}} + \frac{\bar{P}_W}{48\pi^2} \bar{h}_w^3 \frac{\Delta \bar{z}}{\Delta \bar{x}} - \frac{\bar{P}_P R^2}{12L^2} \left( \bar{h}_n^3 \frac{\Delta \bar{x}}{\Delta \bar{z}} + \bar{h}_s^3 \frac{\Delta \bar{x}}{\Delta \bar{z}} \right) \\ + \frac{\bar{P}_N R^2}{12L^2} \bar{h}_n^3 \frac{\Delta \bar{x}}{\Delta \bar{z}} + \frac{\bar{P}_S R^2}{12L^2} \bar{h}_s^3 \frac{\Delta \bar{x}}{\Delta \bar{z}} \\ = \frac{\Delta \bar{z}}{4\pi} (\bar{h}_e - \bar{h}_w) - (\bar{e}_x \sin(\varphi) - \bar{e}_y \cos(\varphi)) \Delta \bar{x} \Delta \bar{z} \end{aligned} \quad (3.23)$$

A Eq. (3.23) pode ser reescrita na forma simplificada:

$$\bar{P}_P = \frac{\bar{P}_E C_E + \bar{P}_W C_W + \bar{P}_N C_N + \bar{P}_S C_S + B_P}{C_P} \quad (3.24)$$

sendo:

$$\begin{aligned} C_E &= \frac{\bar{h}_e^3}{48\pi^2} \frac{\Delta\bar{z}}{\Delta\bar{x}} \\ C_W &= \frac{\bar{h}_w^3}{48\pi^2} \frac{\Delta\bar{z}}{\Delta\bar{x}} \\ C_N &= \frac{\bar{h}_n^3 R^2}{12L^2} \frac{\Delta\bar{x}}{\Delta\bar{z}} \\ C_S &= \frac{\bar{h}_s^3 R^2}{12L^2} \frac{\Delta\bar{x}}{\Delta\bar{z}} \end{aligned} \quad (3.25)$$

$$\begin{aligned} C_P &= C_E + C_W + C_N + C_S = \frac{\bar{h}_e^3}{48\pi^2} \frac{\Delta\bar{z}}{\Delta\bar{x}} + \frac{\bar{h}_w^3}{48\pi^2} \frac{\Delta\bar{z}}{\Delta\bar{x}} + \frac{\bar{h}_n^3 R^2}{12L^2} \frac{\Delta\bar{x}}{\Delta\bar{z}} + \frac{\bar{h}_s^3 R^2}{12L^2} \frac{\Delta\bar{x}}{\Delta\bar{z}} \\ B_P &= \frac{\Delta\bar{z}}{4\pi} (\bar{h}_e - \bar{h}_w) - (\bar{e}_x \sin(\varphi) - \bar{e}_y \cos(\varphi)) \Delta\bar{x} \Delta\bar{z} \end{aligned}$$

A integração do campo de pressão no domínio do mancal é realizada de forma iterativa através do método Gauss-Seidel, utilizando as Eq. (3.24) e (3.25). O erro entre as iterações é calculado pela diferença total entre os campos de pressão da iteração atual com a iteração anterior, conforme mostrado na Eq. (3.26):

$$E_{\text{pressão}} = \sum_{l=1}^{N_x} \sum_{k=1}^{N_z} |\bar{P}_{(l,k)iter} - \bar{P}_{(l,k)iter-1}| \quad (3.26)$$

Após o cálculo do campo de pressão, as forças hidrodinâmicas atuantes no mancal são calculadas. A Eq. (3.27) apresenta a decomposição das forças hidrodinâmicas adimensionais  $\bar{F}_X$  e  $\bar{F}_Y$  nas direções  $X$  e  $Y$  do sistema de referencial inercial, conforme apresentado na Figura 3-1.

$$\begin{aligned} \bar{F}_X &= \int_0^{2\pi R} \int_0^L \bar{P}(x, z) \text{sen } \theta \, dz \, dx = \sum_{l=1}^{N_x} \sum_{k=1}^{N_z} \bar{P}_{(l,k)} \text{sen } \theta_l \, \Delta x \Delta z \\ \bar{F}_Y &= \int_0^{2\pi R} \int_0^L -\bar{P}(x, z) \text{cos } \theta \, dz \, dx = \sum_{l=1}^{N_x} \sum_{k=1}^{N_z} -\bar{P}_{(l,k)} \text{cos } \theta_l \, \Delta x \Delta z \end{aligned} \quad (3.27)$$

A Eq. (3.28) apresenta as forças hidrodinâmicas dimensionais, obtidas a partir da Eq. (3.12). A equação de Reynolds trata-se de uma equação não linear, logo, as forças hidrodinâmicas obtidas a partir da sua solução são forças não lineares.

$$\begin{aligned} F_X &= \bar{F}_X \frac{\mu \Omega R^2}{C_r^2} \\ F_Y &= \bar{F}_Y \frac{\mu \Omega R^2}{C_r^2} \end{aligned} \quad (3.28)$$

Com a solução da equação de Reynolds é possível determinar a posição de equilíbrio estático do centro do eixo em relação ao centro do mancal. O equilíbrio estático ocorre quando o somatório das forças internas é igual ao somatório das forças externas, ou seja, quando as cargas radiais aplicadas ao mancal são iguais as forças hidrodinâmicas em todas as direções. Este lugar geométrico é conhecido como curva de Lócus, conforme apresentado na Figura 3-3, onde é possível verificar que para baixas rotações, o ponto de equilíbrio estático do centro do eixo está próximo do limite da folga radial e com o aumento da rotação, a sustentação é mais efetiva, garantindo que o eixo se posicione ao centro do mancal.

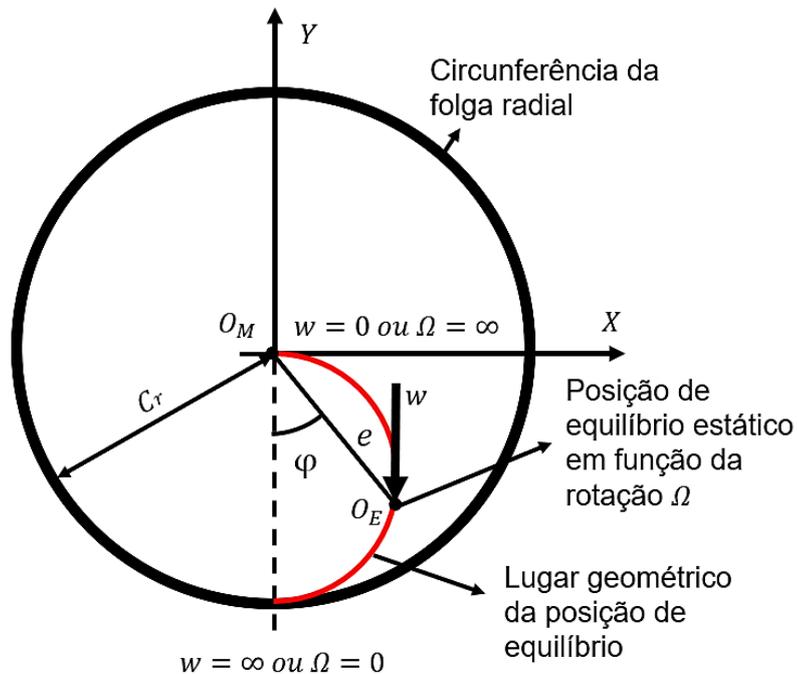


Figura 3-3: Esquema ilustrativo da curva de lócus.

Fonte: Adaptado de Pedreira (2006).

Conforme apresentado na Figura 3-3, a curva de Locus não depende somente da velocidade de rotação do eixo, visto que as características do mancal e a carga radial aplicada também influenciam na posição de equilíbrio. Entretanto, considerando uma carga constante aplicada em um dado mancal, as análises da posição de equilíbrio são comumente apresentadas variando apenas a velocidade de rotação do eixo enquanto os outros parâmetros permanecem constantes.

### 3.4 Cálculo dos coeficientes equivalentes de rigidez e amortecimento

Com a posição de equilíbrio estática do eixo definida, ao provocar uma pequena perturbação no eixo em relação ao mancal, toda a camada de filme lubrificante é deslocada. Esta perturbação do equilíbrio pode ser representada numericamente por um sistema de dois graus de liberdade, relacionando o deslocamento e velocidade do eixo com os coeficientes de rigidez e amortecimento do fluido lubrificante, conforme ilustra a Figura 3-4. Segundo Dimond et al. (2009) as forças de inércia podem ser desprezadas para um fluxo laminar de fluido lubrificante com folgas muito pequenas.

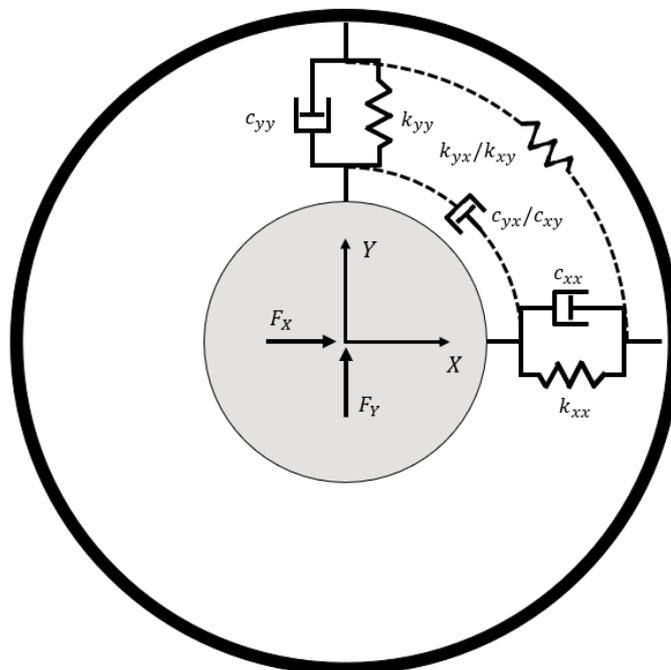


Figura 3-4: Modelo físico de um mancal hidrodinâmico.

Fonte: Adaptado de Nasselqvist (2011).

Conforme descrito na seção anterior, as características do mancal e o movimento de translação e rotação do eixo dentro da folga radial do mancal resulta em um campo de pressão que gera as forças hidrodinâmicas. Entretanto, conforme proposto por Lund (1964, 1987), as forças hidrodinâmicas podem ser linearizadas, representando-as através de uma expansão em série de Taylor de primeira ordem quando a órbita do eixo ocorre ao redor da posição de equilíbrio estático com amplitude e velocidade significativamente pequenas. Isto é, a descrição das forças hidrodinâmicas pode ser realizada apenas com a posição e velocidade do eixo:

$$\begin{aligned} F_X &= F_{X0} + K_{xx}\Delta e_X + K_{xy}\Delta e_Y + C_{xx}\Delta \dot{e}_X + C_{xy}\Delta \dot{e}_Y \\ F_Y &= F_{Y0} + K_{yx}\Delta e_X + K_{yy}\Delta e_Y + C_{yx}\Delta \dot{e}_X + C_{yy}\Delta \dot{e}_Y \end{aligned} \quad (3.29)$$

Sendo assim, o filme lubrificante comporta-se como um conjunto de molas e amortecedores lineares, cuja matriz de coeficientes equivalentes de rigidez,  $\mathbf{K}_m$ , e amortecimento,  $\mathbf{C}_m$ , são as derivadas parciais das forças hidrodinâmicas em relação ao deslocamento e velocidade, respectivamente, avaliadas na posição de equilíbrio estático:

$$\mathbf{K}_m = \begin{bmatrix} K_{xx} & K_{xy} \\ K_{yx} & K_{yy} \end{bmatrix} = \begin{bmatrix} \frac{\partial F_X}{\partial X} & \frac{\partial F_X}{\partial Y} \\ \frac{\partial F_Y}{\partial X} & \frac{\partial F_Y}{\partial Y} \end{bmatrix}_0 \quad (3.30)$$

$$\mathbf{C}_m = \begin{bmatrix} C_{xx} & C_{xy} \\ C_{yx} & C_{yy} \end{bmatrix} = \begin{bmatrix} \frac{\partial F_X}{\partial \dot{X}} & \frac{\partial F_X}{\partial \dot{Y}} \\ \frac{\partial F_Y}{\partial \dot{X}} & \frac{\partial F_Y}{\partial \dot{Y}} \end{bmatrix}_0 \quad (3.31)$$

Os coeficientes  $K_{xx}$ ,  $K_{yy}$ ,  $C_{xx}$  e  $C_{yy}$  cuja perturbação e força são associadas na mesma direção, são conhecidos como coeficientes diretos, enquanto os coeficientes  $K_{xy}$ ,  $K_{yx}$ ,  $C_{xy}$  e  $C_{yx}$ , que relacionam perturbações e forças em diferentes direções são conhecidos como coeficientes cruzados (SOMEYA, 1989). Conforme apresentado por Cunha (2019), os coeficientes equivalentes de rigidez podem ser obtidos através da solução numérica da Eq.(3.30) pelo método das diferenças finitas através de pequenas perturbações de deslocamento ( $\Delta e_X$  e  $\Delta e_Y$ ) nas direções  $X$  e  $Y$ , respectivamente, com o eixo centrado na posição de equilíbrio estático:

$$\begin{aligned}
K_{xx} &= \left( \frac{\partial F_X}{\partial X} \right)_0 \approx \frac{F_X^{e_{X_0} - \Delta e_X, e_{Y_0}} - F_X^{e_{X_0} + \Delta e_X, e_{Y_0}}}{2\Delta e_X} \\
K_{xy} &= \left( \frac{\partial F_X}{\partial Y} \right)_0 \approx \frac{F_X^{e_{X_0, e_{Y_0} - \Delta e_Y} - F_X^{e_{X_0, e_{Y_0} + \Delta e_Y}}}{2\Delta e_Y} \\
K_{yx} &= \left( \frac{\partial F_Y}{\partial X} \right)_0 \approx \frac{F_Y^{e_{X_0} - \Delta e_X, e_{Y_0}} - F_Y^{e_{X_0} + \Delta e_X, e_{Y_0}}}{2\Delta e_X} \\
K_{yy} &= \left( \frac{\partial F_Y}{\partial Y} \right)_0 \approx \frac{F_Y^{e_{X_0, e_{Y_0} - \Delta e_Y} - F_Y^{e_{X_0, e_{Y_0} + \Delta e_Y}}}{2\Delta e_Y}
\end{aligned} \tag{3.32}$$

onde o subscrito de  $F$  indica a direção da força resultante e o sobrescrito de  $F$  indica onde as perturbações na posição do eixo são aplicadas. Analogamente, os coeficientes equivalentes de amortecimento são determinados através de perturbações na velocidade ( $\Delta \dot{e}_X$  e  $\Delta \dot{e}_Y$ ), sendo, neste caso, que o equilíbrio estático ocorre com velocidades nulas, logo:

$$\begin{aligned}
C_{xx} &= \left( \frac{\partial F_X}{\partial \dot{X}} \right)_0 \approx \frac{F_X^{-\Delta \dot{e}_X} - F_X^{\Delta \dot{e}_X}}{2\Delta \dot{e}_X} \\
C_{xy} &= \left( \frac{\partial F_X}{\partial \dot{Y}} \right)_0 \approx \frac{F_X^{-\Delta \dot{e}_Y} - F_X^{\Delta \dot{e}_Y}}{2\Delta \dot{e}_Y} \\
C_{yx} &= \left( \frac{\partial F_Y}{\partial \dot{X}} \right)_0 \approx \frac{F_Y^{-\Delta \dot{e}_X} - F_Y^{\Delta \dot{e}_X}}{2\Delta \dot{e}_X} \\
C_{yy} &= \left( \frac{\partial F_Y}{\partial \dot{Y}} \right)_0 \approx \frac{F_Y^{-\Delta \dot{e}_Y} - F_Y^{\Delta \dot{e}_Y}}{2\Delta \dot{e}_Y}
\end{aligned} \tag{3.33}$$

### 3.5 Modelagem de sistemas rotativos pelo método dos elementos finitos

Os elementos típicos que compõem um rotor flexível são os discos rígidos discretos, os segmentos de eixo com massa e elasticidade distribuídas, os mancais de apoio, os selos de fluxo, os acoplamentos e a fundação. Este sistema é ilustrado na Figura 3-5, sendo  $XYZ$  o mesmo sistema inercial utilizado na análise do mancal (Figura 3-1). O referencial móvel  $X'Y'Z'$  é determinado a partir da rotação de um ângulo  $\omega t$  em torno do eixo longitudinal, com  $\omega$  sendo a rotação de precessão do rotor. Segundo Tuckmantel (2010), os vetores de deslocamento angulares ( $B, \tau$ ) são considerados aproximadamente colineares com os eixos ( $X, Y$ ) para pequenas

deformações transversais. Ademais, a deformação torcional considerada como  $T$  pode ser considerada desprezível para uma velocidade constante do sistema.

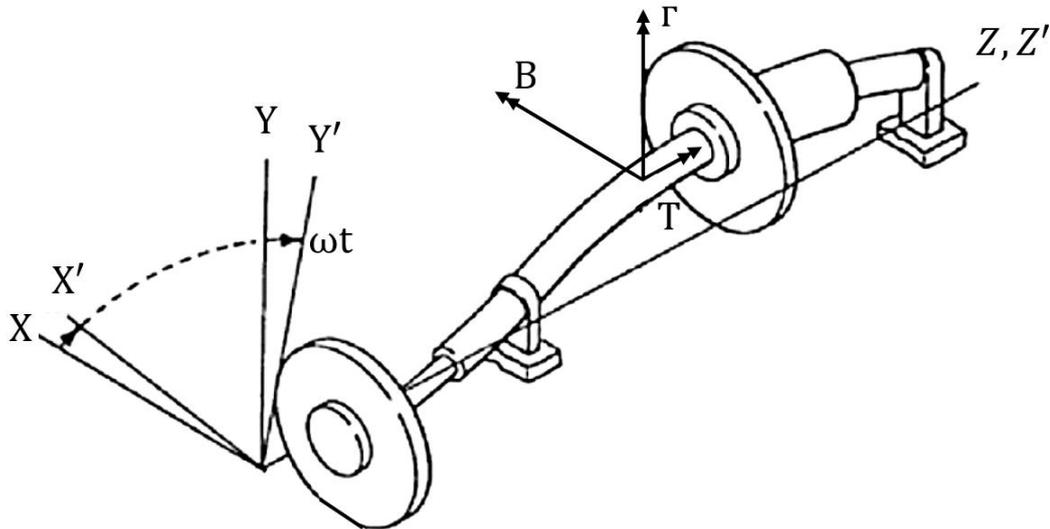


Figura 3-5: Configuração típica de um sistema rotativo.

Fonte: Adaptado de Nelson e McVaugh (1976).

Neste trabalho, o modelo matemático do rotor é desenvolvido pelo Método dos Elementos Finitos (MEF), em que o domínio do rotor é discretizado em elementos finitos contínuos, conforme proposto por Nelson e McVaugh (1976). Segundo Pedreira (2006), a análise do comportamento dinâmico pelo MEF é essencial para o projeto de rotores, pois é possível estimar parâmetros como as velocidades críticas<sup>1</sup> e o limiar de estabilidade<sup>2</sup>.

De acordo com Tuckmantel (2010), a modelagem de um sistema contínuo pelo MEF é realizada por um conjunto finito de elementos que podem ser considerados contínuos individualmente, sendo que cada elemento discreto é ligado ao outro através de nós. Logo, é possível calcular a energia cinética ( $T_{e_i}$ ), energia de deformação ( $U_{e_i}$ ) e o termo de dissipação de energia ( $R_{e_i}$ ) de cada elemento  $i$ , em função dos deslocamentos dos nós em sua fronteira, conforme apresentado pela Eq. (3.34). Portanto, para uma estrutura com  $N_e$  elementos, a soma das energias de cada elemento determina a energia estrutural global.

<sup>1</sup> Velocidade crítica refere-se à velocidade na qual a frequência de rotação é igual a uma das frequências naturais do rotor (RAO, 2011).

<sup>2</sup> Limiar de estabilidade refere-se à velocidade limite de operação do sistema devido ao surgimento de vibrações auto-excitadas (GENTA, 2005).

$$T_e = \sum_{i=1}^{N_e} T_{e_i}; \quad U_e = \sum_{i=1}^{N_e} U_{e_i}; \quad R_e = \sum_{i=1}^{N_e} R_{e_i}. \quad (3.34)$$

A energia cinética, a energia de deformação e o trabalho das forças não-conservativas globais são escritas como (NELSON e MCVAUGH, 1976):

$$T_e = \frac{1}{2} \{\dot{\mathbf{q}}\}^T [\mathbf{M}] \{\dot{\mathbf{q}}\} - \Omega \{\dot{\mathbf{q}}\}^T [\mathbf{G}] \{\mathbf{q}\} + \frac{1}{2} I_p \Omega^2 \quad (3.35)$$

$$U_e = \frac{1}{2} \{\mathbf{q}\}^T [\mathbf{K}] \{\mathbf{q}\} \quad (3.36)$$

$$R_e = \frac{1}{2} \{\dot{\mathbf{q}}\}^T [\mathbf{C}] \{\dot{\mathbf{q}}\} \quad (3.37)$$

Lalanne e Ferraris (1990) descrevem detalhadamente a determinação da equação de movimento por meio da equação de Lagrange, como apresentada na Eq. (3.38).

$$\frac{d}{dt} \left( \frac{\partial T_e}{\partial \dot{q}_i} \right) - \left( \frac{\partial T_e}{\partial q} \right) + \left( \frac{\partial U_e}{\partial q_i} \right) + \left( \frac{\partial R_e}{\partial \dot{q}_i} \right) = F_i, \quad (3.38)$$

Nesta equação,  $q_i$  e sua derivada são coordenadas generalizadas do sistema e  $F_i$  é a força generalizada atuando na direção da  $i$ -ésima coordenada generalizada para  $i = 1, 2, \dots, N_e$ . Sendo assim, cada coordenada generalizada possui uma equação de movimento, resultando então em um sistema de equações diferenciais, cuja solução determina o comportamento dinâmico do rotor.

Aplicando as relações das equações da energia cinética, da energia de deformação e do trabalho das forças não-conservativas na equação de Lagrange, obtém-se a equação de movimento do sistema, conforme apresentada na Eq. (3.39).

$$[\mathbf{M}_{global}] \{\ddot{\mathbf{q}}\} + ([\mathbf{C}_{global}] + \Omega [\mathbf{G}_{global}]) \{\dot{\mathbf{q}}\} + [\mathbf{K}_{global}] \{\mathbf{q}\} = \{\mathbf{f}_{global}\}, \quad (3.39)$$

onde  $M_{global}$ ,  $C_{global}$ ,  $G_{global}$  e  $K_{global}$  são as matrizes globais de massa, amortecimento, giroscópica e rigidez, respectivamente,  $f_{global}$  é o vetor de excitação externa e  $q, \dot{q}, \ddot{q}$  são respectivamente os vetores de deslocamento, velocidade e aceleração relativo ao sistema de referência inercial.

Geralmente nos casos práticos de eixos rotativos é possível fazer uma combinação linear das matrizes de massa,  $M_{global}$ , e de rigidez,  $K_{global}$ , para determinar a matriz de amortecimento proporcional,  $C_{global}$ , conforme mostrado na Eq. (3.40):

$$[C_{global}] = \alpha[M_{global}] + \beta[K_{global}] \quad (3.40)$$

sendo  $\alpha$  o coeficiente de proporcionalidade para a massa e  $\beta$  o coeficiente de proporcionalidade para a rigidez. Este tipo de amortecimento é conhecido como amortecimento estrutural proporcional e, apesar de ser uma aproximação, é capaz de representar uma ampla gama de sistemas de maneira satisfatória, como por exemplo, eixos rotativos de aço.

As matrizes globais do rotor são capazes de indicar a distribuição de massa, rigidez, efeito giroscópico e amortecimento ao longo do rotor, incluindo diferentes efeitos de cada elemento do domínio discretizado. As matrizes globais são formadas pela sobreposição das matrizes dos elementos de eixo e elementos de disco. A descrição das matrizes do elemento de eixo e das matrizes do elemento de disco são apresentadas por Ehrich (1992) e são baseadas nos trabalhos desenvolvidos por Nelson e McVaugh (1976) e Nelson (1980).

A modelagem do eixo por um conjunto de elementos de vigas é comumente aplicada em dinâmica de rotores. Tais vigas geralmente são prismáticas e homogêneas, ou seja, suas características geométricas e propriedades do material são constantes ao longo de seu comprimento, tornando possível a utilização de métodos com modelos contínuos, baseados nos elementos de viga.

A teoria de viga de Euler-Bernoulli despreza a deformação causada pelo esforço cortante, ou seja, as seções transversais permanecem planas e normal ao eixo da viga. Outro modelo de viga utilizado é o modelo conhecido como elemento de viga de Timoshenko, cuja principal diferença está relacionada a consideração do

cisalhamento da viga, no qual as seções transversais deixam de ser planas e normais ao eixo (LALANNE e FERRARIS, 1990). Dentre os modelos clássicos, o modelo de viga empregado neste trabalho foi o de Timoshenko.

Após determinar as matrizes dos elementos de eixo e disco, as matrizes globais são então construídas a partir da sobreposição das matrizes elementares nos respectivos graus de liberdade das matrizes globais. A Figura 3-6 indica como a montagem da matriz global é realizada, a partir da sobreposição das matrizes dos elementos.

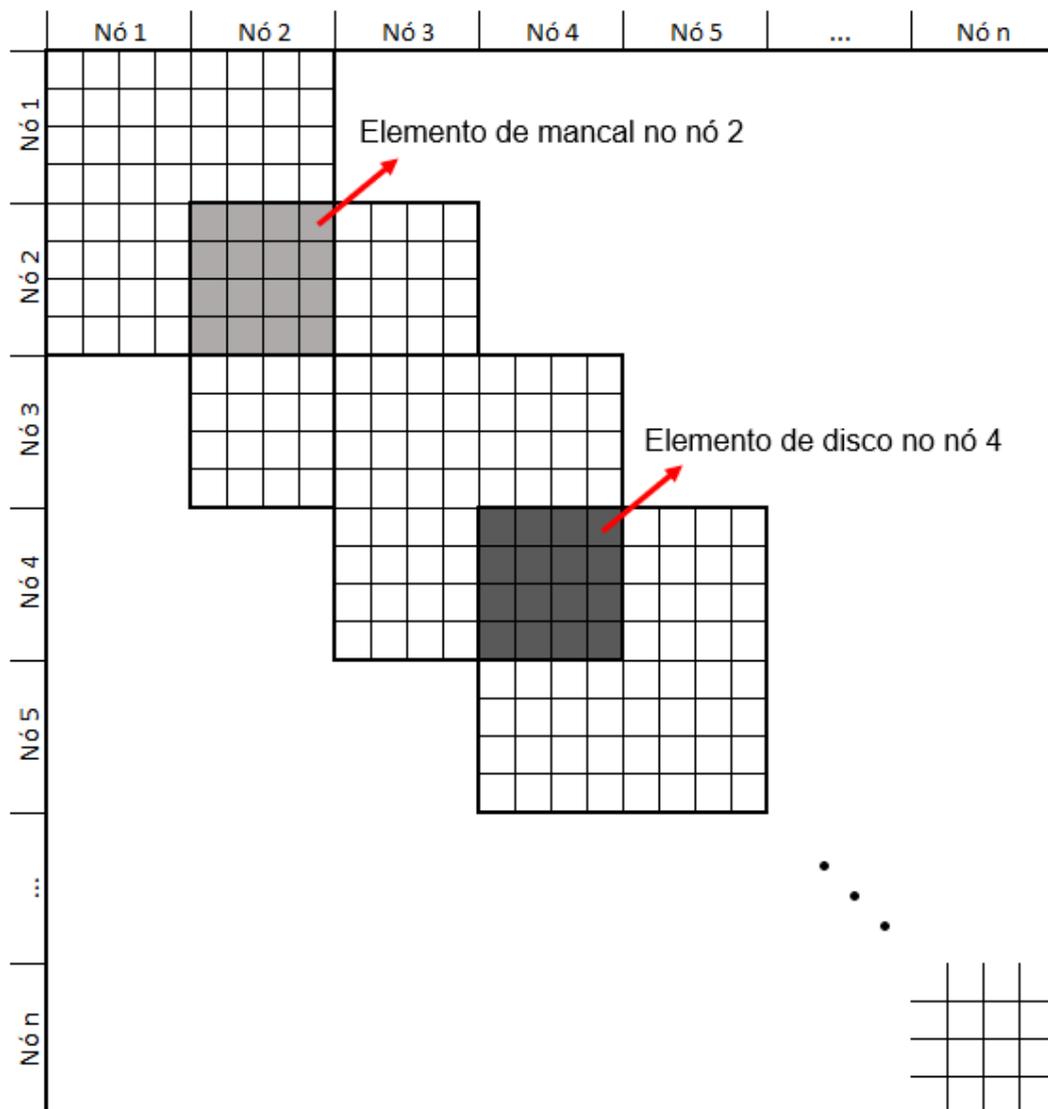


Figura 3-6: Esquema de montagem da matriz global.

Fonte: Adaptado de Castro (2007).

Neste trabalho, a força externa aplicada ao rotor é composta de três forças principais: força peso, forças hidrodinâmicas do mancal e forças de desbalanceamento. A força peso é calculada a partir da massa dos elementos do rotor e não varia com o tempo. As forças hidrodinâmicas variam em função da posição e velocidade do rotor e, conseqüentemente, em função do tempo (RAMOS, 2019). A força de desbalanceamento varia em função do tempo e é calculada seguindo a norma ISO 1940, a partir do grau de qualidade de balanceamento.

A norma ISO 1940 (ORGANIZATION INTERNATIONAL STANDARD, 2003) define o grau de qualidade de balanceamento em rotores, caracterizando tolerâncias máximas no desbalanceamento, o número necessário para correção de planos e os métodos para verificação de um desbalanceamento residual. O grau de desbalanceamento residual permissível específico é apresentado na Eq. (3.41):

$$e_{per} = \frac{G_{ISO}}{1000\Omega} \quad (3.41)$$

no qual  $G_{ISO}$  é definido como o grau de qualidade de balanceamento descrito em milímetros por segundo ( $mm/s$ ) e  $\Omega$  é a rotação do rotor em radianos por segundo ( $rad/s$ ). A Eq. (3.42) apresenta o desbalanceamento residual permissível medido em quilogramas metro ( $kgm$ ), onde  $m_r$  é a massa do rotor descrita em quilogramas ( $kg$ ).

$$U_{per} = m_r e_{per} \quad (3.42)$$

Ademais, a norma ISO 1940 estabelece um grau de qualidade de desbalanceamento para cada tipo específico de máquina rotativa, no qual a classe 6,3 representa a classe de máquinas em geral. Com base no desbalanceamento residual permissível, a força de desbalanceamento pode ser escrita como:

$$\begin{aligned} f_{Xd} &= U_{per}\Omega^2 \cos(\Omega t + \phi) \\ f_{Yd} &= U_{per}\Omega^2 \sin(\Omega t + \phi) \end{aligned} \quad (3.43)$$

onde  $t$  é o tempo e  $\phi$  a defasagem do desbalanceamento. Essas forças devem ser adicionadas ao vetor de forças externas na equação de movimento, nos respectivos graus de liberdades dos nós que possuem desbalanceamento.

Uma vez que as matrizes globais e o vetor de força externa são determinados, é possível, por meio da solução da equação de movimento, obter o deslocamento, velocidade e aceleração do sistema rotativo no domínio do tempo. A análise do comportamento dinâmico do rotor pode ser solucionada a partir de um integrador numérico. Neste trabalho, foi utilizado o integrador Newmark juntamente com o método de busca Newton-Raphson, sendo um dos integradores usualmente utilizado neste tipo de análise (RAMOS, 2019).

### **3.6 Modelos substitutos**

Os modelos matemáticos tem se tornado cada vez mais complexos, devido à necessidade em elevar a representatividade e acurácia de seus resultados. Com isso, a alta complexidade desses modelos induzem um elevado custo computacional, inviabilizando a sua utilização em diversas aplicações. Neste cenário, a aplicação de modelos substitutos tem se destacado, pois, a partir de um conjunto de amostras do modelo original, os modelos substitutos se ajustam para realizar a regressão ou interpolação dos dados. Sendo assim, os modelos substitutos devem oferecer a maior representatividade possível com os dados do modelo original e com um baixo custo computacional.

#### **3.6.1 Amostragem**

Os modelos substitutos dependem de um banco de dados conhecido como base para realizar a regressão ou interpolação para um novo conjunto de dados. Devido a sua importância, a amostragem do banco de dados deve garantir a representatividade do problema proposto, para que os modelos substitutos realizem o melhor ajuste possível dentro dos limites estabelecidos de sua população. Segundo Sacks et al. (1989), uma boa técnica de amostragem deve preencher todo o espaço amostral, sendo que as técnicas *grid* retangular e o Hipercubo Latino estão entre as técnicas mais utilizadas para esta abordagem.

De acordo com Urban e Fricker (2010), o método *grid* retangular seleciona os valores igualmente espaçados nos limites do espaço amostral. Ainda, segundo os autores, esse método é muito popular pois a aplicação é a mais simples possível, além de requerer apenas o intervalo dos parâmetros e o tamanho do conjunto. Entretanto, o tamanho do conjunto cresce exponencialmente com o número de parâmetros.

O método Hipercubo Latino é um procedimento de amostragem aleatória, no qual fornece de forma eficiente uma amostragem de variáveis a partir de suas distribuições multivariadas (MINASNY e MCBRATNEY, 2006). Segundo Sicchieri (2019), o método Hipercubo Latino divide cada um dos parâmetros de entrada  $k_h$  do espaço amostral em  $n_h$  intervalos equiprováveis. Assim, um ponto é escolhido em cada um destes intervalos, resultando-se então em uma matriz de  $k_h$  colunas formadas pelas amostras de cada parâmetro, que são preenchidas com uma distribuição aleatória que leva ao conjunto de amostra final de  $n_h$  vetores de dimensões  $k_h$ . A Figura 3-7 apresenta um conjunto de dados amostrados com duas variáveis de entrada, seguindo o método *grid* retangular e o Hipercubo Latino.

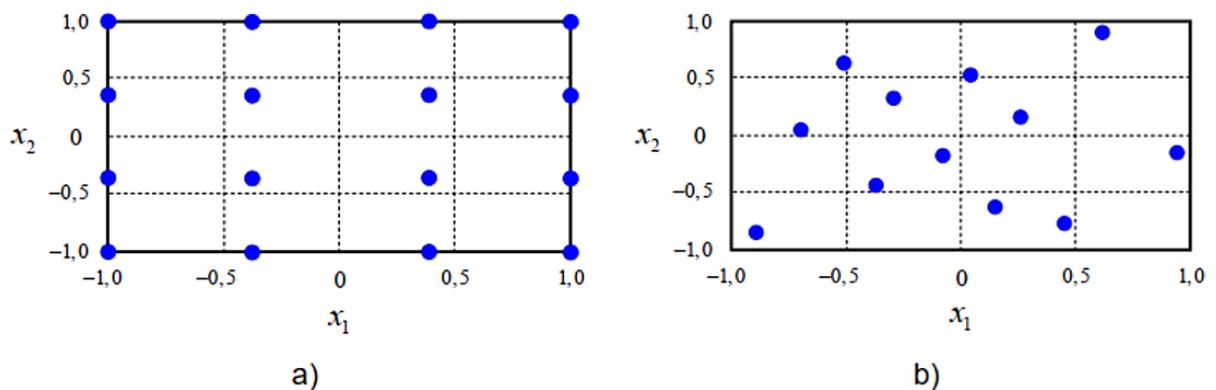


Figura 3-7: Conjunto de dados gerado com o método a) *grid* retangular, b) Hipercubo Latino.

Fonte: (SICCHEIRI, 2019).

Ambos os métodos podem gerar amostras para preencher todo o espaço amostral dentro dos limites estabelecidos para cada variável de entrada. No entanto, o método *grid* retangular será utilizado neste trabalho para determinar os bancos de dados, no qual os modelos substitutos vão ser aplicados.

### 3.6.2 Redes Neurais Artificiais

De acordo com Haykin (2008), uma rede neural artificial é um modelo computacional distribuído massivamente em paralelo com unidades de processamentos simples que têm uma capacidade natural para armazenar conhecimento e torná-lo disponível para uso. Ele se assemelha ao cérebro humano em dois aspectos:

- o conhecimento é adquirido pela rede por meio de um processo de aprendizagem;
- as forças de conexão do interneurônio, conhecidas como pesos sinápticos, são usadas para armazenar o conhecimento adquirido.

As redes neurais são adequadas para a solução de problemas não lineares e com alto número de variáveis de entrada, devido a sua capacidade de alterar os pesos sinápticos dentro dos neurônios para se adaptar ao ambiente. É importante ressaltar que as redes neurais são modelos simplificados baseados em apenas uma parte do cérebro humano. De acordo com Haykin (2008), o cérebro humano é uma estrutura única que não pode ser encontrada digitalmente e que não está nem próxima de ser recriada com redes neurais artificiais. A Figura 3-8 apresenta um dos modelos de neurônio mais utilizados na literatura, conhecido como *perceptron* e proposto por Rosenblatt (1962).

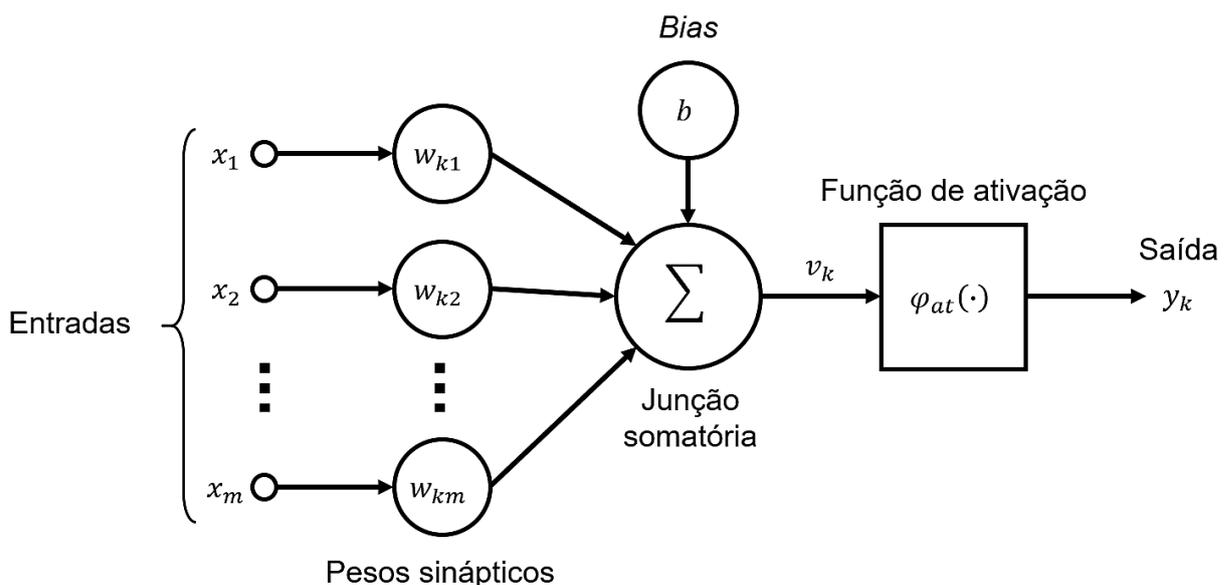


Figura 3-8: Modelo de neurônio artificial (*perceptron*).

Fonte: Adaptado de Haykin (2008).

Em resumo, o neurônio calcula a saída  $y_k$  por meio de uma combinação linear dos sinais de entrada  $x_j$ , ponderados pelos pesos sinápticos  $w_{kj}$ , em que  $k$  representa o índice do neurônio e  $j$  indica o sinal de entrada ao qual o peso está associado, e incorpora externamente com um *bias*  $b$ , gerando  $v_k$ , o qual passa por uma função de ativação  $\varphi_{at}(\cdot)$ , usualmente de caráter não-linear, resultando assim no sinal de saída do neurônio  $y_k$ . Portanto, a saída do neurônio pode ser descrita como:

$$y_k = \varphi_{at}(v_k) = \varphi_{at}\left(\sum_{j=1}^m w_{kj}x_j + b\right) \quad (3.44)$$

A função de ativação determina a saturação da saída do neurônio e sua escolha tem influência sobre alguns aspectos da rede neural, tais como sua flexibilidade para aproximar mapeamentos entradas-saídas complexos e a eficiência de seu treinamento. Por muito tempo as funções sigmóides, como a tangente hiperbólica e a função logística, representaram a função padrão utilizada nas redes neurais. A Figura 3-9 apresenta a saturação das funções de ativação e suas derivadas. A justificativa para isso é que as duas funções são diferenciáveis em todos os pontos, conforme demonstrado nas equações abaixo.

a) Tangente hiperbólica:

$$\varphi_{at}(v_k) = \tanh(v_k) = \frac{e^{v_k} - e^{-v_k}}{e^{v_k} + e^{-v_k}}, \quad (3.45)$$

$$\frac{d\varphi_{at}(v_k)}{dv_k} = 1 - \tanh^2(v_k) = 1 - \left(\frac{e^{v_k} - e^{-v_k}}{e^{v_k} + e^{-v_k}}\right)^2; \quad (3.46)$$

b) Função logística:

$$\varphi_{at}(v_k) = \frac{1}{1 + e^{-v_k}}, \quad (3.47)$$

$$\frac{d\varphi_{at}(v_k)}{dv_k} = \frac{1}{1 + e^{-v_k}} \left(1 - \frac{1}{1 + e^{-v_k}}\right). \quad (3.48)$$

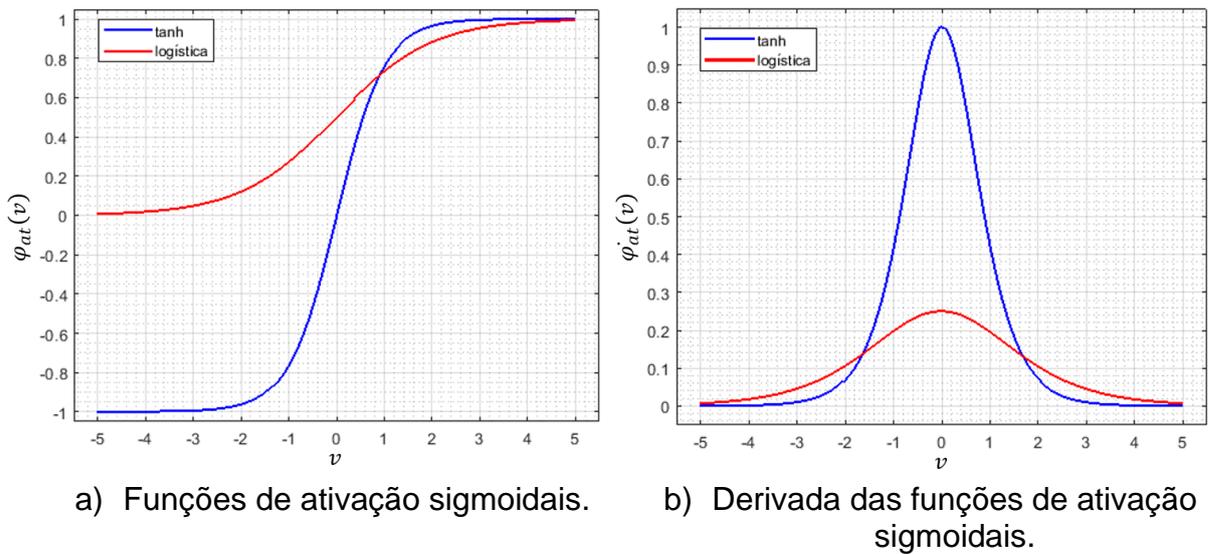


Figura 3-9: Comparação da saturação das funções de ativação sigmóides e suas derivadas.

Um único neurônio *perceptron* consegue solucionar problemas de classificação e regressão lineares, entretanto, ele não consegue resolver problemas de classificação e regressão não lineares (ALPAYDIN, 2014). Esta limitação não se aplica quando um conjunto de neurônios são agrupados e organizados formando uma arquitetura. A arquitetura de uma rede é definida a partir do tipo, da quantidade e do padrão de conectividade estabelecido entre os neurônios e é ela quem define a orientação de como os sinais de entrada são propagados dentro da rede para realizar o mapeamento da saída. De forma simples, é possível dividir as diferentes arquiteturas em dois grupos básicos:

- a) redes *feedforward* (FNNs, do inglês *feedforward neural network*), em que as entradas recebidas pela rede são propagadas em um único sentido até que as saídas sejam determinadas. Este tipo de arquitetura é organizado em camadas, sendo que cada camada possui uma quantidade de neurônios própria e realiza um mapeamento entrada-saída. Portanto, as saídas dependem apenas dos parâmetros da rede e das entradas, caracterizando um mapeamento estático;
- b) redes recorrentes (RNNs, do inglês *recurrent neural network*), em que existem laços de realimentação que transmitem as saídas de neurônios de uma determinada camada para neurônios pertencentes à mesma camada ou a camadas anteriores. Este tipo de arquitetura possui um mapeamento dinâmico

pois as saídas dependem dos parâmetros da rede, das entradas e das saídas dos neurônios da iteração anterior.

Um dos principais expoentes da classe de FNNs é a rede conhecida como *perceptron* de múltiplas camadas (MLP, do inglês *multilayer perceptron*), apresentada na Figura 3-10.

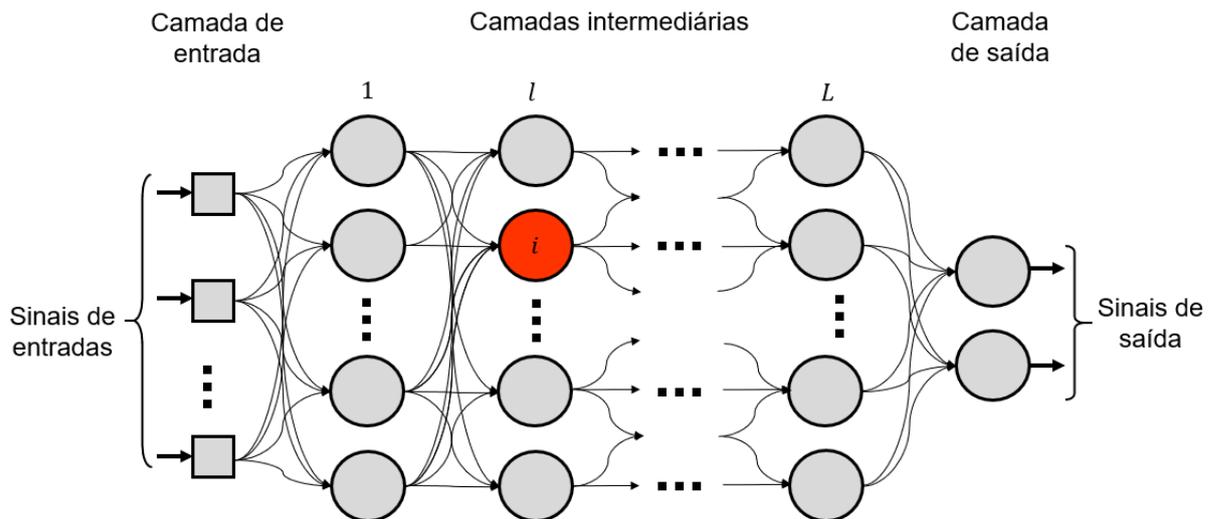


Figura 3-10: Arquitetura de uma rede MLP.

Fonte: Adaptado de Haykin (2008).

A rede MLP possui as seguintes características básicas:

- (a) as funções de ativação de cada neurônio dentro da rede são não lineares e diferenciáveis em todos os pontos;
- (b) a rede contém uma ou mais camadas intermediárias (ou ocultas) entre as camadas de entrada e saída;
- (c) os neurônios de uma camada  $l$  estão conectados a todos os neurônios da camada seguinte ( $l + 1$ ). Por isso, essa estrutura é também chamada de totalmente conectado (ou densa).

De acordo com a Figura 3-10, a camada de entrada de uma rede MLP é apenas uma ilustração da passagem dos atributos à rede. As camadas intermediárias são responsáveis por realizar o mapeamento não-linear da entrada-saída dos dados. Por fim, os neurônios da camada de saída combinam as informações fornecidas pela última camada intermediária, produzindo as respostas da rede para aquele padrão de entrada. Logo, a saída do  $i$ -ésimo neurônio da  $l$ -ésima camada intermediária, como

destacado na Figura 3-10, em que  $i = 1, \dots, n_l$  e  $l = 1, \dots, L$ , é obtida da seguinte forma:

$$y_i^l = \varphi_{at} \left( \sum_{j=1}^m w_{ij}^l y_j^{l-1} + b \right) \quad (3.49)$$

onde  $w_{ij}^l$  representa o peso sináptico da conexão que liga o  $j$ -ésimo neurônio da camada  $l - 1$  ao  $i$ -ésimo neurônio da camada  $l$ . Para a primeira camada intermediária, os sinais de entrada são os próprios atributos do dado, i.e.  $y_j^0 = x_j, j = 1, \dots, m$ .

Para obter o sinal de saída desejado, a camada de saída de uma rede MLP depende do problema abordado. Em classificação binária ou multi-classe, utiliza-se funções que apresentam a probabilidade de que a saída pertencer a classe ou não, sendo que se recorre à função logística no caso binário, enquanto a *softmax* é utilizada no cenário multi-classe. Em regressão, os neurônios da saída têm a função de ativação igual à identidade, de modo que cada saída da rede é obtida por meio de uma combinação linear das saídas dos neurônios da última camada intermediária.

O processo de aprendizagem de uma rede MLP é baseado na otimização dos pesos sinápticos,  $w_{ij}^l$ , e do bias,  $b$ , de todas as camadas, em que se busca os valores que levem ao melhor mapeamento entrada-saída possível para a rede. Este processo de otimização é conduzido de maneira iterativa, minimizando uma função custo  $J(\mathbf{w})$  que descreve uma medida de erro entre as saídas fornecidas pela rede e as saídas desejadas, em que  $\mathbf{w}$  representa o vetor com todos os pesos e *bias* da rede.

Este processo de otimização pode ser baseado nas derivadas de primeira ou de segunda ordem da função custo, conhecidas como vetor gradiente ou matriz hessiana respectivamente. Uma das funções de custo mais utilizadas é o erro quadrático médio (MSE, do inglês *mean-squared error*):

$$J_{MSE}(\cdot) = \frac{1}{N} \sum_{n=1}^N \sum_{m=1}^r e_m^2(n) = \frac{1}{N} \sum_{n=1}^N \sum_{m=1}^r (d_m(n) - y_m^{L+1}(n))^2, \quad (3.50)$$

onde  $N$  é o número de amostras de cada entrada,  $r$  é o número de entradas,  $d_m$  é a saída desejada e  $y_m^{L+1}$  é a saída obtida pela rede.

Entretanto, os pesos sinápticos não são apresentados de maneira explícita na Eq. (3.50). Para que a dependência de  $J_{MSE}(\cdot)$  em relação aos pesos fique em evidência, é necessário recorrer a aplicações sucessivas da regra da cadeia, este processo é conhecido como retropropagação de erro (HAYKIN, 2008). Este método parte da camada de saída da rede e propaga as derivadas necessárias da função custo até a primeira camada intermediária. Sendo assim, a obtenção do vetor gradiente é dividida em duas etapas, sendo que a primeira etapa, conhecida como *forward*, apresenta um dado a rede e obtém-se a resposta da camada de saída, enquanto na segunda etapa, conhecida como *backward*, calculam-se as derivadas dos pesos sinápticos camada por camada por meio da regra da cadeia até a primeira camada intermediária.

Apesar da não-linearidade da rede neural, a superfície de erro pode ser não-convexa impondo alguns obstáculos para o progresso dos algoritmos de busca, tais como a presença de platôs, pontos de sela e mínimos locais de baixa qualidade (DUDA et. al., 2000). Os algoritmos de otimização baseados no gradiente descendente apresentam avanços expressivos durante a exploração da superfície de erro, pois os parâmetros são ajustados para minimizar a função de custo adaptando o passo e a direção a cada iteração (GÉRON, 2019).

Outros problemas comuns não desejados durante o processo de aprendizado é o subajuste (do inglês, *underfitting*) e o sobreajuste (do inglês, *overfitting*). O primeiro problema representa um mapeamento do modelo inadequado com os dados utilizados no treinamento e ocorre devido a falta do grau de flexibilidade do modelo diante da complexidade do mapeamento a ser aproximado, ou ainda, também por problemas de convergência do processo de treinamento. O segundo problema representa um modelo com alto grau de flexibilidade, reduzindo ao máximo o erro com os dados de treinamento, logo, o modelo comete erros significativos para representar amostras inéditas de entrada. O sobreajuste é muito comum em redes neurais, devido a sua elevada capacidade de aproximação no mapeamento.

Para obter um modelo com melhor capacidade de generalização e, com isso, evitar os problemas previamente citados, utiliza-se a abordagem de validação cruzada (CV, do inglês *cross-validation*) dos dados, no qual o método consiste em dividir o conjunto de amostras de treinamento em duas partes:

- a) A primeira parte (~80% da base) é conhecida como conjunto de treinamento e é efetivamente empregado no ajuste dos parâmetros do modelo;

- b) A segunda parte (~20% da base) é conhecido como conjunto de validação e é utilizado para monitorar a capacidade de generalização do modelo.

Sendo assim, tendo à disposição um conjunto de amostras separado para validação, durante o treinamento do modelo, é feito um monitoramento do seu desempenho junto aos dados de validação.

### **3.6.3 Interpolação**

A interpolação é um método utilizado para estimar as saídas de funções discretas em pontos intermediários, a partir de um conjunto discreto de dados previamente conhecido. Este tipo de aproximação pode ser aplicado para funções de múltiplas entradas e saídas. Para as funções de múltiplas entradas e saídas, as saídas interpoladas são calculadas nos pontos mais próximos das entradas em cada respectiva dimensão. O método consiste em obter uma saída aproximada dentro de um determinado intervalo, sendo que as estimativas fora do intervalo são conhecidas como extrapolações.

Logo, a propriedade fundamental das funções de interpolação é que elas devem coincidir com os dados de amostras nos pontos de interpolação, assim, seja  $y(x_l)$  os pontos de amostragem e  $\hat{y}(x_l)$  o correspondente a função de interpolação, então,  $\hat{y}(x_l) = y(x_l)$ , onde  $x_l$  são os pontos de interpolação (KEYS, 1981).

#### **3.6.3.1 Interpolação Linear**

De acordo com Franco (2006), a aproximação de funções por polinômios é uma das técnicas mais utilizadas devido às diversas vantagens associadas com os polinômios, como a facilidade computacional, entre outras. Segundo Lopes e Costa (2017), a interpolação de um conjunto de dados consiste em criar uma função que melhor se ajusta a esse conjunto de dados, sendo que essa função pertence a uma classe definida a priori, como um polinômio de grau  $n_p$ .

A interpolação linear pode ser interpretada como uma média ponderada entre a vizinhança mais próxima da saída desejada. O método interliga os pontos de um conjunto de dados discreto por meio de retas, como apresentada na Figura 3-11. Assim, a interpolação linear é um polinômio de grau 1, conforme descrito na Eq. (3.51).

Portanto, usando semelhança de triângulos, pode-se reorganizar e definir a Eq. (3.52), utilizada como interpolação linear.

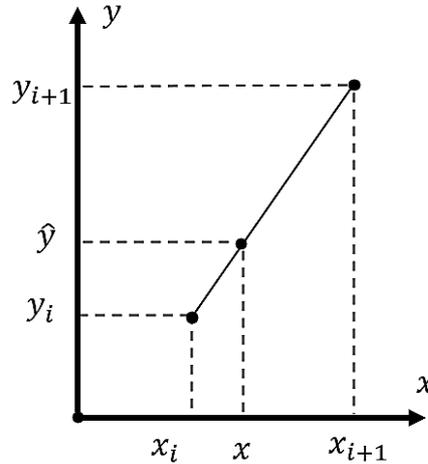


Figura 3-11: Ilustração da interpolação linear.

$$\hat{y} = a_i x + b_i, \quad (3.51)$$

$$\hat{y} = y_i + (y_{i+1} - y_i) \frac{x - x_i}{x_{i+1} - x_i}. \quad (3.52)$$

Em geral, quanto menor o intervalo entre os pontos mais próximos, melhor a aproximação, o que se deve ao fato de que, conforme o intervalo diminui, uma função contínua será mais bem aproximada por uma reta (CHAPRA; CANALE, 2008).

### 3.6.3.2 Interpolação Cúbica

Para um conjunto de amostras igualmente espaçadas, a interpolação cúbica pode ser descrita da seguinte forma:

$$\hat{y}(x) = \sum_k c_k u\left(\frac{x - x_k}{h_i}\right) \quad (3.53)$$

Segundo Rifman (1973),  $h_i$  representa o incremento de amostragem,  $x_k$  são as amostras de interpolação,  $u$  é a kernel de interpolação,  $c_k$  são os parâmetros que dependem dos dados amostrados, sendo selecionados de modo que a condição de

interpolação  $\hat{y}(x_k) = y(x_k)$  para cada  $x_k$  seja satisfeita. Ainda, o kernel de interpolação consiste em polinômios de terceiro grau por partes e são continuamente diferenciáveis (MEIJERING; UNSER, 2003). As funções de interpolação linear, cúbica e *spline* cúbico podem ser caracterizados como a Eq. (3.53), com diferentes kernels de interpolação (HOU; ANDREWS, 1978).

De acordo com Rifman (1973), os kernels de interpolação possuem um grande impacto no comportamento numérico das funções de interpolação, por consequência da sua influência na precisão e eficiência dos métodos. O algoritmo de convolução cúbica é derivado de um conjunto de condições impostas no kernel de interpolação que foi projetado para maximizar a precisão de um determinado nível de esforço computacional (KEYS, 1981).

A expressão matemática do kernel de interpolação cúbica é apresentada na Eq. (3.54), sendo que seu equacionamento pode ser visto em detalhes no trabalho proposto por Keys (1981).

$$u(x) = \begin{cases} 3/2 |x|^3 - 5/2 |x|^2 + 1, & \text{se } 0 < |x| < 1 \\ -1/2 |x|^3 - 5/2 |x|^2 - 4|x| + 2, & \text{se } 1 < |x| < 2 \\ 0, & \text{se } 2 < |x| \end{cases} \quad (3.54)$$

Além do kernel de interpolação, a função de interpolação cúbica depende dos pontos de amostragem que são definidos dentro de um intervalo finito,  $[a, b]$ . Por causa das restrições impostas sobre o domínio dos pontos de amostragem, é necessário definir algumas condições de contorno para a função de interpolação cúbica (KEYS, 1981). Para o intervalo  $[a, b]$ , Eq. (3.53) pode ser reescrita como:

$$\hat{y}(x) = \sum_{k=-1}^{N+1} c_k u\left(\frac{x - x_k}{h_i}\right) \quad (3.55)$$

onde para determinar  $\hat{y}$  para todo  $x$  no intervalo  $[a, b]$ , os valores de  $c_k$  para  $k = -1, 0, 1, \dots, N+1$  são necessários. Para  $k = 0, 1, \dots, N$ , tem-se que  $c_k = y(x_k)$ . No entanto, para  $k = -1$  e  $k = N+1$ , o valor de  $y(x_k)$  é desconhecido, uma vez que  $x_{-1}$  e  $x_{N+1}$  estão fora do intervalo de observação. Assim, os valores atribuídos a  $c_{-1}$  e  $c_{N+1}$  são condições de contorno. A dedução completa das condições de contorno foram apresentadas por Keys (1981). Utilizando o kernel de interpolação definido pela Eq.

(3.54), a descrição completa da função de interpolação cúbica para  $x_k < x < x_{k+1}$ , é dada por:

$$\hat{y}(x) = \frac{c_{k-1}(-s^3 + 2s^2 - s) + c_k(3s^3 - 5s^2 + 2) + c_{k+1}(-3s^3 + 4s^2 + s)}{2} + \frac{c_{k+2}(s^3 - s^2)}{2} \quad (3.56)$$

onde  $s = (x - x_k)/h_i$  e  $c_k = y(x_k)$  para  $k = 0, 1, \dots, N$ ,  $c_{-1} = 3y(x_0) - 3y(x_1) + y(x_2)$  para  $k = -1$  e  $c_{N+1} = 3y(x_N) - 3y(x_{N-1}) + y(x_{N-2})$  para  $k = N + 1$ .

### 3.6.3.3 Interpolação Spline

Ao utilizar um único polinômio para interpolar todos os nós de um dado intervalo, especialmente quando possuem grau elevado, um problema comumente encontrado refere-se as grandes flutuações que ocorrem nos extremos do intervalo, conhecido como Fenômeno de Runge. Assim, usa-se uma alternativa para redução dessas flutuações, conhecida como interpolação *spline* ou *spline* cúbico (LOPES; COSTA, 2017).

Essa técnica de interpolação consiste no uso de polinômios de grau reduzido em seções menores do intervalo total dos pontos, considerando certas condições que garantam que a função de aproximação resultante seja contínua e tenha derivadas contínuas até certa ordem. Na prática, a interpolação com o *spline* é a mais empregada, e as funções em cada seção podem ser representadas pela Eq. (3.57), encontradas em McKinley e Levine (1998).

$$y(x) = \begin{cases} y_1(x) & \text{se } x_1 \leq x \leq x_2, \\ y_2(x) & \text{se } x_2 \leq x \leq x_3, \\ \vdots & \\ y_{n-1}(x) & \text{se } x_{n-1} \leq x \leq x_n, \end{cases} \quad (3.57)$$

onde  $y_i$  é o polinômio de 3º grau dado pela Eq. (3.58).

$$\hat{y} = a_i(x - x_i)^3 + b_i(x - x_i)^2 + c_i(x - x_i) + d_i, \quad (3.58)$$

Os *splines* de grau  $n + 1$  garantem que as  $n$  derivadas são contínuas nos nós, o que contribui para fornecerem uma aproximação superior do comportamento de funções que têm variações locais abruptas. Além disso, para o caso de um *spline* que demande segundas derivadas nulas nos nós extremos, também chamado de *spline* natural, seu resultado tem um ajuste melhor que o obtido por um polinômio cúbico que não possui tal restrição (CHAPRA; CANALE, 2008).

As restrições necessárias para o uso do *spline* cúbico resultam em um ajuste distinto daquele obtido através da interpolação cúbica, como mostrado na Figura 3-12.

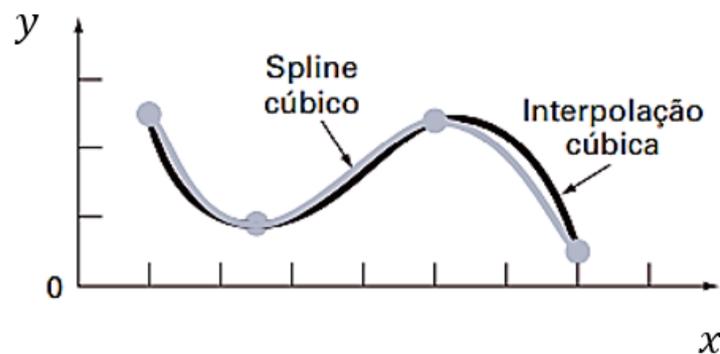


Figura 3-12: Comparação de ajuste de curvas por interpolação cúbica e *spline* cúbico.

Fonte: (CHAPRA; CANALE, 2008).

### 3.6.4 Métricas de avaliação dos modelos substitutos

Durante as etapas de testes os modelos substitutos são avaliados por meio de diferentes métricas, comparando as saídas estimadas com as saídas originais. As métricas de avaliação utilizadas neste trabalho são: a raiz do erro quadrático médio (RMSE, do inglês *Root Mean Square Error*), o erro relativo médio da força resultante, o erro relativo, o erro relativo médio e o coeficiente de determinação.

A Eq. (3.59) apresenta a expressão da RMSE, que avalia a ordem de grandeza do erro médio. Assim, quanto mais próximo de zero for o valor de RMSE, mais próximo são as saídas dos modelos substitutos com o modelo original.

$$RMSE_y = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad (3.59)$$

Sendo que  $y_i$  é a saída do modelo original,  $\hat{y}_i$  é a saída estimada pelo modelo substituto e  $N$  é o número de amostras.

O Erro Relativo Médio da Força Resultante ( $ERM_{F_R}$ ) representa a razão entre o vetor do erro resultante ( $E_R$ ) e o vetor da força resultante do modelo original ( $F_R$ ), conforme apresentado na Eq. (3.60). A Figura 3-13 mostra uma ilustração dos vetores de forças calculados para obter o  $E_R$ , no qual os vetores vermelhos representam as forças do modelo original, os vetores verdes com o sobrescrito  $\hat{\phantom{x}}$  representam as forças estimadas pelo modelo substituto, o vetor em azul representa o erro entre as forças resultante entre o modelo original e o substituto, os subscritos  $X$  e  $Y$  representam as direções das forças no sistema de coordenadas inercial e o subscrito  $R$  representa a resultante dos vetores adjacentes.

$$ERM_{F_R} = \frac{1}{N} \sum_{i=1}^N \frac{E_{Ri}}{F_{Ri}} = \frac{1}{N} \sqrt{\sum_{i=1}^N \frac{(F_{x_i} - \hat{F}_{x_i})^2 + (F_{y_i} - \hat{F}_{y_i})^2}{F_{x_i}^2 + F_{y_i}^2}} \quad (3.60)$$

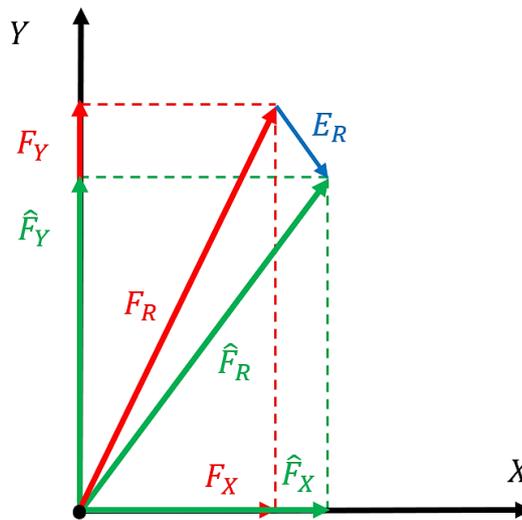


Figura 3-13: Ilustração do cálculo do  $ERM_{F_R}$ .

O coeficiente de determinação ( $R^2$ ) indica o quão próximo são as saídas estimadas pelos modelos substitutos com as saídas originais, sendo que, quanto mais próximo de 1 for o coeficiente de determinação, mais próxima é a saída estimada com a saída original (MONTGOMERY; RUNGER, 2014). A Eq. (3.61) apresenta o cálculo do coeficiente de determinação:

$$R_y^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (3.61)$$

onde  $\bar{y}$  é o valor médio das saídas do modelo original.]

### 3.7 Classificação de defeitos com aprendizado profundo

Os algoritmos de aprendizado de máquina (ML, do inglês *Machine Learning*) tem sido os métodos mais utilizados nos últimos anos para identificação e diagnóstico de defeitos em mancais (HOANG e KANG, 2018). Entre as diferentes abordagens disponíveis nesta área, os métodos de aprendizado de máquina mais aplicados para classificação de dados são as redes neurais artificiais, análise dos componentes principais (PCA, do inglês *Principle Component Analysis*), k vizinhos mais próximos (kNN, do inglês *k-Nearest Neighbors*) e máquinas de vetores-suporte (SVMs, do inglês *Support Vector Machines*) (ZHANG et al., 2020). Segundo Huang (1996, apud, HOANG e KANG, 2018), os métodos de aprendizado de máquina demandam de quatro etapas para realizar a classificação, sendo elas: aquisição de dados, extração de atributos, seleção de atributos e classificação dos dados.

A aquisição de dados é realizada coletando sinais da máquina com diferentes tipos de sensores. Os tipos de sinais coletados para identificação e diagnóstico de defeitos em mancais são muito variados. Dentro da literatura é possível encontrar trabalhos aplicando correntes elétricas de motores (SINGH et al. 2014), sinais acústicos (CHACON et al. 2015) e sinais de vibração (ALVES et al, 2020) na classificação de defeitos. Segundo Kharche e Kshirsagar (2014), os sinais de vibração são os mais aplicados para classificação, pois, as informações da saúde estrutural do rotor são refletidas diretamente no comportamento dinâmico das máquinas rotativas.

Os sinais extraídos das máquinas rotativas são dados adquiridos no domínio do tempo. Para cada sinal adquirido é atribuído um rótulo com a condição da máquina, sendo ele, em condições normais ou com diferentes tipos e intensidade de defeitos. Entretanto, os métodos clássicos de aprendizado de máquina citados não são capazes de classificar os sinais brutos no domínio do tempo, pois, a extração e seleção de atributos são etapas primordiais para a garantir a eficiência na classificação do defeito.

Os principais atributos extraídos de sinais no domínio do tempo são os momentos estatísticos como média, desvio padrão, assimetria, curtose e momento de sexta ordem (SAMANTA e AL-BALUSHI, 2003), e fatores de forma do sinal como valor de pico a pico, valor quadrático médio (RMS, do inglês *Root Mean Square*) e fator de crista (DELGADO et al., 2013; NEUPANE e SEOK, 2020). A próxima etapa é a seleção dos conjuntos de atributos para finalmente aplicar os métodos de aprendizado de máquina na classificação de defeitos.

Uma desvantagem da aplicação deste tipo de aprendizado de máquina, é que o procedimento de extração e seleção de atributos são especificamente desenhados para apenas um tipo de defeito (HOANG e KANG, 2018). Recentemente, novos algoritmos de classificação utilizando aprendizado profundo (DL, do inglês *Deep Learning*) vem ganhando destaque dentro do aprendizado de máquina. Um dos algoritmos mais utilizados em aprendizado profundo é a rede neural convolucional. Este algoritmo já dispõe de um estágio de pré-processamento e extração de dados, o que se torna vantajoso no processo de classificação e, portanto, tem sido escolhido neste trabalho para classificação de defeitos.

### **3.7.1 Redes neurais convolucionais**

A inspiração da estrutura e funcionamento das redes neurais convolucionais (CNNs, do inglês *Convolutional Neural Network*) foi baseado no córtex visual de mamíferos para reconhecimento de padrões de imagem (ZHANG et al., 2020). Este conceito foi estabelecido por Fukushima (1980), com seu artigo sobre o *neocognitron*, que veio a ser conhecido posteriormente como CNN. Segundo Goodfellow et al. (2016) as redes neurais convolucionais têm desempenhado um papel importante na história do aprendizado profundo, pois sua aplicação em aprendizado de máquina demonstram um exemplo-chave bem-sucedido das percepções obtidas ao estudar o cérebro animal.

As CNNs são tipicamente empilhadas em camadas convolucionais em sequência de camadas de agrupamento, sendo que este tipo de estrutura é repetido algumas vezes. Com isso, os dados de entrada se tornam cada vez menores à medida que atravessa a rede. Por fim, tem-se então uma rede neural do tipo *feedforward*, composta por algumas camadas totalmente conectadas com propósito de gerar uma

resposta ao padrão de entrada (GÉRON, 2019). A Figura 3-14 apresenta a arquitetura típica de uma CNN.

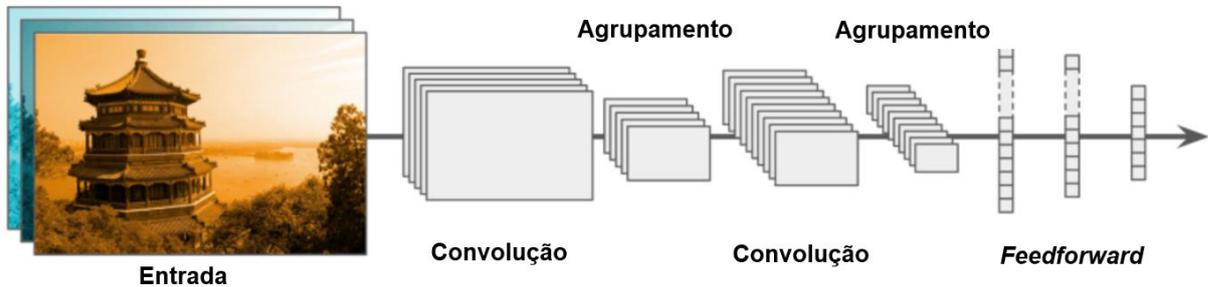


Figura 3-14: Típica rede neural convolucional.

Fonte: Adaptado de Géron (2019).

Segundo Goodfellow et al. (2016), o processo de convolução é um tipo especializado de operação linear e permite explorar informações em estruturas organizadas no tempo e espaço. Segundo Gonzalez e Woods (2010), o termo convolução entre dois sinais unidimensionais  $x(n)$  e  $w(n)$  é definido como:

$$y(n) = \sum_{k=-\infty}^{\infty} x(k)w(n-k) = (x * w)(n) \quad (3.62)$$

Este tipo de operação pode se estender para o caso de duas dimensões, como:

$$S(i, j) = (K * X)(i, j) = \sum_m \sum_n K(m, n)X(i-m, j-n) \quad (3.63)$$

A operação de convolução é dada por um filtro espacial retangular, conhecido como kernel de convolução. Este tipo de kernel percorre toda a imagem de entrada, onde a saída é obtida através da soma dos pixels da imagem dentro da vizinhança definida pelo kernel, multiplicados pelos coeficientes do kernel, como ilustrado na Figura 3-15. Além disso, tipicamente é aplicado uma função de ativação  $\varphi(\cdot)$ , que é resultado da convolução (GOODFELLOW et al., 2016).

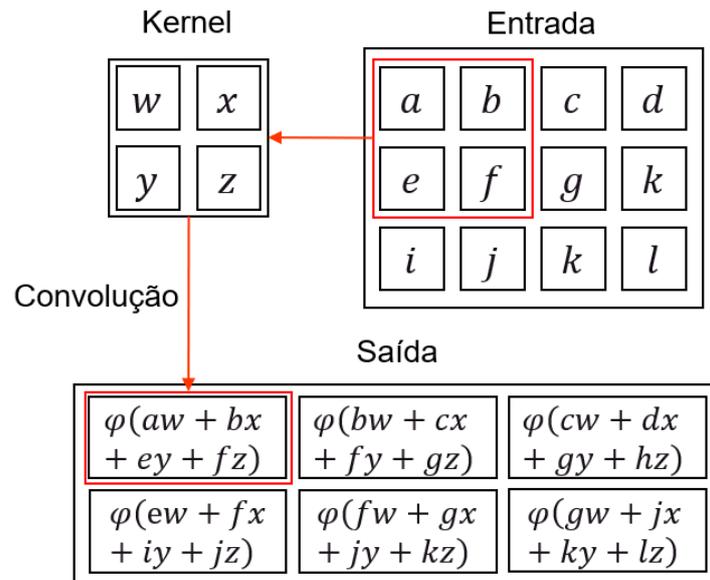


Figura 3-15: Exemplo de convolução 2-D.

Fonte: Adaptado de Goodfellow et al. (2016).

É importante ressaltar que o tamanho de um kernel define um campo receptivo e que cada kernel gera uma nova imagem como resposta à entrada, a qual é chamada de *feature map*. Para gerar um *feature map* é necessário definir o conceito de *zero padding* e o deslocamento vertical e horizontal do kernel durante a convolução, conhecido como *stride*.

A técnica conhecida como *zero padding* considera uma versão ampliada da imagem de entrada através da adição de pixels com valores nulos em suas bordas, fazendo com que o tamanho original da imagem seja mantido (GÉRON, 2019). E o valor de *stride* representa a quantidade de pixels com que o kernel é movido nas direções horizontal e vertical, ou seja, quanto maior o valor de *stride*, maior será a redução da imagem (GÉRON, 2019). A Figura 3-16 ilustra uma convolução com *zero padding* e *stride* diferente de um.

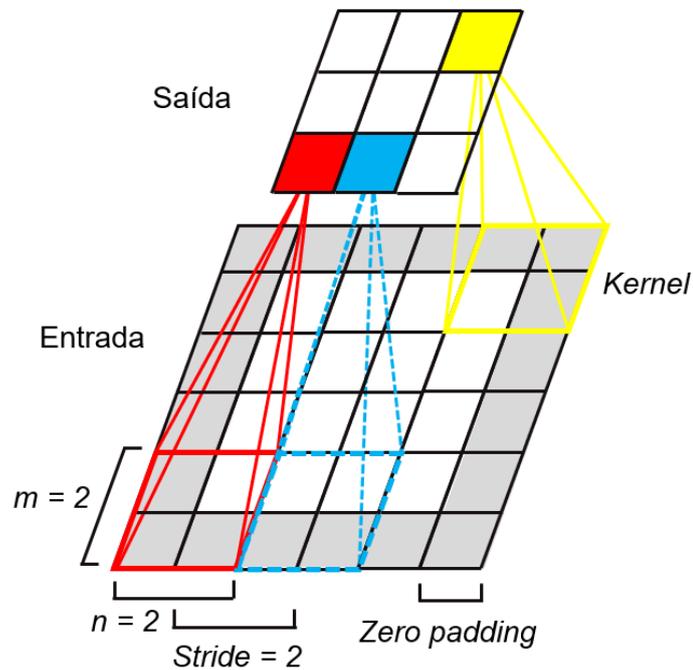


Figura 3-16: Processo de convolução 2-D (Kernel 2x2,  $stride = 2$ , com *zero padding*).  
 Fonte: Adaptado de Géron (2019).

Segundo Géron (2019), o processo de agrupamento é aplicado para reduzir a carga computacional, o uso de memória e o número de parâmetros da rede. O objetivo é sub-amostrar a imagem de entrada, fornecendo uma imagem reduzida com as informações relevantes da entrada. Assim como em uma camada convolucional, é necessário definir o tamanho do campo receptivo retangular, o *stride* e o *padding* da camada de agrupamento. Porém, ao invés de conter coeficientes, a camada de agrupamento faz uso de uma função de agregação. Usualmente são aplicados dois tipos de agrupamento, com o valor médio do campo receptivo conhecido como *average pooling*, ou com o valor máximo conhecido como *max-pooling*. A Figura 3-17 ilustra a ação da camada de agrupamento do tipo *max-pooling*.

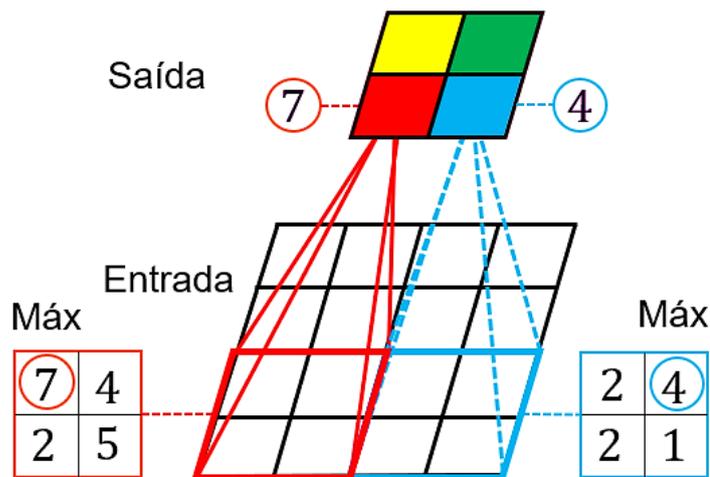


Figura 3-17: Exemplo de agrupamento 2-D (*max-pooling* 2x2, *stride* = 2, sem *padding*).

Fonte: Adaptado de Géron (2019).

Segundo Bishop (2006), apesar de sua complexidade, o processo de aprendizagem de uma CNN é muito semelhante com o processo de uma rede MLP, onde é necessário otimizar os coeficientes dos kernels e dos pesos sinápticos da rede *feedforward*. Logo, todas redes podem ser treinadas por minimização de erros utilizando retropropagação para avaliar o gradiente da função custo.

### 3.7.2 Imagem de vibração

Os sinais de vibração usualmente são vetores de deslocamento, velocidade ou aceleração no domínio do tempo, onde a taxa e o tempo de amostragem definem o comprimento deste vetor. Estes sinais de vibração podem ser convertidos em uma imagem em escala cinza (TGD, do inglês *Time-domain Grayscale Diagram*), gerando uma imagem de vibração (HOANG e KANG, 2018). Ao construir uma imagem de vibração, a amplitude de cada amostra do sinal de vibração é normalizada dentro de uma escala de 0 a 1 e depois realocada em uma posição da imagem de forma sequencial, como demonstrado na Figura 3-18.

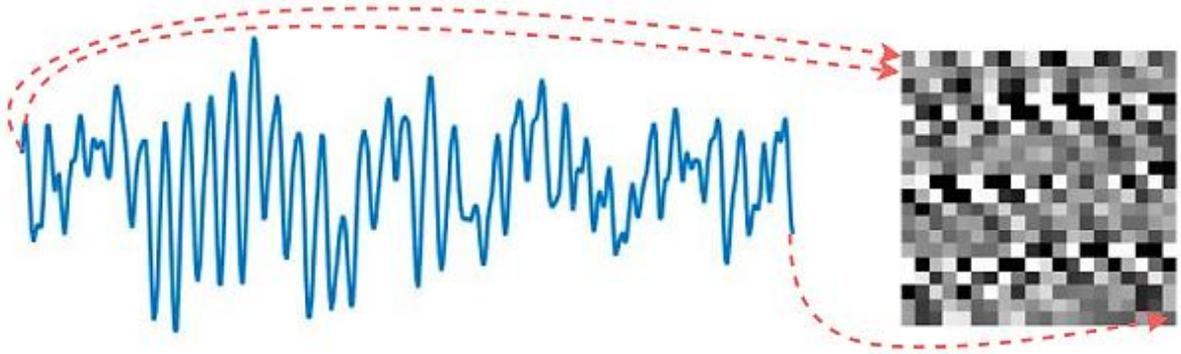


Figura 3-18: Processo de montagem da imagem de vibração.

Fonte: (HOANG e KANG, 2018).

A normalização dos sinais de vibração pode ser realizada com um mapeamento linear:

$$A_v(i) = \frac{s_v(i) - \text{mín}(s_v)}{\text{máx}(s_v) - \text{mín}(s_v)} \quad (3.64)$$

onde  $s_v$  é o vetor com o sinal de vibração e  $A_v$  é o sinal de vibração com a amplitude normalizada de 0 a 1. A imagem de vibração é determinada a partir do vetor  $A_v$  com dimensões  $N_v \times M_v$ . É importante ressaltar que o número de pixels totais na imagem gerada é igual ao número de amostras do sinal de vibração, ou seja, nenhuma informação do sinal de vibração é perdida no processo, apenas realocada.

### 3.7.3 Aumento de dados

Os bancos de dados de treinamento gerados artificialmente com modelos matemáticos são uma alternativa mais viável, quando comparados com o procedimento de coleta de dados em campo ou em bancadas de ensaios. No entanto, este procedimento requer um elevado número de simulações para gerar um grande volume de dados em tempo hábil de execução. Em virtude disso, é possível aplicar técnicas de aumento de dados (DA, do inglês *Data Augmentation*) para criar maiores conjuntos de dados, com intuito de melhorar os resultados do aprendizado profundo (GÉRON, 2019).

Este tipo de técnica consiste em aumentar artificialmente o tamanho de um conjunto de dados de treinamento gerando diversas variações plausíveis para cada amostra. Os dados sintetizados devem ser tão realistas quanto possível, isto tende a forçar o modelo a ser cada vez mais tolerante a variações aleatórias como ruídos. Para aumentar os bancos de dados gerados com sinais de vibração é possível aplicar um ruído gaussiano branco com diferentes níveis de relação sinal-ruído (SNR, do inglês *Signal-to-Noise Ratio*) medidos em decibéis (*dB*). O SNR é definido como:

$$SNR = 10 \log_{10} \left( \frac{P_{sinal}}{P_{ruído}} \right) \quad (3.65)$$

onde  $P_{sinal}$  e  $P_{ruído}$  representa a potência média do sinal e do ruído, respectivamente.

### 3.7.4 Métricas de avaliação de classificação

Diferentes métricas de avaliação são usadas para determinar o desempenho dos algoritmos de classificação, sendo que elas devem ser selecionadas de acordo com o tipo de problema de classificação que se deseja solucionar. Entre essas métricas, o desempenho do algoritmo de classificação pode ser avaliado com base nas informações sobre os dados classificados, que são apresentadas na forma de uma matriz de confusão, apresentada na Figura 3-19. Calculada a partir da decisão do classificador, a matriz de confusão contabiliza o número de classificações corretas e incorretas para cada uma das classes existentes.

		Classe estimada	
		+	-
Classe verdadeira	+	Verdadeiro positivo (TP)	Falso negativo (FN)
	-	Falso positivo (FP)	Verdadeiro negativo (TN)

Figura 3-19: Matriz de confusão binária.

Fonte: Adaptado de Sokolova e Lapalme (2009).

A diagonal principal indica o número de classificações corretas para cada classe e o restante são as classificações incorretas. O termo *TP* (*True positive*) corresponde ao número de amostras da classe positiva classificadas corretamente, *TN* (*True negative*) ao número de amostras da classe negativa classificadas corretamente, *FP* (*False positive*) ao número de amostras classificadas como positivas, mas que na realidade pertencem à classe negativa e por fim, *FN* (*False negative*) ao número de amostras classificadas como negativas, mas que pertencem à classe positiva. (SOKOLOVA e LAPALME, 2009)

De acordo com Sokolova e Lapalme (2009), a classificação binária é a mais popular dentre os tipos de classificação existentes, visto que os dados de entrada são classificados em apenas uma de duas classes existentes. Para avaliar a quantidade de acertos da classificação binária pode ser usada uma matriz de confusão, que contém as informações sobre o número de dados divididos nas classes correta e incorretamente. Por outro lado, a classificação pode ser multi-classe, onde o dado de entrada é classificado em apenas uma de  $M$  classes distintas.

De acordo com Galar *et al.* (2011), é geralmente mais fácil criar um classificador que distingue apenas duas classes do que um que considera mais que duas classes em um problema. Esse fato impulsionou o desenvolvimento de técnicas que se propõem a decompor os problemas multi-classe em problemas de classificação binária. Essas soluções não são dependentes do tipo de classificador, sendo assim aplicáveis a qualquer classificador binário.

Dentre as diversas estratégias de decomposição que podem ser encontradas na literatura, uma das mais comuns é conhecida como um-contra-todos (OAR, do inglês *One-Against-Rest*). Na decomposição OAR, um problema de  $Q$  classes é dividido em  $Q$  problemas binários onde cada problema é resolvido por um classificador que é responsável por distinguir uma classe de todas as outras. Dessa forma, em cada etapa dessa técnica uma classe é analisada separadamente das outras, e consequentemente, obtém-se diferentes matrizes de confusão para cada classe.

Utilizando como base as informações encontradas na matriz de confusão, é possível obter métricas de avaliação do desempenho do algoritmo de classificação utilizado, dentre as quais uma das mais encontradas na literatura é a acurácia. De acordo com Maxwell *et al.* (2021), o uso da métrica de acurácia com algoritmos de classificação resulta em alguns benefícios, como possibilitar a comparação de metodologias, visto que é a métrica mais empregada para os resultados de estudos

na área de aprendizado de máquina. Além disso, a acurácia fornece compreensão sobre o desempenho do algoritmo, de forma intuitiva e de fácil compreensão.

Em situações reais é mais comum encontrar problemas de multi-classes do que problemas binários, e portanto, a equação da acurácia deve ser adaptada de forma adequada. Para tanto, pode ser utilizada um valor médio do desempenho da acurácia para cada classe do classificador, como mostrado na Eq. (3.66).

$$A_c = \left( \sum_{i=1}^Q \frac{TP_i + TN_i}{TP_i + FN_i + FP_i + TN_i} \right) / Q \quad (3.66)$$

onde  $Q$  é o número de classes e  $A_c$  é a acurácia da classificação.

## 4 RESULTADOS E DISCUSSÕES

Na seção 3, foi apresentado os modelos numéricos utilizados para obter a solução da equação de Reynolds, a resposta dinâmica do rotor, os modelos substitutos e o método de classificação de defeitos. Em continuidade, a presente seção descreve inicialmente os parâmetros geométricos e as condições operacionais do mancal hidrodinâmico e dos rotores analisados. Em seguida, um teste de convergência das forças hidrodinâmicas é apresentado considerando diferentes dimensões de malhas. Além disso, os coeficientes equivalentes de rigidez e amortecimento do mancal são avaliados em conjunto com o diagrama de Campbell para as duas geometrias de rotores analisados.

Uma vez estabelecida a correta solução da Equação de Reynolds, os bancos de dados aplicados nos modelos substitutos são então construídos. Após isso, são avaliadas as respostas obtidas pelos modelos substitutos, a partir de um banco de teste gerado por meio de uma distribuição uniforme.

Por fim, os modelos substitutos previamente analisados são então aplicados na classificação de defeitos de um rotor, a fim de avaliar se há impacto significativo dessa abordagem de mancal sobre a acurácia da classificação de defeitos em diferentes condições de operação e tipo de rotor.

### 4.1 Características do sistema rotor-mancais

Os resultados apresentados nesta seção foram obtidos considerando um sistema rotor-mancais, cujas características do mancal cilíndrico e as condições de operação são apresentados na Tabela 4-1.

Tabela 4-1: Características do mancal cilíndrico.

Descrição	Símbolo	Valor	Unidade
Diâmetro do mancal	$D$	31,0	$mm$
Largura do mancal	$L$	20,0	$mm$
Viscosidade dinâmica	$\mu$	50,0	$mPa.s$
Folga radial	$C_r$	90,0	$\mu m$

Para calcular as forças hidrodinâmicas pelo método dos volumes finitos (MVF), é necessário definir o tamanho da malha. A Figura 4-1 apresenta as forças

hidrodinâmicas e o tempo de solução em função do tamanho da malha, sendo calculados a partir de uma razão de excentricidade de 0,4, ângulo de atitude de  $\pi/4 \text{ rad}$ , velocidades de translações do eixo nulas e uma velocidade de rotação de  $15 \text{ Hz}$ . O critério de convergência utilizado no cálculo das forças é apresentado na Eq. (3.26), considerando o erro total do campo de pressão entre duas iterações abaixo de  $10^{-2} \text{ Pa}$ . Com base nos resultados obtidos, a malha por volumes finitos utilizada neste trabalho foi de  $N_x = N_z = 40$ , com tempo médio de  $50 \text{ ms}$  para realizar uma estimativa das forças hidrodinâmicas. A Figura 4-2 apresenta o perfil de pressão no plano central do mancal, estimado com a malha definida.

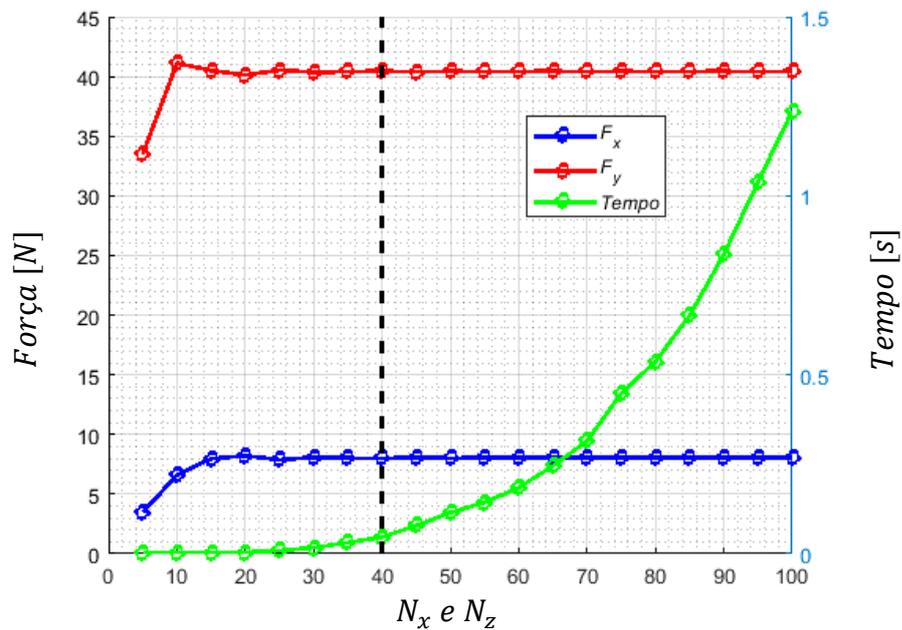


Figura 4-1: Testes de convergência de malha.

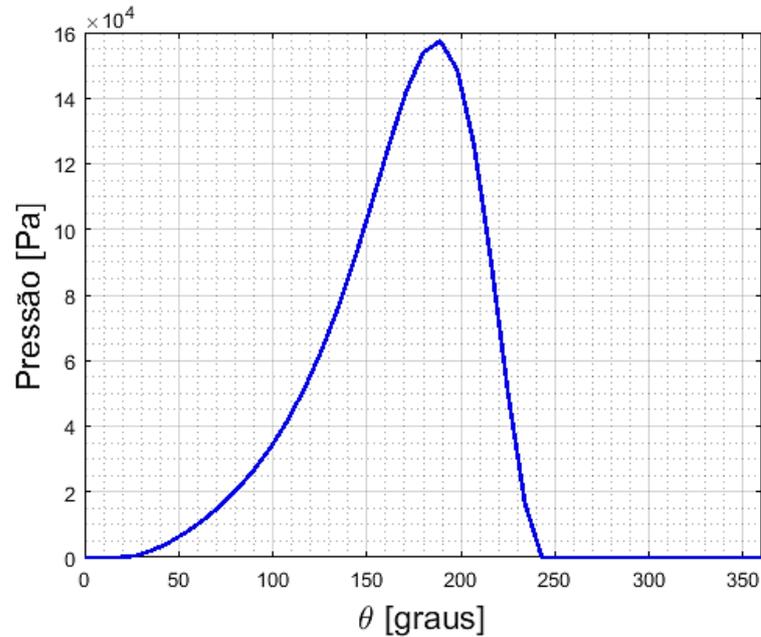


Figura 4-2: Campo de pressão estimado.

A Figura 4-3 apresenta a discretização do rotor utilizado neste trabalho. Trata-se de um rotor com disco centralizado e bi-apoiado em mancais hidrodinâmicos simétricos. Conforme pode ser observado, o modelo possui 10 elementos de viga, um elemento de disco e 2 elementos de mancais. Assim, o rotor foi discretizado em 11 nós, com 44 graus de liberdade (GDL) no total. Este sistema rotativo possui duas geometrias, caracterizando um rotor flexível e um rotor mais rígido (denominado neste trabalho como rígido), cujas dimensões são descritas na Tabela 4-2. É importante destacar que a dimensão do disco centralizado é a mesma para ambos os rotores. Por fim, as características dos materiais do eixo e do disco são apresentadas na Tabela 4-3.

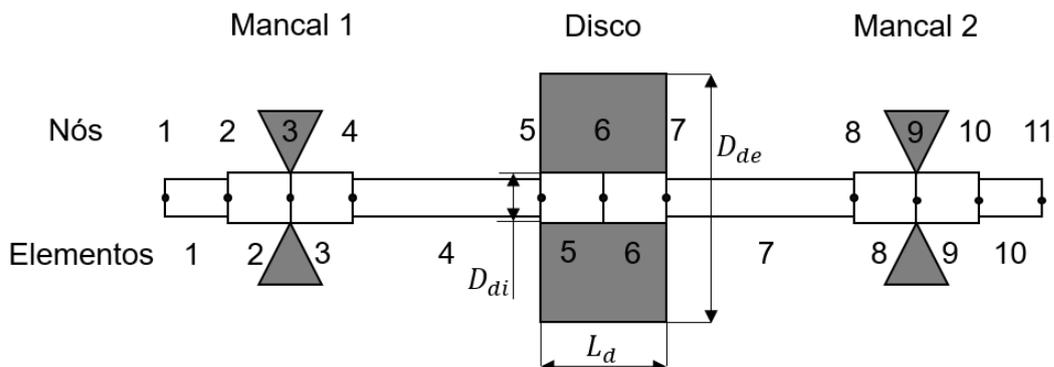


Figura 4-3: Rotor discretizado em elementos finitos.  
Fonte: Adaptada de (OLIVEIRA, 2021).

Tabela 4-2: Dimensões dos rotores (unidades em milímetros).

Elementos	Rotor flexível		Rotor Rígido	
	Comprimento	Diâmetro	Comprimento	Diâmetro
1, 10	40,0	12,0	40,0	17,7
2, 3, 8, 9	10,0	31,0	10,0	31,0
4, 7	266,5	12,0	100,5	17,7
5, 6	23,5	23,5	23,5	23,5

Tabela 4-3: Propriedades dos materiais e dimensões do disco rígido.

Descrição	Símbolo	Valor	Unidade
Módulo de elasticidade	$E$	200,0	$GPa$
Densidade	$\rho$	7850,0	$kg/m^3$
Constante de proporcionalidade de massa	$\alpha$	0,0	$1/m^2s$
Constante de proporcionalidade de rigidez	$\beta$	$10^{-4}$	$s$
Constante gravitacional	$g$	9,81	$m/s^2$
Largura do disco	$L_d$	47	$mm$
Diâmetro externo do disco	$D_{de}$	47,35	$mm$
Diâmetro interno do disco	$D_{di}$	11,75	$mm$

Para as duas geometrias de rotores considerados neste trabalho, as cargas radiais estáticas aplicadas nos dois mancais são as mesmas. Sendo assim, os coeficientes equivalentes de rigidez e amortecimento podem ser calculados e aplicados em ambos os rotores. A Figura 4-4 e a Figura 4-5 apresentam os coeficientes equivalentes de rigidez e amortecimento, respectivamente, calculados de 10 até 300 Hz. Estes coeficientes são utilizados para determinar o diagrama de Campbell desses sistemas rotor-mancais.

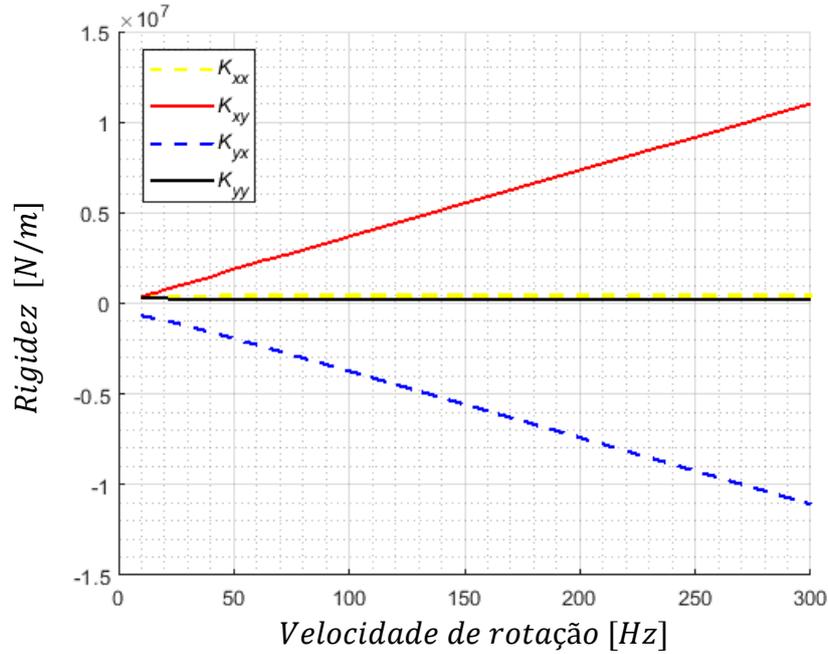


Figura 4-4: Coeficientes equivalentes de rigidez.

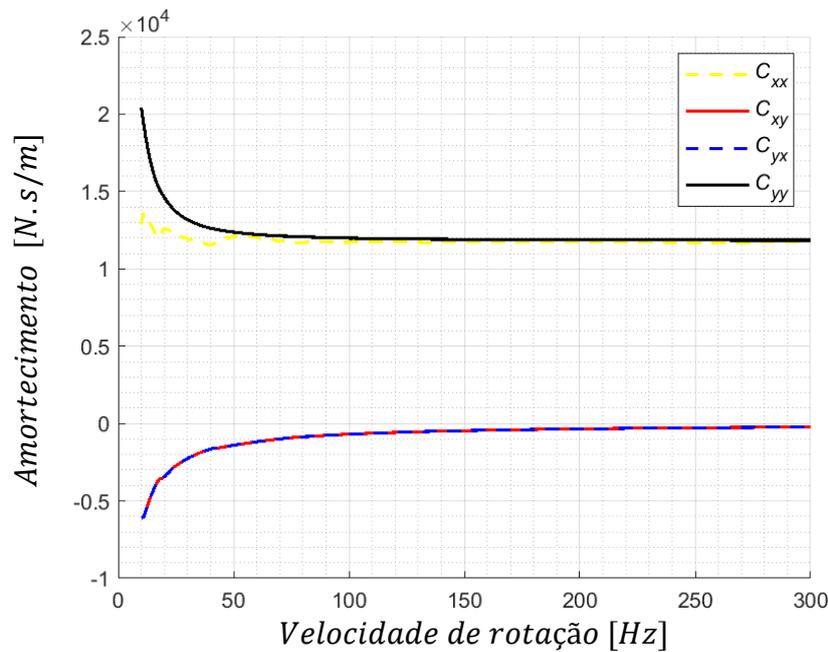


Figura 4-5: Coeficientes equivalentes de amortecimento.

A variação das frequências naturais do sistema em função da velocidade de rotação é apresentada pelo diagrama de Campbell. A Figura 4-6 e a Figura 4-7 apresentam o diagrama de Campbell do rotor flexível e rígido, respectivamente. A linha tracejada azul das figuras representa uma excitação 1X ( $\omega = \Omega$ ), equivalente a uma excitação por desbalanceamento do rotor, o que é muito comum em máquinas rotativas.

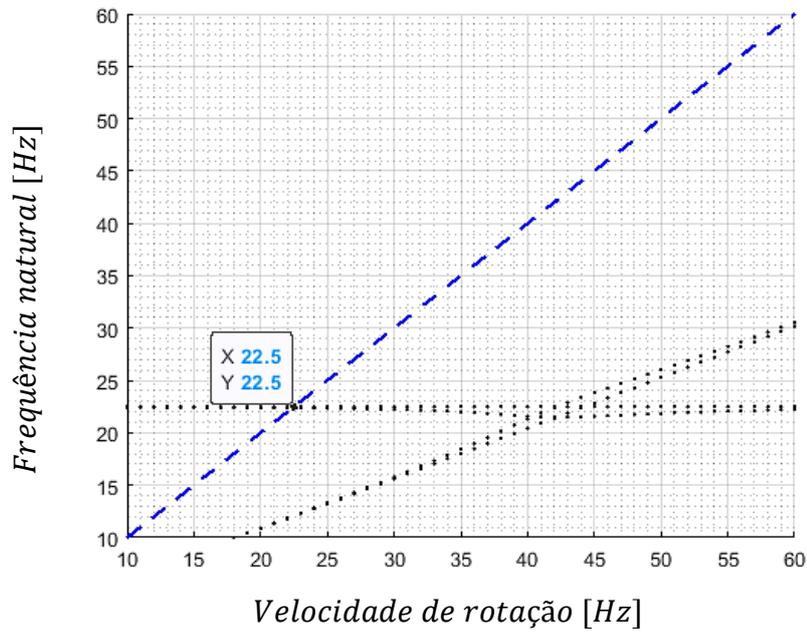


Figura 4-6: Diagrama de Campbell do rotor flexível.

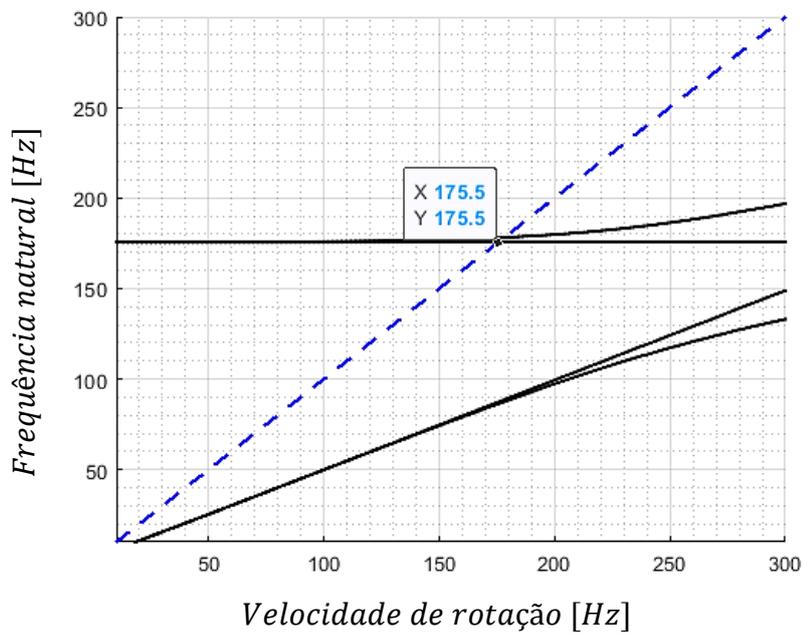


Figura 4-7: Diagrama de Campbell do rotor rígido.

A partir desses diagramas é possível identificar a primeira velocidade crítica do rotor flexível em torno de 22,5 Hz, enquanto a primeira velocidade crítica do rotor rígido está próxima de 175,5 Hz.

## 4.2 Banco de dados dos modelos substitutos

Com o intuito de analisar o desempenho dos modelos substitutos no cálculo das forças hidrodinâmicas para mancais cilíndricos, foram gerados diferentes bancos de dados para treinamento ou interpolação. Além disso, foi gerado também um banco de dados de teste para aplicação nos modelos substitutos, a fim de verificar a acuraria das respostas estimadas. Os bancos de dados foram gerados com base na solução da equação de Reynolds pelo método de volumes finitos, considerando quatro atributos de entrada para cada modelo substituto, sendo eles: a razão de excentricidade ( $\varepsilon$ ), o ângulo de atitude ( $\varphi$ ), e as velocidades de translação do rotor  $e_x$  e  $e_y$  nas direções  $X$  e  $Y$ , respetivamente.

Com o objetivo de gerar os bancos de dados, tanto para treinamento ou interpolação quanto para teste, é necessário primeiramente determinar os limites do domínio de cada atributo de entrada, para depois determinar as amostras dentro do domínio do mancal. Para tanto, foi realizada uma simulação do rotor flexível no domínio do tempo considerando uma velocidade de rotação de  $15 \text{ Hz}$  e  $G_{ISO}$  de  $6,3$ .

A Figura 4-8 apresenta o deslocamento e a velocidade de translação do rotor nos nós 3 e 9 (Mancal 1 e 2) e nas direções  $X$  e  $Y$ . Nesta figura, as linhas azuis representam o deslocamento e a velocidade, já as linhas pretas pontilhadas representam os limites estabelecidos para gerar os bancos de dados. Como os mancais são idênticos e simétricos, os cálculos das forças hidrodinâmicas são calculados apenas para um mancal utilizando o método dos volumes finitos, mas são aplicados nos dois mancais. A Tabela 4-4 apresenta os limites selecionados para cada atributo.

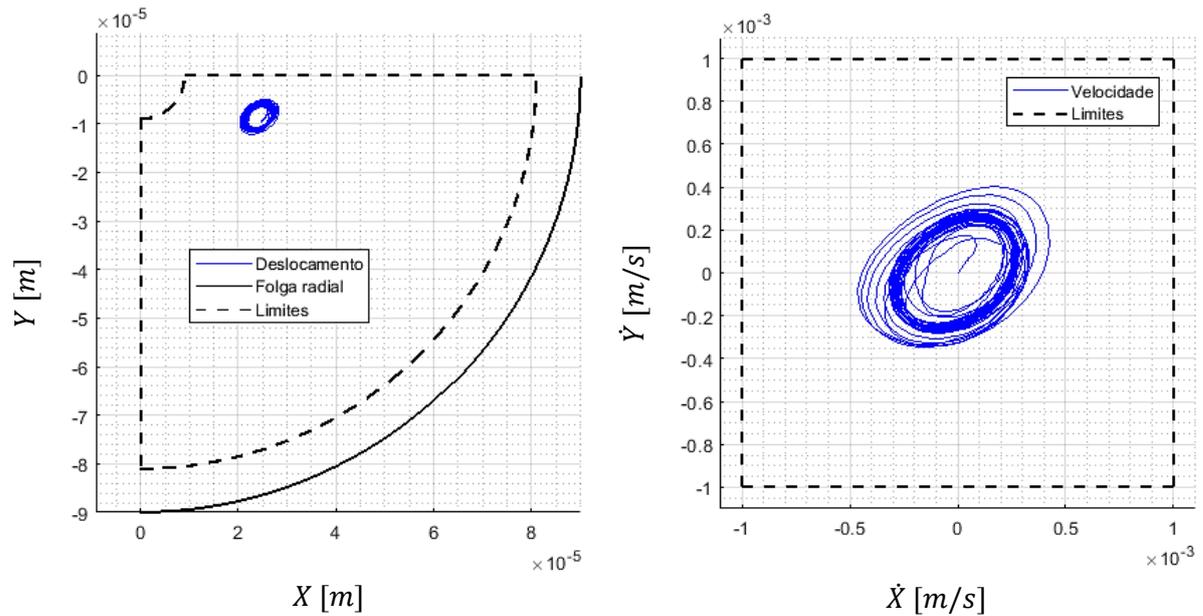


Figura 4-8: Análise da dinâmica do rotor para definição dos limites dos bancos de dados de treinamento ou interpolação e de teste.

Tabela 4-4: Atributos do mancal hidrodinâmico.

Atributos	Unidade	Mínimo	Máximo
$\varepsilon$	—	0,1	0,9
$\varphi$	<i>rad</i>	0	$\pi/2$
$\dot{e}_x$	<i>m/s</i>	-0,001	0,001
$\dot{e}_y$	<i>m/s</i>	-0,001	0,001

Para obter a solução adimensional da Equação de Reynolds é necessário normalizar as velocidades de translação do rotor pela sua velocidade de rotação e pela folga radial do mancal, conforme descrito nas Eqs. (3.13) e (3.14). Isto impõe uma limitação nos modelos substitutos, visto que, é necessário definir uma folga radial e uma velocidade de rotação mínima que não altere os limites estabelecidos. Neste trabalho, a folga radial mínima adotada foi de  $90 \mu m$  e a velocidade de rotação mínima foi de  $10 Hz$ . Logo, os modelos substitutos analisados neste trabalho não podem ser aplicados para um mancal cilíndrico com uma folga radial e velocidade de rotação menor do que a definida, pois, as velocidades de translação do rotor podem extrapolar os limites definidos na Tabela 4-4.

É importante mencionar que os modelos substitutos avaliados neste trabalho visam representar as forças hidrodinâmicas considerando uma condição genérica do eixo no interior do mancal. Por isso, os intervalos para os atributos de entrada foram

selecionados buscando uma ampla faixa. Por fim, com o intuito de avaliar diferentes modelos substitutos, foram gerados diferentes bancos de dados utilizando o método grid retangular, variando entre 4 até 10 amostras por atributo de entrada conforme apresentado na Tabela 4-5.

Tabela 4-5: Características dos bancos de dados para treinamento ou interpolação dos modelos substitutos.

Número de amostras por atributo de entrada				Número total de amostras
$\varepsilon$	$\varphi$	$e'_x$	$e'_y$	
4	4	4	4	256
5	5	5	5	625
6	6	6	6	1296
7	7	7	7	2401
8	8	8	8	4096
9	9	9	9	6561
10	10	10	10	10000

O banco de teste é formado com 10 amostras por atributo de entrada, totalizando 10000 amostras de teste, sendo que os atributos de entrada foram selecionados através de uma distribuição uniforme dentro dos limites estabelecidos pela Tabela 4-4. Em todos os bancos de dados, tanto os de treinamento ou interpolação quanto o de teste, as forças  $F_X$  e  $F_Y$  são calculadas com relação ao sistema inercial do mancal utilizando o método dos volumes finitos dada as entradas conhecidas dos bancos de dados.

### 4.3 Treinamento e testes com os modelos substitutos

Neste trabalho, foram aplicadas as redes neurais MLP. Essas redes foram geradas e treinadas com o auxílio do software *Matlab*®. Em geral, as redes são compostas de uma camada de entrada com 4 neurônios, 10 camadas intermediárias com 10 neurônios por camada e uma camada de saída com 2 neurônios. Para determinar o número de camadas intermediárias e o número de neurônios destas camadas foi realizado um teste preliminar com as redes neurais, os resultados obtidos são apresentados no Apêndice A.

As redes foram geradas utilizando a função *'feedforwardnet'*. O treinamento de todas as redes foi realizado por meio da função *'train'*, com a inicialização de todos os *bias* e pesos dos neurônios nulas. A função aplicada para avaliar o desempenho da rede foi o erro quadrático médio e a função de ativação dos neurônios utilizada foi a tangente hiperbólica. A função de busca utilizada no treinamento foi a *'trainlm'*, que emprega o método de Levenberg-Marquardt. A aplicação do método de Levenberg-Marquardt no treinamento de redes neurais é demonstrada por Hagan e Menhaj (1994).

Durante a etapa de treinamento das redes neurais, os dados de treinamento são separados em dois subconjuntos selecionados aleatoriamente com distribuição uniforme: subconjunto de treinamento, com 80% dos dados, e subconjunto de validação, com os demais 20%. Este procedimento foi adotado para realizar a validação cruzada dos dados durante a etapa de treinamento, evitando assim o sobreajuste dos modelos.

Os métodos de interpolação linear, cúbica e *spline* não necessitam de uma etapa de treinamento. As interpolações foram realizadas utilizando a função *'interp'* do *software Matlab®*, onde os bancos de dados de interpolação são fornecidos e o *software* realiza o tipo de interpolação especificado para cada nova amostra. A Figura 4-9 apresenta um fluxograma com os passos seguidos para treinamento e teste dos modelos substitutos.

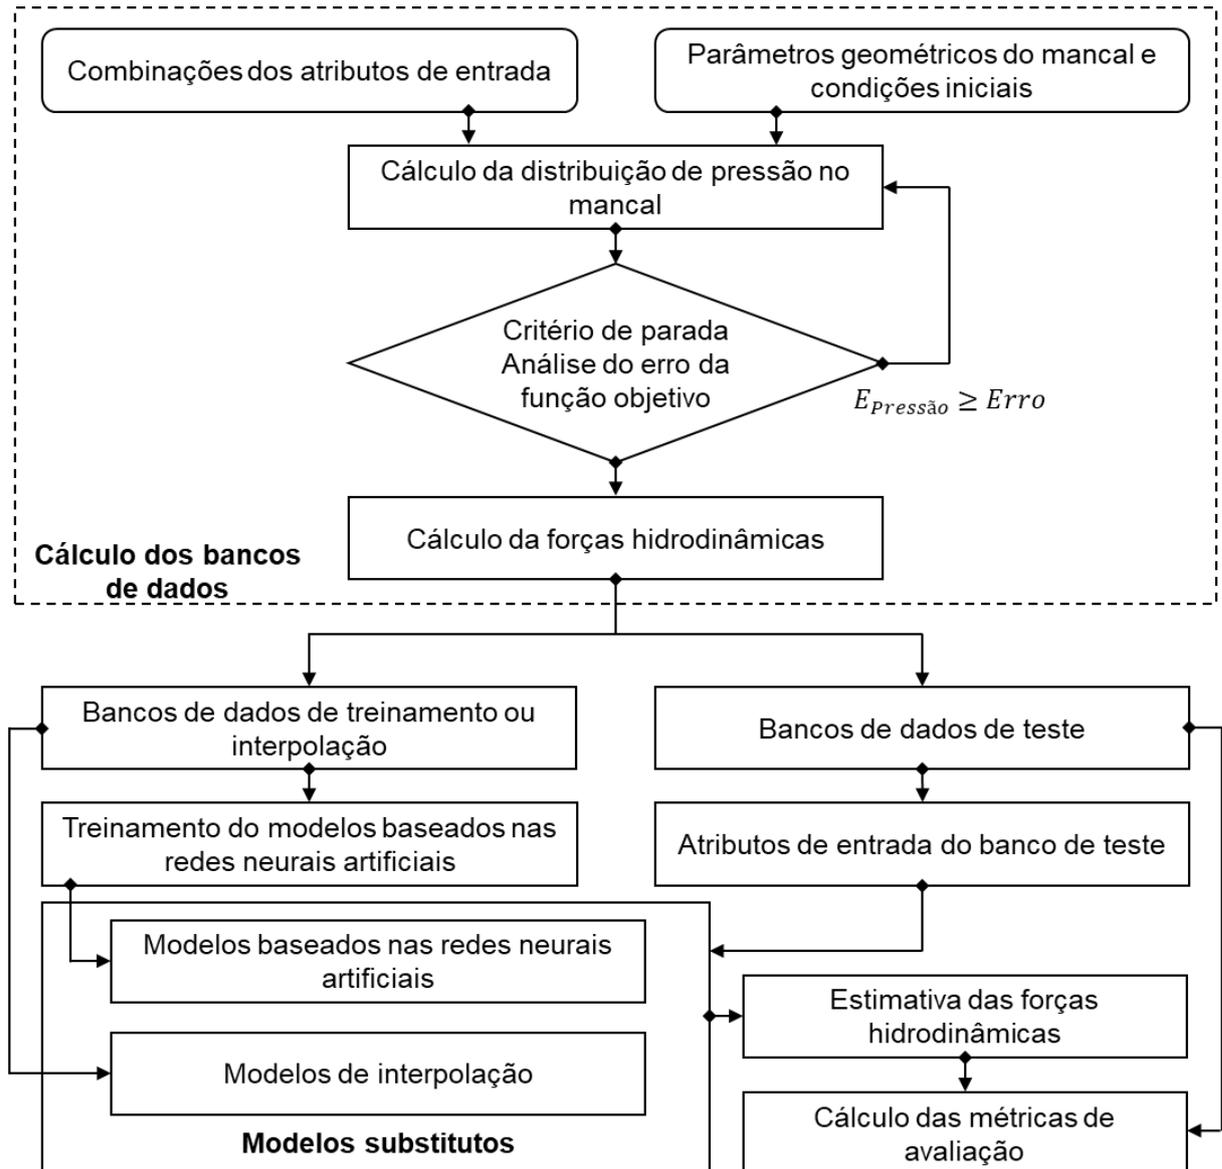


Figura 4-9: Fluxograma da aplicação dos modelos substitutos.

Após o treinamento das redes neurais, todos os modelos substitutos foram testados com o mesmo banco de teste, que possui 10000 amostras geradas através de uma distribuição uniforme dentro dos limites estabelecidos. As Tabelas 4-5, 4-6, 4-7, 4-8 e 4-9 apresentam os resultados das métricas  $RMSE_X$ ,  $RMSE_Y$ ,  $ERMF_R$ ,  $R_X^2$  e  $R_Y^2$  respectivamente, com relação as forças hidrodinâmicas obtidas com os dados de teste. Cada tabela apresenta uma comparação dos resultados de uma métrica entre os modelos substitutos aplicados com diferentes números de amostras de treinamento ou interpolação, considerando as forças hidrodinâmicas obtidas através da solução pelo método dos volumes finitos.

Tabela 4-6: Comparação dos resultados do  $RMSE$  da força na direção  $X$  entre os modelos substitutos utilizados com diferentes números de amostras de treinamento ou interpolação.

<i>Amostras de treinamento ou interpolação</i>	<i>RMSE<sub>X</sub></i>			
	<i>Rede Neural</i>	<i>Int. Linear</i>	<i>Int. Cúbica</i>	<i>Int. Spline</i>
<b>256</b>	$102,15 * 10^{-5}$	$38,97 * 10^{-5}$	$24,32 * 10^{-5}$	$19,51 * 10^{-5}$
<b>625</b>	$39,51 * 10^{-5}$	$21,80 * 10^{-5}$	$12,64 * 10^{-5}$	$8,12 * 10^{-5}$
<b>1296</b>	$0,445 * 10^{-5}$	$8,22 * 10^{-5}$	$3,96 * 10^{-5}$	$2,50 * 10^{-5}$
<b>2401</b>	$0,190 * 10^{-5}$	$1,51 * 10^{-5}$	$2,31 * 10^{-5}$	$1,29 * 10^{-5}$
<b>4096</b>	$0,144 * 10^{-5}$	$2,48 * 10^{-5}$	$3,06 * 10^{-5}$	$1,76 * 10^{-5}$
<b>6561</b>	$0,104 * 10^{-5}$	$2,65 * 10^{-5}$	$2,43 * 10^{-5}$	$1,53 * 10^{-5}$
<b>10000</b>	$0,079 * 10^{-5}$	$2,25 * 10^{-5}$	$1,39 * 10^{-5}$	$1,04 * 10^{-5}$

Tabela 4-7: Comparação dos resultados do  $RMSE$  da força na direção  $Y$  entre os modelos substitutos utilizados com diferentes números de amostras de treinamento ou interpolação.

<i>Amostras de treinamento ou interpolação</i>	<i>RMSE<sub>Y</sub></i>			
	<i>Rede Neural</i>	<i>Int. Linear</i>	<i>Int. Cúbica</i>	<i>Int. Spline</i>
<b>256</b>	$122,74 * 10^{-5}$	$66,56 * 10^{-5}$	$43,74 * 10^{-5}$	$35,16 * 10^{-5}$
<b>625</b>	$72,24 * 10^{-5}$	$37,63 * 10^{-5}$	$22,40 * 10^{-5}$	$14,07 * 10^{-5}$
<b>1296</b>	$0,736 * 10^{-5}$	$14,28 * 10^{-5}$	$6,90 * 10^{-5}$	$4,27 * 10^{-5}$
<b>2401</b>	$0,312 * 10^{-5}$	$2,71 * 10^{-5}$	$3,99 * 10^{-5}$	$2,18 * 10^{-5}$
<b>4096</b>	$0,244 * 10^{-5}$	$4,47 * 10^{-5}$	$5,23 * 10^{-5}$	$2,98 * 10^{-5}$
<b>6561</b>	$0,156 * 10^{-5}$	$4,79 * 10^{-5}$	$4,10 * 10^{-5}$	$2,57 * 10^{-5}$
<b>10000</b>	$0,135 * 10^{-5}$	$4,18 * 10^{-5}$	$2,32 * 10^{-5}$	$1,75 * 10^{-5}$

Tabela 4-8: Comparação dos resultados do  $ERMF_R$  entre os modelos substitutos utilizados com diferentes números de amostras de treinamento ou interpolação.

<i>Amostras de treinamento ou interpolação</i>	<i>ERMF<sub>R</sub> [%]</i>			
	<i>Rede Neural</i>	<i>Int. Linear</i>	<i>Int. Cúbica</i>	<i>Int. Spline</i>
<b>256</b>	156,5293	46,2089	34,4104	95,5717
<b>625</b>	45,7743	29,0566	16,7149	21,5189
<b>1296</b>	7,6776	10,3721	4,4361	5,8331

<b>2401</b>	4,2713	6,9597	2,8673	2,9683
<b>4096</b>	3,3441	7,2313	3,1971	2,6074
<b>6561</b>	2,1515	5,4497	1,9852	1,5626
<b>10000</b>	1,6254	4,9848	1,4899	1,2604

Tabela 4-9: Comparação dos resultados do coeficiente de determinação  $R^2$  da força na direção  $X$  entre os modelos substitutos utilizados com diferentes números de amostras de treinamento ou interpolação.

<i>Amostras de treinamento ou interpolação</i>	$R_X^2$			
	<i>Rede Neural</i>	<i>Int. Linear</i>	<i>Int. Cúbica</i>	<i>Int. Spline</i>
<b>256</b>	-0,9824	-0,9274	0,2492	0,5165
<b>625</b>	0,3745	0,3948	0,7971	0,9161
<b>1296</b>	0,9997	0,9142	0,9801	0,9920
<b>2401</b>	1,000	0,9971	0,9932	0,9979
<b>4096</b>	1,000	0,9922	0,9880	0,9960
<b>6561</b>	1,000	0,9911	0,9924	0,9970
<b>10000</b>	1,000	0,9936	0,9975	0,9986

Tabela 4-10: Comparação dos resultados do coeficiente de determinação  $R^2$  da força na direção  $Y$  entre os modelos substitutos utilizados com diferentes números de amostras de treinamento ou interpolação.

<i>Amostras de treinamento ou interpolação</i>	$R_Y^2$			
	<i>Rede Neural</i>	<i>Int. Linear</i>	<i>Int. Cúbica</i>	<i>Int. Spline</i>
<b>256</b>	-1,4676	-1,0951	0,0941	0,4154
<b>625</b>	0,3092	0,3291	0,7627	0,9064
<b>1296</b>	0,9997	0,9043	0,9775	0,9914
<b>2401</b>	1,000	0,9965	0,9925	0,9977
<b>4096</b>	1,000	0,9905	0,9870	0,9958
<b>6561</b>	1,000	0,9891	0,9920	0,9969
<b>10000</b>	1,000	0,9917	0,9974	0,9986

Em geral, os resultados obtidos com os bancos de 256 e 625 amostras apresentaram métricas de avaliação com menor precisão<sup>3</sup> para todos os modelos substitutos. Todavia, conforme o número de amostras de treinamento ou interpolação aumentam, os resultados obtidos apresentam melhores métricas de avaliação. Com relação ao baixo número de amostras, a rede neural, interpolação cúbica e *spline* são as que mais se destacaram, pois, a partir de 1296 amostras de treinamento ou interpolação, os modelos já apresentaram uma boa precisão para as métricas de avaliação. A interpolação linear apresenta bons resultados somente a partir de 2401 amostras de interpolação.

É possível notar que a Tabela 4-9 e a Tabela 4-10 apresentam coeficientes de determinação menor do que zero, que representa um ajuste pior do que a média do modelo original para um caso linear. Logo, os valores negativos apenas representam um ajuste muito ruim do modelo, sendo que a regra de que quanto mais próximo de 1 for o coeficiente de determinação maior é a precisão da saída estimada com a saída original.

A Figura 4-10 e a Figura 4-11 apresentam a comparação entre as forças hidrodinâmicas adimensionais calculadas pelo método de volumes finitos e as forças estimadas pelo modelo substituto via interpolação *spline* com 10000 amostras de interpolação nas direções x e y, respectivamente. O modelo substituto foi selecionado por apresentar a maior precisão com relação aos resultados apresentados na Tabela 4-8.

---

<sup>3</sup> Neste caso, precisão nas métricas de avaliação dos modelos substitutos refere-se a baixos valores de  $RMSE$  e  $ERMF_R$  e coeficiente de determinação próximos de 1.

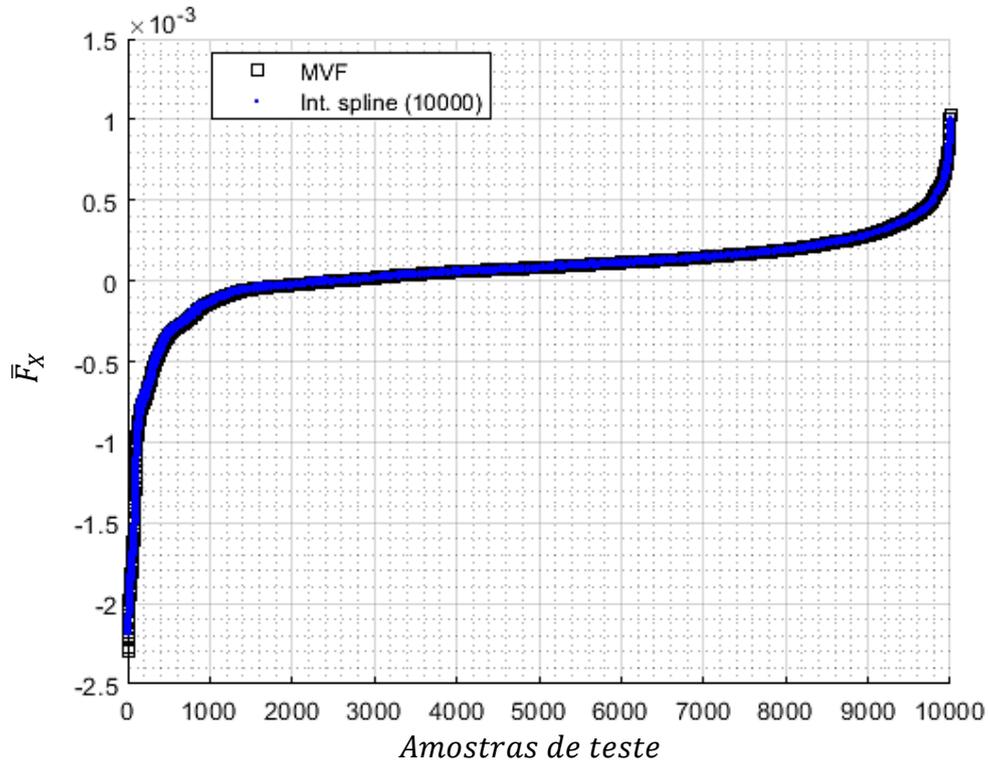


Figura 4-10: Comparação das forças hidrodinâmicas adimensionais na direção .

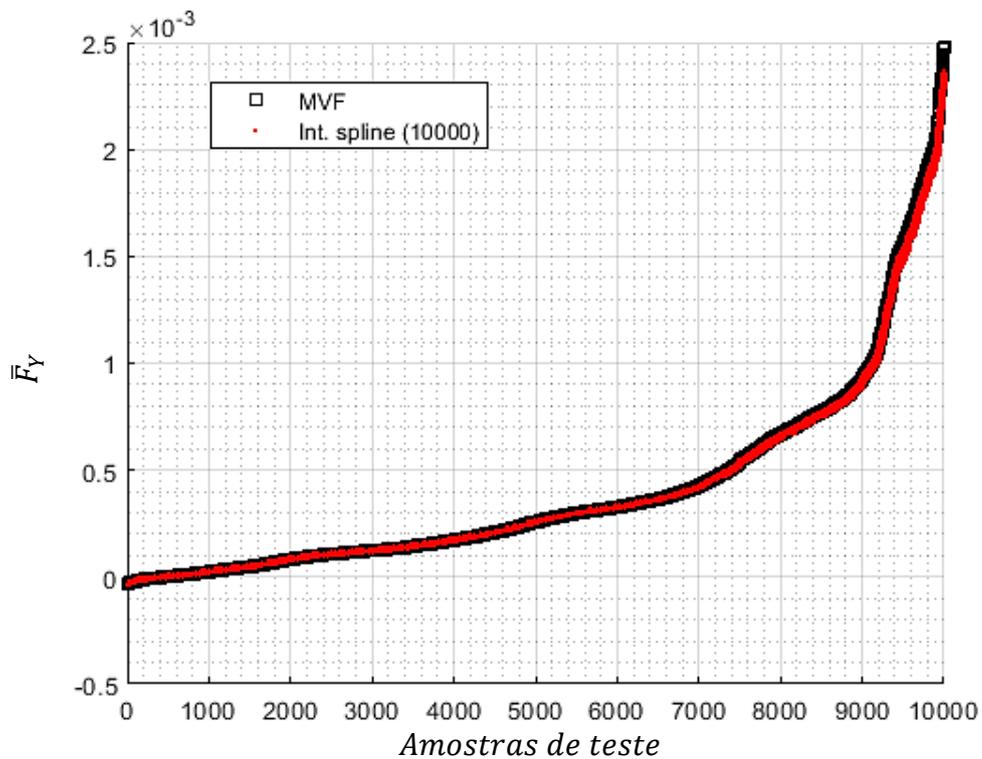


Figura 4-11: Comparação das forças hidrodinâmicas adimensionais na direção Y.

A Tabela 4-11 apresentam as estimativas de tempo que as redes neurais, levaram para calcular uma amostra ( $T_a$ ) e para realizar o treinamento do modelo ( $T_t$ ).

A Tabela 4-12 apresenta as estimativas de tempo que as três interpolações levaram para calcular uma amostra ( $T_a$ ). Vale ressaltar que as interpolações não dependem de treinamento, logo, não possuem tempo para treinamento dos modelos. Os resultados foram obtidos com o *software Matlab®* em um computador com processador Intel® core™ i5-8265U CPU 1,6Ghz com memória RAM de 16 GB.

Tabela 4-11: Tempos para efetuar as estimativas e o treinamento da rede neural com diferentes números de amostras de treinamento.

<b><i>Amostras de treinamento</i></b>	<b><math>T_a</math> [ms]</b>	<b><math>T_t</math> [s]</b>
<b>256</b>	7,5040	0,3471
<b>625</b>	7,3869	0,4080
<b>1296</b>	7,3516	2,6552
<b>2401</b>	7,6040	8,3320
<b>4096</b>	7,3835	23,5781
<b>6561</b>	7,6833	71,2445
<b>10000</b>	6,9723	93,3489

Tabela 4-12: Tempos para efetuar uma estimativa nas três interpolações com diferentes números de amostras de interpolação.

<b><i>Amostras de interpolação</i></b>	<b><math>T_a</math> [ms]</b>		
	<b><i>Int. Linear</i></b>	<b><i>Int. Cúbica</i></b>	<b><i>Int. Spline</i></b>
<b>256</b>	0,6701	0,8749	0,8620
<b>625</b>	0,6692	0,8184	0,8796
<b>1296</b>	0,6702	0,8256	0,9436
<b>2401</b>	0,6688	0,8395	1,1768
<b>4096</b>	0,6750	0,8244	1,1949
<b>6561</b>	0,6667	0,8172	1,3946
<b>10000</b>	0,6698	0,8334	1,6538

Os resultados obtidos nessas análises mostram que para os modelos substitutos via rede neural, interpolação linear e cúbica, o tempo para realizar a estimativa de uma amostra permanece constante independentemente do número de amostras de

treinamento ou interpolação. Por outro lado, as interpolações *spline* apresentam uma tendência de aumento do tempo para realizar a estimativa de uma amostra ( $T_a$ ) quanto maior o número de amostras de interpolação. Além disso, é possível notar que o tempo para realizar o treinamento das redes neurais aumenta conforme o número de amostras de treinamento.

Em geral, o modelo que apresentou o menor custo computacional para o cálculo de uma amostra foi a interpolação linear, seguida pela interpolação cúbica, interpolação *spline* e, por fim, a rede neural. Com relação ao custo computacional individual de cada modelo apresentado para realizar a estimativa de uma amostra, as três interpolações apresentaram resultados excelentes quando comparados com os resultados obtidos com as redes neurais. Ainda, as interpolações independem de uma etapa de treinamento, sendo necessário apenas a aplicação do método com relação aos dados de base, reduzindo a complexidade do modelo.

#### 4.4 Classificação de defeitos

Um dos defeitos mais comuns em máquinas rotativas é o desbalanceamento, que pode ser provocado por alterações na distribuição de massa do rotor. Quando ocorre em elevados níveis, pode provocar desgastes e danos aos mancais com consequente falha. Desta forma, a detecção e diagnóstico deste tipo de defeito é de suma importância.

Para realizar a classificação de defeitos, as redes neurais convolucionais devem ser treinadas com bancos contendo as imagens de vibração com os devidos rótulos. Neste trabalho, essas imagens de vibração são geradas a partir dos sinais de vibração simulados do rotor com diferentes condições de desbalanceamento. Para isso, os bancos de dados são formados através de simulações dos rotores no domínio do tempo, considerando diferentes condições de temperatura do óleo do mancal, velocidade de rotação e desbalanceamento permissível do rotor. Os dados gerados são classificados em três classes diferentes de desbalanceamento, sendo que as classes são definidas a partir do grau de qualidade de desbalanceamento,  $G_{ISO}$ , conforme apresentado na Tabela 4-13. Entretanto, nas simulações realizadas para a geração dos dados, foram definidos valores de mínimo e máximo aplicados no grau de qualidade de desbalanceamento de 2,5 e 6,3, respectivamente. Estes limites foram

estabelecidos para garantir que o deslocamento e as velocidades do rotor não ultrapassem os limites aplicados nos modelos substitutos.

Tabela 4-13: Definição das classes de defeitos.

<i>Desbalanceamento</i>	<i>Classe</i>
$G_{ISO} \leq 3,7$	1
$3,7 < G_{ISO} \leq 4,5$	2
$4,5 < G_{ISO}$	3

As redes neurais convolucionais são treinadas e aplicadas em 4 conjuntos de dados para a classificação de defeitos, conforme apresenta a Tabela 4-14. Estes conjuntos foram definidos para avaliar o desempenho da rede de classificação e do modelo substituto do mancal em diferentes situações. Os conjuntos de baixa e elevada rotação foram definidos a partir do diagrama de Campbell do rotor flexível (Figura 4-6), com o intuito de analisar o rotor flexível com velocidades de rotação abaixo e acima da velocidade crítica. Embora o mesmo não ocorra para o caso do rotor rígido, essas velocidades para os conjuntos de baixa e elevada rotação são aplicadas para ambas as geometrias do rotor, apenas para fins de comparação.

Tabela 4-14: Conjuntos de defeitos analisados.

Conjunto de dados	Geometria do rotor	Velocidade de rotação
1	Flexível	Baixa
2	Flexível	Elevada
3	Rígido	Baixa
4	Rígido	Elevada

O grau de qualidade de desbalanceamento depende da massa total do rotor, da velocidade de rotação e da massa de desbalanceamento permissível do rotor conforme descrito pela Eq. (3.41) e (3.42). Logo, para não extrapolar os limites estabelecidos dos conjuntos de dados de baixa e elevada rotação, os valores mínimos e máximos do desbalanceamento permissível são ajustados de acordo com a velocidade de rotação do rotor. A Tabela 4-15 e a Tabela 4-16 apresentam os valores mínimos e máximos dos atributos dos bancos de dados de treinamento e de teste da rede neural convolucional, para os conjuntos de baixa e elevada rotação, respectivamente. Vale ressaltar que as duas geometrias do rotor analisadas neste

trabalho apresentam a mesma massa total, logo, os limites dos conjuntos de baixa e elevada rotação podem ser aplicados em ambas as geometrias.

Tabela 4-15: Limites dos atributos para os bancos de baixa rotação.

Atributos	Unidade	Mínimo	Máximo
<i>Temp. do óleo</i> [T]	°C	25	35
<i>Rotação</i> [Ω]	Hz	10	15
<i>Desb. perm.</i> [ $U_{per}$ ]	<i>mkg</i>	$1,3448 * 10^{-4}$ ( $G_{ISO}$ 2,5)	$2,2593 * 10^{-4}$ ( $G_{ISO}$ 6,3)

Tabela 4-16: Limites dos atributos para os bancos de elevada rotação.

Atributos	Unidade	Mínimo	Máximo
<i>Temp. do óleo</i> [T]	°C	45	55
<i>Rotação</i> [Ω]	Hz	30	35
<i>Desb. perm.</i> [ $U_{per}$ ]	<i>mkg</i>	$4,4827 * 10^{-4}$ ( $G_{ISO}$ 2,5)	$9,6827 * 10^{-4}$ ( $G_{ISO}$ 6,3)

As condições de temperatura do óleo influenciam na sua viscosidade dinâmica e, por sua vez, alteram a sustentação de carga do mancal. Neste trabalho, o cálculo da viscosidade dinâmica do fluido lubrificante (ISO VG 32) é dado pela Equação de Vogel (4.1), conforme descrito por Knežević e Savić (2006).

$$\mu(T) = 736,317 * 10^{-7} \exp\left(\frac{797,7122}{(T + 273,15) - 177,3562}\right) \quad (4.1)$$

onde  $T$  é a temperatura do óleo em graus Celsius.

Os bancos de dados podem ser formados por sinais de deslocamento, velocidade e aceleração, nas direções  $X$ ,  $Y$  e de amplitude resultante ( $R = \sqrt{X^2 + Y^2}$ ). Desta forma, os sinais de deslocamento nas direções  $X$ ,  $Y$  e de amplitude resultante foram separados e analisados durante as etapas de classificação. Por fim, os sinais de vibração aplicados neste trabalho são os de amplitude resultante de deslocamento no nó 3 do rotor (Mancal 1). Além disso, destaca-se que os sinais de deslocamento aplicados são órbitas do rotor após atingir o regime permanente.

Para obter os sinais de deslocamento em regime permanente, as simulações do comportamento dinâmico do rotor com os modelos substitutos foram realizadas no

domínio do tempo com duração de 4 segundos e frequência de amostragem de 1 *kHz*, sendo que a condição de regime permanente é obtida considerando apenas o último segundo de simulação. É importante ressaltar que os bancos de dados são normalizados por meio de um mapeamento linear entre a amplitude de deslocamento mínima e máxima do banco de dados de treinamento. Sendo assim, a amplitude de deslocamento mínima do banco de dados assume o valor de 0 e a amplitude máxima assume o valor 1.

A partir desses sinais de deslocamento do rotor, as imagens de vibração são formadas conforme proposto por Hoang e Kang (2018). Para isso, o comprimento do segmento do sinal deve ser longo o suficiente para capturar as características localizadas dos sinais, porém, não deve ser muito longo para não tornarem o modelo do classificador muito complexo. Neste trabalho, a imagem de vibração contém dimensões quadradas de 30 × 30 pixels, totalizando 900 pontos por imagem, sendo um recorte do sinal em regime permanente. A Figura 4-12 apresenta as imagens de vibração geradas a partir do deslocamento do rotor flexível para o caso de baixa rotação, considerando as três classes de desbalanceamento.

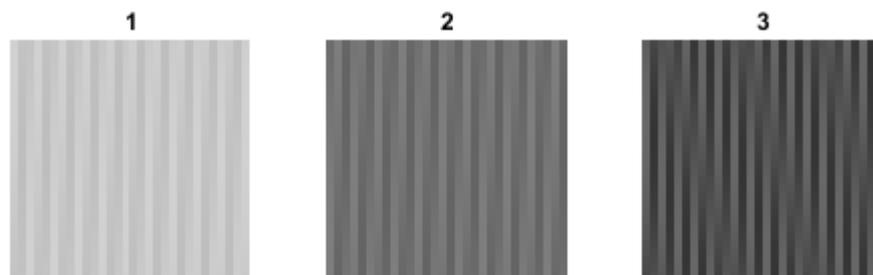


Figura 4-12: Imagens de vibração dos sinais gerados com rótulos.

Neste trabalho, foram selecionados 7 modelos para estimar as forças hidrodinâmicas dos mancais, a saber, a solução por coeficientes equivalentes, as redes neurais artificiais treinadas com 625, 2401 e 6561 amostras e as interpolações cúbicas com bancos de interpolação de 625, 2401 e 6561 amostras. Cada modelo foi aplicado para gerar os 4 conjuntos de dados para classificação (flexível-baixa rotação, flexível-elevada rotação, rígido-baixa rotação, rígido-elevada rotação). No entanto, a rede neural artificial treinada com 625 amostras não foi capaz de gerar todos os 4 conjuntos de bancos de dados, pois, devido à baixa precisão na estimativa das forças hidrodinâmicas, este modelo extrapolou os limites dos modelos substitutos

estabelecidos na Tabela 4-4 durante as simulações dos rotores no domínio do tempo. Logo, as análises são realizadas apenas para as redes treinadas com 2401 e 6561 amostras.

Foram gerados dois volumes de dados para treinamento das redes neurais convolucionais, o primeiro volume contém 1200 amostras e o segundo volume contém 2400 amostras. Estes dados de treinamento foram gerados a partir das condições de temperatura do óleo, velocidade de rotação e massa de desbalanceamento permissível, com amostras igualmente espaçadas dentro do domínio estabelecido pela Tabela 4-15 e Tabela 4-16. A Tabela 4-17 apresenta o número de amostras para cada bancos de dados de treinamento e teste. Para cada conjunto de dados foi gerado um banco de teste com 288 amostras obtidas a partir de uma distribuição uniforme.

Tabela 4-17: Número de amostras por variável dos bancos de dados para treinamento e teste das redes neurais convolucionais.

Banco de dados	Número de amostras por variável			Número total de amostras
	<i>Temp.</i> [T]	<i>Rotação</i> [ $\Omega$ ]	<i>Desb. perm.</i> [ $U_{per}$ ]	
<i>Treinamento (volume 1)</i>	10	6	20	1200
<i>Treinamento (volume 2)</i>	10	12	20	2400
<i>Teste</i>	4	6	12	288

Os bancos de dados gerados podem ser aumentados aplicando ruído gaussiano branco com diferentes níveis de relação SNR nos sinais de vibração. Segundo Alves et al. (2020), a aplicação de níveis de SNR menores do que 10 distorcem o sinal significativamente, podendo causar efeitos adversos na precisão da classificação. Ainda, os níveis de SNR superiores a 18 não geram diferenças significativas entre os sinais de vibração. Logo, os níveis 10, 12, 14, 16 e 18 de SNR são aplicados nos bancos de dados, proporcionando um banco de dados 6 vezes maior do que o original. A Figura 4-13 apresenta as imagens de vibração com adição de ruído gaussiano branco em diferentes níveis SNR. Apenas para simplificar, os bancos de dados com amostras sem ruído são nomeados de bancos de dados naturais, e os bancos de dados com ruídos são nomeados de bancos de dados aumentados.

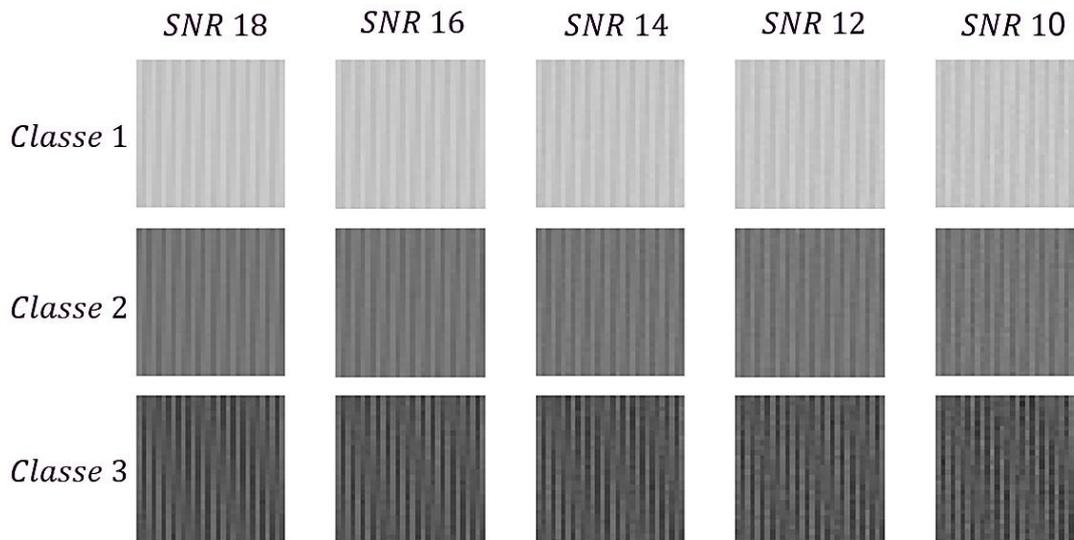


Figura 4-13: Imagens de vibração dos sinais gerados com adição de ruídos em diferentes níveis SNR.

A estrutura da rede neural convolucional de classificação aplicada neste trabalho foi baseada na estrutura apresentada por Hoang e Kang (2018). A rede neural convolucional possui duas camadas convolucionais e duas camadas de agrupamento, sendo que o tipo de agrupamento aplicado foi o *max-pooling*. Além disso, temos uma rede do tipo *feedforward*, totalmente conectada, com uma camada intermediária e três neurônios nessa camada e na saída, sendo a função logística considerada como função de ativação. As demais características da rede neural convolucional são apresentadas na Tabela 4-18.

Tabela 4-18: Características da estrutura da rede neural convolucional.

Camada	Número de Kernels	Tamanho do Kernel	Stride	Zero padding	Tamanho da saída
Convolução 1	30	5 × 5	1	igual	30 × 30
Agrupamento 1	30	2 × 2	2	nulo	15 × 15
Convolução 2	60	3 × 3	1	igual	15 × 15
Agrupamento 2	60	2 × 2	2	nulo	7 × 7

As redes neurais convolucionais de classificação aplicadas neste trabalho foram geradas e treinadas com o auxílio do software *Matlab*®. As camadas das redes neurais convolucionais foram geradas utilizando as funções '*convolution2dLayer*', para gerar as camadas convolucionais, '*maxPooling2dLayer*', para gerar as camadas

de agrupamento e *'fullyConnectedLayer'*, para gerar a rede totalmente conectada. O treinamento de todas as redes foi realizado por meio da função *'trainNetwork'*, com a inicialização de todos os *bias* e pesos dos neurônios e dos kernels como nulas. A função aplicada para avaliar o desempenho da rede foi a entropia cruzada e a função de ativação aplicada nas camadas de convolução foi a função *ReLU*. Por fim, a função de busca utilizada no treinamento foi a *'adam'*, que emprega o método de estimativa de momento adaptativo (ADAM do inglês, *Adaptive Moment Estimation*). A aplicação do método de ADAM no treinamento de redes neurais convolucionais foi demonstrada por Kingma e Ba (2015).

Durante a etapa de treinamento das redes neurais convolucionais, os dados de treinamento são separados em dois subconjuntos selecionados aleatoriamente com distribuição uniforme: um subconjunto de treinamento com 80% dos dados e um subconjunto de validação com os demais 20%. Este procedimento foi adotado para realizar a validação cruzada dos dados durante a etapa de treinamento, evitando assim o sobreajuste das redes.

Os próximos tópicos desta seção apresentam os resultados obtidos com a classificação dos 4 conjuntos de dados. Para cada conjunto, foi calculado 2 volumes de bancos de dados naturais (1200 e 2400 amostras) e cada banco de dados foi aumentado aplicando ruído gaussiano branco (de 1200 para 7200 amostras; de 2400 para 14400 amostras), totalizando 4 bancos de dados diferentes para cada conjunto. Em relação aos bancos de teste de 288 amostras, é possível gerar seis bancos diferentes, um banco natural sem ruídos e os demais bancos são gerados com a adição de ruídos com diferentes níveis de SNR (10, 12, 14, 16 e 18 dB). Por fim, os resultados obtidos são as acurácias de classificação de cada rede neural convolucional treinada com os bancos de dados gerados usando os modelos substitutos para representar o mancal hidrodinâmico. A análise dos resultados é realizada de forma comparativa entre os modelos substitutos abordados neste trabalho. Para detalhar o procedimento adotado para geração dos bancos de dados e aplicação para classificação dos dados foi elaborado um fluxograma apresentado na Figura 4-14.

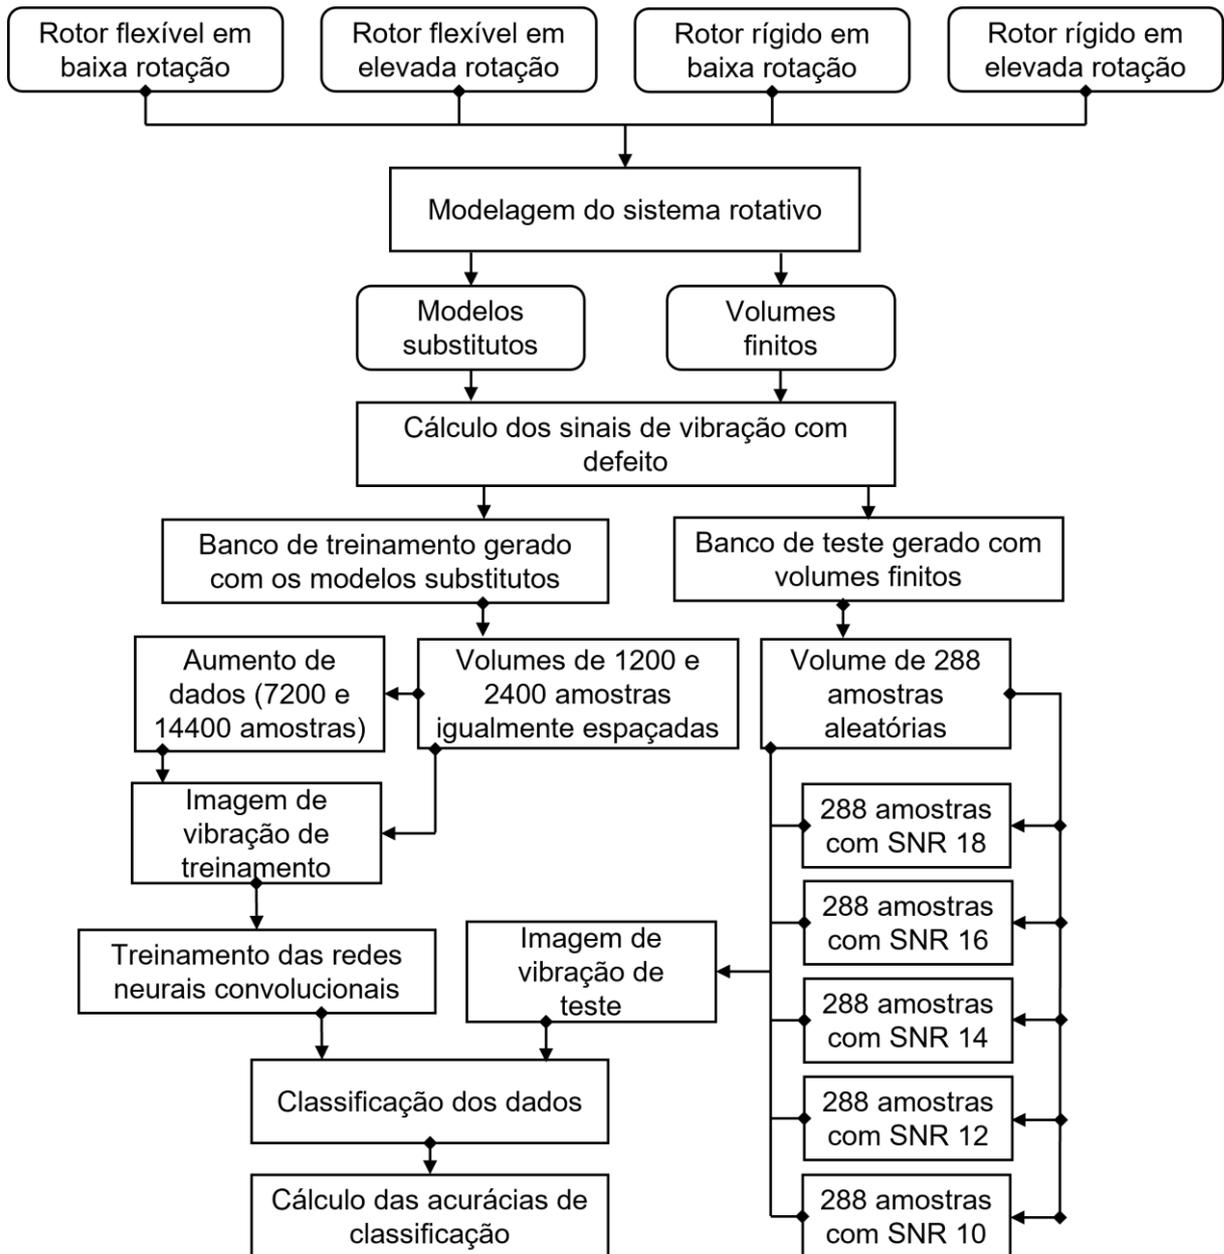


Figura 4-14: Fluxograma da classificação de defeitos.

#### 4.4.1 Análise da classificação do rotor flexível em baixa rotação

O primeiro conjunto de dados é relacionado ao rotor flexível em baixa rotação, denominado aqui como conjunto flexível-baixa rotação. A Tabela 4-19 apresenta as acurácias obtidas na classificação considerando os bancos de dados natural de 1200 amostras. Os resultados apresentados nas linhas da Tabela 4-19 são as acurácias obtidas com a rede neural convolucional treinada com o banco de dados gerado pelo modelo substituto do mancal hidrodinâmico e as colunas apresentam o banco de teste

aplicado na análise como demonstrado no fluxograma da Figura 4-14. É importante ressaltar que o banco de teste é aplicado de forma individual em cada análise, ou seja, não se trata de um banco aumentado, apenas de um banco de dados sem ruído e com ruído considerando diferentes níveis de SNR.

Tabela 4-19: Comparação das acurácias na classificação de defeitos para o rotor flexível em baixa rotação com banco de dados natural de 1200 amostras.

<i>Modelo substituto</i>	<i>Acurácia da classificação [%]</i>					
	<i>Sem ruído</i>	<i>SNR 18</i>	<i>SNR 16</i>	<i>SNR 14</i>	<i>SNR 12</i>	<i>SNR 10</i>
<i>Coef. Equivalentes</i>	90,63	86,81	85,76	81,94	80,56	78,47
<i>Rede Neural (2401)</i>	87,15	80,90	80,56	79,51	77,43	77,08
<i>Rede Neural (6561)</i>	93,75	89,24	88,19	84,03	81,94	78,47
<i>Int. Cúbica (625)</i>	80,21	78,82	78,82	78,47	77,43	77,08
<i>Int. Cúbica (2401)</i>	82,64	79,17	79,17	77,78	77,78	77,08
<i>Int. Cúbica (6561)</i>	86,11	82,29	81,94	79,86	79,51	78,82

A partir da Tabela 4-19, é possível verificar que as acurácias de classificação de todos os modelos tendem a cair conforme diminui o nível SNR do ruído dos bancos de teste. Essa característica é esperada, pois, as redes neurais convolucionais foram treinadas com um volume de dados sem ruídos (banco de dados natural). A Tabela 4-20 apresenta os resultados obtidos com bancos de dados aumentado de 7200 amostras. É importante lembrar que os bancos de dados aumentados contêm os dados naturais sem ruídos e estes mesmos dados contaminados por ruídos com diferentes níveis de SNR.

Tabela 4-20: Comparação das acurácias na classificação de defeitos para o rotor flexível em baixa rotação com banco de dados aumentado de 7200 amostras.

<i>Modelo substituto</i>	<i>Acurácia da classificação [%]</i>					
	<i>Sem ruído</i>	<i>SNR 18</i>	<i>SNR 16</i>	<i>SNR 14</i>	<i>SNR 12</i>	<i>SNR 10</i>
<i>Coef. Equivalentes</i>	97,92	96,88	95,83	94,10	91,67	90,28
<i>Rede Neural (2401)</i>	97,22	96,53	95,83	94,44	93,75	90,63
<i>Rede Neural (6561)</i>	97,92	97,22	96,88	96,53	95,14	93,06
<i>Int. Cúbica (625)</i>	85,07	83,33	82,64	81,60	80,21	78,47

<i>Int. Cúbica (2401)</i>	95,49	94,10	92,71	90,97	88,19	85,42
<i>Int. Cúbica (6561)</i>	94,44	93,06	90,97	89,93	89,58	87,50

Os resultados obtidos na Tabela 4-20 apresentam um aumento significativo das acurácias de todos os modelos e em todos os bancos de testes, quando comparados com os resultados obtidos com o banco de dados natural apresentados na Tabela 4-19. Logo, é possível concluir que as acurácias dos resultados de classificação são melhores quando as redes neurais convolucionais são treinadas com um banco de dados aumentado. Além disso, uma vez que as redes neurais convolucionais foram treinadas com dados com ruídos, sua acurácia tende a cair menos quando são testados dados ruidosos.

Apesar da melhora significativa dos resultados obtidos com os bancos de dados aumentados quando comparado com os bancos de dados naturais, foi avaliado também o uso de um banco de dados naturais com o dobro do volume, ou seja, com 2400 amostras. A Tabela 4-21 apresenta as acurácias obtidas na classificação considerando os bancos de dados naturais de 2400 amostras.

Tabela 4-21: Comparação das acurácias na classificação de defeitos para o rotor flexível em baixa rotação com banco de dados natural 2400 amostras.

<i>Modelo substituto</i>	<i>Acurácia da classificação [%]</i>					
	<i>Sem ruído</i>	<i>SNR 18</i>	<i>SNR 16</i>	<i>SNR 14</i>	<i>SNR 12</i>	<i>SNR 10</i>
<i>Coef. Equivalentes</i>	99,94	98,96	98,61	96,88	96,88	92,01
<i>Rede Neural (2401)</i>	96,88	95,49	93,40	89,24	84,72	77,78
<i>Rede Neural (6561)</i>	99,65	99,65	98,96	97,22	93,40	89,24
<i>Int. Cúbica (625)</i>	95,49	89,58	86,46	82,99	79,17	72,92
<i>Int. Cúbica (2401)</i>	95,83	89,58	88,89	86,46	83,33	78,47
<i>Int. Cúbica (6561)</i>	99,65	97,92	97,57	95,83	91,32	83,33

É possível notar através da Tabela 4-21 que as acurácias dos resultados obtidos são mais elevadas quando comparadas com as acurácias apresentadas na Tabela 4-19. Este aumento nas acurácias é decorrente do aumento do volume de dados de treinamento. No entanto, as acurácias dos resultados tendem a cair conforme diminui

os níveis SNR dos ruídos. A Tabela 4-22 apresenta os resultados obtidos considerando os bancos de dados aumentados de 14400 amostras.

Tabela 4-22: Comparação das acurácias na classificação de defeitos para o rotor flexível em baixa rotação com banco de dados aumentado de 14400 amostras.

<b>Modelo substituto</b>	<b>Acurácia da classificação [%]</b>					
	<b>Sem ruído</b>	<b>SNR 18</b>	<b>SNR 16</b>	<b>SNR 14</b>	<b>SNR 12</b>	<b>SNR 10</b>
<b>Coef. Equivalentes</b>	89,93	94,44	94,79	96,53	96,53	97,92
<b>Rede Neural (2401)</b>	97,57	96,88	97,22	96,18	95,83	94,10
<b>Rede Neural (6561)</b>	98,61	98,96	99,31	97,92	97,92	96,88
<b>Int. Cúbica (625)</b>	97,22	96,18	96,53	94,44	93,06	91,67
<b>Int. Cúbica (2401)</b>	86,11	90,97	93,06	94,45	94,43	96,18
<b>Int. Cúbica (6561)</b>	97,92	98,61	97,92	97,92	97,22	97,57

Ao observar a Tabela 4-22, é possível notar que no geral houve um aumento das acurácias quando considerados os bancos de testes com ruídos. No entanto, as acurácias obtidas com o banco de teste sem ruído apresentadas na Tabela 4-22 são inferiores que as acurácias obtidas na Tabela 4-21 no geral. Esse comportamento indica que se o banco de dados natural é grande suficientemente para resultar em elevadas acurácias em testes com banco sem ruído, o uso de dados aumentados por ruídos no banco de treinamento pode não trazer efeitos positivos. Por outro lado, esse mesmo comportamento não é observado para o caso de banco de teste com elevado ruídos, visto que o treinamento com banco de dados aumentados por ruídos tende a auxiliar na classificação dos defeitos.

Para analisar e comparar os resultados obtidos com as classificações relacionadas ao rotor flexível em baixa rotação, a Tabela 4-23 apresenta os valores médios das acurácias obtidas com os diferentes bancos de teste para cada modelo substituto.

Tabela 4-23: Comparação das acurácias na classificação entre os diferentes bancos de dados de treinamento para o rotor flexível em baixa rotação.

<b>Modelo substituto</b>	<b>Média das acurácias de classificação [%]</b>			
	<b>1200 dados</b>	<b>7200 dados</b>	<b>2400 dados</b>	<b>14400 dados</b>
<b>Coef. Equivalentes</b>	84,03	94,44	97,22	95,02
<b>Rede Neural (2401)</b>	80,44	94,73	89,58	96,30
<b>Rede Neural (6561)</b>	85,94	96,12	96,35	98,26
<b>Int. Cúbica (625)</b>	78,48	81,89	84,43	94,85
<b>Int. Cúbica (2401)</b>	78,94	91,15	87,09	92,53
<b>Int. Cúbica (6561)</b>	78,47	90,91	94,27	97,86
<b>Média final</b>	81,54	91,54	91,49	95,80

No âmbito de comparar os resultados obtidos durante a classificação são apresentadas as médias finais das acurácias obtidas com os respectivos bancos de dados de treinamento. Por meio da Tabela 4-23, é possível observar que o aumento do volume de dados causou um aumento significativo da média das acurácias de classificação. Estes resultados apresentam que em média, quanto maior o número de amostras de treinamento, melhor será a acurácia dos resultados obtidos. Ainda, as acurácias médias de classificação dos modelos substitutos são maiores com os bancos de dados aumentados comparados com os bancos de dados naturais de seus respectivos volumes. Logo, o aumento do banco de dados com adição de ruído aumenta em média a acurácia de classificação das redes neurais convolucionais.

Levando em consideração os dados de treinamento aumentados de 14400 amostras, dentre todas as redes neurais convolucionais avaliadas, a que mais se destacou foi a rede treinada com bancos de dados gerados com a rede neural de 6561 amostras com acurácia média de 98,26%, seguidas pela interpolação cúbica de 6561 amostras com acurácia média de 97,86% e pela rede neural de 2401 amostras com acurácia média de 96,30%. Entretanto, é importante ressaltar que o custo computacional para a geração dos dados com o modelo substituto via rede neural é significativamente mais elevado do que o obtido nos demais modelos substitutos (interpolação cúbica e coeficientes equivalentes).

Em geral, as acurácias de classificação obtidas para o conjunto de dados relacionados ao rotor flexível em baixa rotação são elevadas, acima de 95% na maioria dos casos.

#### 4.4.2 Análise da classificação do rotor flexível em elevada rotação

O segundo conjunto de dados é relacionado ao rotor flexível em elevada rotação, denominado aqui como conjunto flexível-elevada rotação. A Tabela 4-24 apresenta as acurácias obtidas na classificação considerando os bancos de dados naturais de 1200 amostras.

Tabela 4-24: Comparação das acurácias na classificação de defeitos para o rotor flexível em elevada rotação com banco de dados natural de 1200 amostras.

<i>Modelo substituto</i>	<i>Acurácia da classificação [%]</i>					
	<i>Sem ruído</i>	<i>SNR 18</i>	<i>SNR 16</i>	<i>SNR 14</i>	<i>SNR 12</i>	<i>SNR 10</i>
<i>Coef. Equivalentes</i>	37,15	46,53	52,78	55,90	55,56	50,00
<i>Rede Neural (2401)</i>	32,99	40,63	43,40	50,00	49,31	50,35
<i>Rede Neural (6561)</i>	37,85	37,85	41,32	41,32	46,88	53,13
<i>Int. Cúbica (625)</i>	35,76	35,42	35,76	36,46	39,93	48,26
<i>Int. Cúbica (2401)</i>	35,42	35,07	35,42	39,58	42,01	44,44
<i>Int. Cúbica (6561)</i>	29,86	28,13	27,08	23,61	20,83	23,61

Os resultados apresentados na Tabela 4-24 demonstram que as redes neurais convolucionais tiveram dificuldades na classificação dos dados, com valores de acurácia abaixo de 50%. Observa-se ainda que essas baixas acurácias ocorrem para todos os modelos substitutos e em todos os tipos de testes, indicando que a causa não está relacionada ao tipo de modelo e nem a adição de ruídos no banco de teste. Diante disso, partiu-se então para a análise dos resultados de classificação considerando os demais bancos de dados. A Tabela 4-25 apresenta os resultados obtidos considerando os bancos de dados aumentado de 7200 amostras.

Tabela 4-25: Comparação das acurácias na classificação de defeitos para o rotor flexível em elevada rotação com banco de dados aumentado de 7200 amostras.

<b>Modelo substituto</b>	<b>Acurácia da classificação [%]</b>					
	<b>Sem ruído</b>	<b>SNR 18</b>	<b>SNR 16</b>	<b>SNR 14</b>	<b>SNR 12</b>	<b>SNR 10</b>
<b>Coef. Equivalentes</b>	56,25	58,33	57,99	58,68	59,38	59,03
<b>Rede Neural (2401)</b>	40,97	43,40	42,01	42,01	40,63	42,01
<b>Rede Neural (6561)</b>	38,19	37,85	38,19	37,50	39,53	38,19
<b>Int. Cúbica (625)</b>	53,82	53,47	52,43	55,21	50,69	55,21
<b>Int. Cúbica (2401)</b>	44,44	46,18	45,49	45,49	44,44	45,14
<b>Int. Cúbica (6561)</b>	56,60	55,56	56,60	59,72	60,07	62,50

Comparando os resultados obtidos com os bancos de dados aumentados da Tabela 4-25 com os bancos de dados naturais da Tabela 4-24, é possível observar que houve um aumento das acurácias de classificação. Entretanto, embora o aumento do volume de dados tenha indicado uma melhora na acurácia, os resultados obtidos ainda apresentam valores baixos de acurácia, todos abaixo de 65%.

Dando então continuidade as análises de classificação, a Tabela 4-26 apresenta as acurácias obtidas na classificação considerando os bancos de dados naturais de 2400 amostras.

Tabela 4-26: Comparação das acurácias na classificação de defeitos para o rotor flexível em elevada rotação com banco de dados natural de 2400 amostras.

<b>Modelo substituto</b>	<b>Acurácia da classificação [%]</b>					
	<b>Sem ruído</b>	<b>SNR 18</b>	<b>SNR 16</b>	<b>SNR 14</b>	<b>SNR 12</b>	<b>SNR 10</b>
<b>Coef. Equivalentes</b>	89,24	86,11	85,76	84,72	79,17	70,14
<b>Rede Neural (2401)</b>	88,19	78,13	74,31	68,40	58,33	43,75
<b>Rede Neural (6561)</b>	87,50	88,89	86,46	81,94	75,69	64,24
<b>Int. Cúbica (625)</b>	87,50	79,51	71,88	64,24	53,13	34,03
<b>Int. Cúbica (2401)</b>	84,03	84,03	81,25	77,08	67,36	55,21
<b>Int. Cúbica (6561)</b>	91,32	74,31	64,58	53,47	36,81	26,04

É possível notar através da Tabela 4-26 que as acurácias obtidas com os bancos de dados de 2400 amostras são significativamente maiores do que as acurácias

obtidas na Tabela 4-24 com os bancos de dados de 1200 amostras. Logo, os valores baixos de acurácias apresentados na Tabela 4-24 podem ser relacionados ao baixo volume de dados de treinamento. Ademais, as acurácias obtidas tendem a cair significativamente conforme diminui os níveis SNR dos ruídos dos bancos de testes.

Por fim, a Tabela 4-27 apresenta os resultados obtidos considerando os bancos de dados aumentados de 14400 amostras.

Tabela 4-27: Comparação das acurácias na classificação de defeitos para o rotor flexível em elevada rotação com banco de dados aumentado de 14400 amostras.

<b>Modelo substituto</b>	<b>Acurácia da classificação [%]</b>					
	<b>Sem ruído</b>	<b>SNR 18</b>	<b>SNR 16</b>	<b>SNR 14</b>	<b>SNR 12</b>	<b>SNR 10</b>
<b>Coef. Equivalentes</b>	84,72	85,07	87,15	82,99	85,76	82,99
<b>Rede Neural (2401)</b>	88,54	87,85	87,50	87,50	87,85	87,85
<b>Rede Neural (6561)</b>	83,33	82,29	83,68	82,64	84,38	86,46
<b>Int. Cúbica (625)</b>	90,28	88,54	89,58	88,54	88,54	85,76
<b>Int. Cúbica (2401)</b>	90,28	87,85	89,58	87,50	88,19	89,93
<b>Int. Cúbica (6561)</b>	92,36	90,63	89,93	88,54	88,19	87,85

Ao observar os resultados obtidos na Tabela 4-27, é possível notar que em geral houve um aumento das acurácias obtidas com os bancos de dados aumentados em comparação com as acurácias obtidas na Tabela 4-26 com os bancos de dados naturais. Esse comportamento corrobora a necessidade de um maior volume de dados de treinamento para obter elevada acurácia na classificação de defeitos em rotores flexíveis operando em elevada rotação.

A Tabela 4-28 apresenta os valores médios das acurácias obtidas com diferentes bancos de teste para cada modelo substituto.

Tabela 4-28: Comparação das acurácias na classificação entre os diferentes bancos de dados de treinamento para o rotor flexível em elevada rotação.

<b>Modelo substituto</b>	<b>Média das acurácias de classificação [%]</b>			
	<b>1200 dados</b>	<b>7200 dados</b>	<b>2400 dados</b>	<b>14400 dados</b>
<b>Coef. Equivalentes</b>	49,65	58,28	82,52	84,78
<b>Rede Neural (2401)</b>	44,44	41,84	68,52	87,85

<b>Rede Neural (6561)</b>	43,06	38,25	80,79	83,80
<b>Int. Cúbica (625)</b>	38,60	53,47	65,05	88,54
<b>Int. Cúbica (2401)</b>	38,66	45,20	74,83	88,89
<b>Int. Cúbica (6561)</b>	25,52	58,51	57,75	89,58
<b>Média final</b>	39,99	49,26	71,58	87,24

Por meio da Tabela 4-28, é possível observar o mesmo padrão obtido com os resultados do rotor flexível em baixa rotação, onde o aumento do volume de dados e os bancos de dados aumentados resultam nas acurácias de classificação mais elevadas. Considerando os dados de treinamento aumentados de 14400 amostras, as redes neurais convolucionais que mais se destacaram foram as treinadas a partir dos dados gerados pelos modelos substitutos via interpolações cúbicas de 6561 amostras, com acurácia média de 89,58%, seguida pelas interpolações cúbicas de 2401 e 625 amostras, com acurácias médias de 88,89% e 88,54% respectivamente.

Em geral, as acurácias de classificação obtidas para o conjunto de dados relacionados ao rotor flexível em elevada rotação são significativas, com valores acima de 80%. No entanto, é de notória relevância os resultados obtidos com os bancos de dados de treinamento com volume de 1200 amostras, com acurácia média final de aproximadamente 40%. Isto demonstra a importância da escolha do volume de dados de treinamento para a classificação de defeitos aplicando as redes neurais convolucionais.

#### 4.4.3 Análise da classificação do rotor rígido em baixa rotação

Este terceiro conjunto de dados é relacionado ao rotor rígido em baixa rotação, denominado aqui como conjunto rígido-baixa rotação. A Tabela 4-29 apresenta as acurácias obtidas na classificação com bancos de dados naturais de 1200 amostras.

Tabela 4-29: Comparação das acurácias na classificação de defeitos para o rotor rígido em baixa rotação com banco de dados natural de 1200 amostras.

<b>Modelo substituto</b>	<b>Acurácia da classificação [%]</b>					
	<b>Sem ruído</b>	<b>SNR 18</b>	<b>SNR 16</b>	<b>SNR 14</b>	<b>SNR 12</b>	<b>SNR 10</b>
<b>Coef. Equivalentes</b>	78,82	77,43	74,65	73,96	72,22	72,57

<b>Rede Neural (2401)</b>	70,49	69,44	69,10	68,75	67,36	67,36
<b>Rede Neural (6561)</b>	71,88	72,22	70,83	70,83	71,53	71,53
<b>Int. Cúbica (625)</b>	78,82	77,08	76,04	73,96	70,49	67,36
<b>Int. Cúbica (2401)</b>	80,21	77,78	74,65	72,92	70,14	68,06
<b>Int. Cúbica (6561)</b>	82,29	77,43	76,74	75,35	71,88	69,10

A partir da Tabela 4-29, é possível verificar que na maioria dos casos as acurácias de classificação tendem a cair conforme aumenta-se a intensidade do ruído nos bancos de teste, conforme já observado e justificado nas análises anteriores para o rotor flexível. Além disso, é possível observar que este conjunto rígido-baixa rotação apresentou valores de acurácia menores que os observados para o conjunto flexível-baixa rotação, embora os valores apresentados sejam superiores a 65%.

A fim de verificar a influência do aumento de dados de treinamento no desempenho da classificação de defeitos em rotor rígido, a Tabela 4-30 apresenta os resultados obtidos considerando os bancos de dados aumentado de 7200 amostras.

Tabela 4-30: Comparação das acurácias na classificação de defeitos para o rotor rígido em baixa rotação com banco de dados aumentado de 7200 amostras.

<b>Modelo substituto</b>	<b>Acurácia da classificação [%]</b>					
	<b>Sem ruído</b>	<b>SNR 18</b>	<b>SNR 16</b>	<b>SNR 14</b>	<b>SNR 12</b>	<b>SNR 10</b>
<b>Coef. Equivalentes</b>	82,64	84,38	86,11	86,81	86,81	84,72
<b>Rede Neural (2401)</b>	72,57	73,61	74,31	73,26	72,92	73,26
<b>Rede Neural (6561)</b>	82,29	82,64	81,60	81,94	81,25	78,13
<b>Int. Cúbica (625)</b>	72,92	71,18	70,83	70,14	69,10	69,44
<b>Int. Cúbica (2401)</b>	76,74	73,61	73,96	73,26	72,92	72,22
<b>Int. Cúbica (6561)</b>	80,21	77,78	77,43	76,39	75,35	73,61

Ao comparar os resultados obtidos usando os bancos de dados aumentados da Tabela 4-30 com os resultados obtidos usando os bancos de dados naturais da Tabela 4-29, é possível verificar que houve um aumento das acurácias de classificação na maioria dos testes, especialmente nos testes considerando dados com ruídos. Entretanto, a influência do banco aumentado por ruídos tem se mostrado menor neste

conjunto rígido-baixa rotação de 1200 amostras quando comparado com o conjunto flexível-baixa rotação de 1200 amostras.

Em seguida, buscando avaliar o desempenho da classificação considerando o dobro do volume de dados naturais (sem ruído) no banco de treinamento, a Tabela 4-31 apresenta as acurácias obtidas na classificação considerando os bancos de dados naturais de 2400 amostras.

Tabela 4-31: Comparação das acurácias na classificação de defeitos para o rotor rígido em baixa rotação com banco de dados natural de 2400 amostras.

<b>Modelo substituto</b>	<b>Acurácia da classificação [%]</b>					
	<b>Sem ruído</b>	<b>SNR 18</b>	<b>SNR 16</b>	<b>SNR 14</b>	<b>SNR 12</b>	<b>SNR 10</b>
<b>Coef. Equivalentes</b>	93,75	89,24	88,19	87,85	86,81	82,99
<b>Rede Neural (2401)</b>	78,82	79,86	80,56	79,86	78,82	78,13
<b>Rede Neural (6561)</b>	85,76	82,64	81,60	80,56	79,51	73,61
<b>Int. Cúbica (625)</b>	81,60	77,08	75,35	72,92	68,40	60,76
<b>Int. Cúbica (2401)</b>	94,79	90,97	89,24	87,15	84,03	81,60
<b>Int. Cúbica (6561)</b>	93,75	89,58	89,58	88,19	86,11	82,64

É possível verificar que as acurácias apresentadas na Tabela 4-31 são mais elevadas quando comparada com as acurácias apresentadas na Tabela 4-29 e na Tabela 4-30, sendo que este aumento ocorre devido ao aumento do volume de dados de treinamento.

Por fim, a Tabela 4-32 apresenta os resultados obtidos considerando os bancos de dados aumentados de 14400 amostras.

Tabela 4-32: Comparação das acurácias na classificação de defeitos para o rotor rígido em baixa rotação com banco de dados aumentado de 14400 amostras.

<b>Modelo substituto</b>	<b>Acurácia da classificação [%]</b>					
	<b>Sem ruído</b>	<b>SNR 18</b>	<b>SNR 16</b>	<b>SNR 14</b>	<b>SNR 12</b>	<b>SNR 10</b>
<b>Coef. Equivalentes</b>	89,93	90,28	90,97	92,36	94,10	93,40
<b>Rede Neural (2401)</b>	84,72	83,33	82,29	82,29	81,60	80,56
<b>Rede Neural (6561)</b>	87,85	86,11	86,11	85,76	85,07	84,38
<b>Int. Cúbica (625)</b>	89,93	86,81	87,85	87,50	87,50	84,38

<i>Int. Cúbica (2401)</i>	92,71	93,40	92,32	89,93	88,19	87,85
<i>Int. Cúbica (6561)</i>	94,10	93,06	92,71	92,01	91,32	88,89

Os resultados apresentados na Tabela 4-32 indicam um aumento geral das acurácias obtidas com os bancos de dados aumentados em comparação com as acurácias obtidas na Tabela 4-31 com os bancos de dados naturais. Além disso, a influência do banco aumentado por ruídos tem se mostrado maior neste conjunto rígido-baixa rotação de 2400 amostras quando comparado com o conjunto flexível-baixa rotação de 2400 amostras.

A Tabela 4-33 apresenta os valores médios das acurácias obtidas com diferentes bancos de teste para cada modelo substituto.

Tabela 4-33: Comparação das acurácias na classificação entre os diferentes bancos de dados de treinamento para o rotor rígido em baixa rotação.

<i>Modelo substituto</i>	<i>Média das acurácias de classificação [%]</i>			
	<i>1200 dados</i>	<i>7200 dados</i>	<i>2400 dados</i>	<i>14400 dados</i>
<i>Coef. Equivalentes</i>	74,94	85,24	88,14	91,84
<i>Rede Neural (2401)</i>	68,75	73,32	79,34	82,47
<i>Rede Neural (6561)</i>	71,47	81,31	80,61	85,88
<i>Int. Cúbica (625)</i>	73,96	70,60	72,69	83,33
<i>Int. Cúbica (2401)</i>	73,96	73,78	87,96	90,57
<i>Int. Cúbica (6561)</i>	75,46	76,79	88,31	92,01
<i>Média final</i>	73,09	76,84	82,84	88,35

É possível verificar por meio da Tabela 4-33, que os resultados obtidos para o rotor rígido em baixa rotação apresentam características semelhantes ao rotor flexível em baixa rotação. Como observado em ambos os conjuntos de dados (flexível-baixa rotação e rígido-baixa rotação), o aumento do volume de dados e a aplicação dos bancos de dados aumentados tendem a aumentar de forma significativa as acurácias de classificação.

Em geral, as acurácias de classificação para o rotor rígido em baixa rotação são acima de 90% em alguns casos. É importante observar que, considerando os dados de treinamento aumentados de 14400 amostras, as redes neurais convolucionais que

mais se destacaram foram as treinadas a partir dos dados gerados pelos modelos substitutos via interpolações cúbicas de 6561 amostras, com acurácia média de 92,01%, seguida pela solução por coeficientes equivalentes, com acurácia média de 91,84%, e pela interpolação cúbica de 2401 amostras, com acurácia média de 90,57%.

#### 4.4.4 Análise da classificação do rotor rígido em elevada rotação

O quarto, e último, conjunto de dados é relacionado ao rotor rígido em elevada rotação, denominado aqui como conjunto rígido-elevada rotação. A Tabela 4-34 apresenta as acurácias obtidas na classificação considerando os bancos de dados naturais de 1200 amostras.

Tabela 4-34: Comparação das acurácias na classificação de defeitos para o rotor rígido em elevada rotação com banco de dados natural de 1200 amostras.

<i>Modelo substituto</i>	<i>Acurácia da classificação [%]</i>					
	<i>Sem ruído</i>	<i>SNR 18</i>	<i>SNR 16</i>	<i>SNR 14</i>	<i>SNR 12</i>	<i>SNR 10</i>
<i>Coef. Equivalentes</i>	73,61	78,82	77,08	81,94	79,51	73,26
<i>Rede Neural (2401)</i>	79,86	78,47	78,13	73,61	66,32	59,38
<i>Rede Neural (6561)</i>	72,92	77,43	77,43	76,04	69,79	66,32
<i>Int. Cúbica (625)</i>	75,69	76,04	73,26	68,75	63,19	56,60
<i>Int. Cúbica (2401)</i>	69,44	70,14	70,49	69,44	72,92	72,92
<i>Int. Cúbica (6561)</i>	79,51	86,46	84,38	82,29	72,92	62,50

De forma geral, os resultados apresentados na Tabela 4-34 mostram que as acurácias obtidas nesses modelos não apresentam uma tendência definida, conforme aumenta o nível de ruído no banco de teste. Diferentemente do comportamento observado nos conjuntos anteriores, neste caso é possível observar que o aumento da intensidade do ruído no banco de teste pode tanto aumentar quanto diminuir a acurácia de classificação. Entretanto, é importante destacar que as acurácias obtidas nessas classificações se mostram satisfatórias, com a maioria dos valores superiores a 70%.

Visando analisar a influência do aumento de dados de treinamento no desempenho da classificação, a Tabela 4-35 apresenta os resultados obtidos considerando os bancos de dados aumentado de 7200 amostras.

Tabela 4-35: Comparação das acurácias na classificação de defeitos para o rotor rígido em elevada rotação com banco de dados aumentado de 7200 amostras.

<b>Modelo substituto</b>	<b>Acurácia da classificação [%]</b>					
	<b>Sem ruído</b>	<b>SNR 18</b>	<b>SNR 16</b>	<b>SNR 14</b>	<b>SNR 12</b>	<b>SNR 10</b>
<b>Coef. Equivalentes</b>	64,93	64,93	65,28	65,97	66,67	68,40
<b>Rede Neural (2401)</b>	71,18	72,22	71,88	73,61	74,65	75,00
<b>Rede Neural (6561)</b>	73,61	74,31	74,65	73,61	74,65	76,38
<b>Int. Cúbica (625)</b>	71,53	71,88	72,57	72,57	73,26	71,88
<b>Int. Cúbica (2401)</b>	71,88	72,22	73,26	73,26	73,96	77,08
<b>Int. Cúbica (6561)</b>	74,65	74,31	75,00	75,35	77,43	77,78

A partir dos resultados apresentados na Tabela 4-35, é possível verificar que as acurácias dos resultados obtidos com os bancos de dados aumentados não apresentam um aumento significativo quando comparadas com as acurácias obtidas com os bancos de dados naturais da Tabela 4-34. Tal comportamento difere do que foi observado nas análises anteriores, indicando, portanto, que a aplicação da técnica de aumento de dados por ruídos pode não melhorar a classificação de defeitos em algumas condições de operação do rotor.

Em seguida, a Tabela 4-36 apresenta as acurácias obtidas na classificação considerando os bancos de dados naturais de 2400 amostras.

Tabela 4-36: Comparação das acurácias na classificação de defeitos para o rotor rígido em elevada rotação com banco de dados natural de 2400 amostras.

<b>Modelo substituto</b>	<b>Acurácia da classificação [%]</b>					
	<b>Sem ruído</b>	<b>SNR 18</b>	<b>SNR 16</b>	<b>SNR 14</b>	<b>SNR 12</b>	<b>SNR 10</b>
<b>Coef. Equivalentes</b>	98,61	90,63	87,50	82,99	72,57	56,94
<b>Rede Neural (2401)</b>	94,10	84,72	78,82	71,18	56,60	44,10
<b>Rede Neural (6561)</b>	97,92	93,75	93,75	87,85	84,03	72,57
<b>Int. Cúbica (625)</b>	92,71	81,94	77,78	68,06	52,78	44,44

<b>Int. Cúbica (2401)</b>	97,92	93,40	86,46	83,33	67,36	50,69
<b>Int. Cúbica (6561)</b>	97,92	95,49	92,01	85,07	70,14	49,65

A partir da Tabela 4-36, é possível observar que houve uma tendência geral das acurácias diminuírem conforme aumenta-se a intensidade de ruído no banco de teste. Vale ressaltar que este comportamento foi também observado nas análises do conjunto de dados do rotor flexível, visto que a inclusão de ruídos no banco de teste tende a dificultar a classificação pois as redes neurais convolucionais utilizaram apenas dados sem ruídos durante a etapa de treinamento (banco de dados natural).

Por fim, a Tabela 4-37 apresenta os resultados obtidos considerando os bancos de dados aumentados de 14400 amostras.

Tabela 4-37: Comparação das acurácias na classificação de defeitos para o rotor rígido em elevada rotação com banco de dados aumentado de 14400 amostras.

<b>Modelo substituto</b>	<b>Acurácia da classificação [%]</b>					
	<b>Sem ruído</b>	<b>SNR 18</b>	<b>SNR 16</b>	<b>SNR 14</b>	<b>SNR 12</b>	<b>SNR 10</b>
<b>Coef. Equivalentes</b>	97,92	97,92	97,57	97,22	97,22	96,53
<b>Rede Neural (2401)</b>	89,93	89,93	89,58	88,89	89,93	88,54
<b>Rede Neural (6561)</b>	93,40	93,75	93,40	93,75	94,44	94,44
<b>Int. Cúbica (625)</b>	91,67	92,01	91,32	90,63	90,63	88,54
<b>Int. Cúbica (2401)</b>	96,88	95,22	96,18	95,49	97,22	97,22
<b>Int. Cúbica (6561)</b>	96,18	97,57	97,92	97,92	97,57	97,57

Com base nos resultados apresentados na Tabela 4-37, é possível notar que no geral houve um aumento das acurácias obtidas com o banco de dados aumentado, principalmente em relação aos testes com ruídos. Esse comportamento foi também observado em casos anteriores e mostra-se bastante coerente, visto que o treinamento da rede com o banco de dados aumentado leva em consideração dados contaminados com ruídos e, portanto, tende a melhorar o desempenho da rede em testes com ruídos. De forma geral, pode-se afirmar que a acurácia obtida com o banco de dados aumentado é bastante satisfatória, apresentando a maioria dos valores superiores a 90%.

De forma a sintetizar os resultados obtidos neste conjunto de dados, a Tabela 4-38 apresenta os valores médios das acurácias obtidas com diferentes bancos de teste para cada modelo substituto.

Tabela 4-38: Comparação das acurácias na classificação entre os diferentes bancos de dados de treinamento para o rotor rígido em elevada rotação.

<b>Modelo substituto</b>	<b>Média das acurácias de classificação [%]</b>			
	<b>1200 dados</b>	<b>7200 dados</b>	<b>2400 dados</b>	<b>14400 dados</b>
<b>Coef. Equivalentes</b>	77,37	66,03	81,54	97,40
<b>Rede Neural (2401)</b>	72,63	73,32	71,59	89,47
<b>Rede Neural (6561)</b>	73,32	74,31	88,31	93,87
<b>Int. Cúbica (625)</b>	68,92	72,28	69,62	90,80
<b>Int. Cúbica (2401)</b>	70,89	73,61	79,86	96,70
<b>Int. Cúbica (6561)</b>	78,01	75,75	81,71	97,45
<b>Média final</b>	73,52	72,55	78,77	94,28

De acordo com a Tabela 4-38, é possível observar que o acréscimo do volume de dados naturais e a aplicação dos bancos de dados aumentados tendem a aumentar a acurácia média dos resultados obtidos, embora esse comportamento não tenha sido observado quando aplicado a técnica de aumento de dados no banco com 1200 amostras naturais.

Em geral, os resultados de classificação obtidos para o rotor rígido em elevada rotação apresentam acurácias satisfatórias. Tomando como base os dados de treinamento aumentados de 14400 amostras, as redes neurais convolucionais que mais se destacaram foram as treinadas a partir dos dados gerados pelos modelos substitutos via as interpolações cúbicas de 6561 amostras, com acurácia média de 97,45%, seguida pela solução por coeficientes equivalentes, com acurácia média de 97,40%, e pela interpolação cúbica de 2401 amostras, com acurácia média de 96,70%.

## 5 CONCLUSÃO

Esta dissertação contribui para um melhor entendimento da influência de diferentes tipos de modelos substitutos de mancais hidrodinâmicos em problemas de classificação de defeitos de rotores. Para isso, diferentes modelos substitutos de mancais hidrodinâmicos foram treinados e testados com diferentes bancos de dados, visando assim obter uma maior representatividade com relação ao modelo original utilizado para determinar as forças hidrodinâmicas em mancais cilíndricos.

Tomando como base as métricas de avaliação de cada modelo substituto aplicados em um banco de teste, as menores precisões dos resultados obtidos foram com os bancos de 256 e 625 amostras para todos os modelos substitutos, enquanto as melhores precisões dos resultados foram obtidas com os bancos de 6561 e 10000 amostras. Todavia, os modelos compostos por redes neurais artificiais, interpolação cúbica e *spline* apresentaram excelentes resultados a partir de 1296 amostras de treinamento ou interpolação. Ademais, a interpolação linear apresentou uma boa precisão somente a partir de 2401 amostras de interpolação. Por fim, os testes iniciais apresentaram o tempo necessário que os modelos levam para realizar uma estimativa, sendo que, neste caso, as interpolações mostraram melhores resultados.

Após devidamente explorado os modelos substitutos de mancais hidrodinâmicos, os que apresentaram bom desempenho foram aplicados na geração de dados de um problema de classificação de defeitos de desbalanceamento do rotor. Para este fim, um sistema rotativo composto de um eixo com disco central e suportado por mancais hidrodinâmicos idênticos foi discretizado pelo método dos elementos finitos, sendo que as forças hidrodinâmicas provenientes dos mancais foram obtidas a partir de diferentes modelos substitutos. Logo, os modelos substitutos foram aplicados e comparados na análise de classificação de defeitos em máquinas rotativas.

Nesta etapa do trabalho, foram gerados diferentes bancos de dados usando os modelos substitutos aplicados ao modelo numérico do rotor, cujos resultados são sinais de vibração ao longo do tempo para diferentes níveis de defeitos de desbalanceamento do rotor, diferentes temperaturas no lubrificante do mancal e diferentes velocidades de rotação do rotor. Estes bancos foram então utilizados no treinamento das redes neurais convolucionais para a classificação dos dados em três classes diferentes de grau de desbalanceamento, a saber, um nível de

desbalanceamento menor que  $G_{ISO}$  3,7, um nível de desbalanceamento entre  $G_{ISO}$  3,7 e  $G_{ISO}$  6,5, e, por fim, um nível de desbalanceamento maior que  $G_{ISO}$  6,5. Para isso, dois diferentes volumes de dados de treinamento foram avaliados (1200 e 2400 amostras), sendo que a média final das acurácias de classificação obtidas foi mais elevada para os bancos de dados com 2400 amostras. Além disso, a aplicação de ruído gaussiano branco com diferentes níveis de SNR apresentou-se um aumento significativo das acurácias médias obtidas, exceto no caso de rotor rígido em elevada rotação com o banco de menor volume de amostras. Portanto, as análises comparativas entre os modelos substitutos são realizadas através dos resultados obtidos com as redes neurais convolucionais treinadas com 14400 amostras, ou seja, aplicando a técnica de aumento de dados no banco com 2400 amostras naturais.

Em geral, todos os resultados de classificação obtidos com as redes neurais convolucionais treinadas com os bancos gerados por diferentes modelos substitutos apresentaram acurácias médias acima de 80%. A maior acurácia média apresentada para o primeiro conjunto de dados, relacionado ao rotor flexível em baixa rotação, é dada pela rede neural convolucional treinada com o banco de dados gerado pela rede neural de 6561 amostras, sendo a acurácia média de 98,26%. No caso dos outros três conjuntos de dados (flexível-elevada rotação, rígido-baixa rotação e rígido-elevada rotação), o banco de dados gerado pela interpolação cúbica de 6561 amostras conseguiu obter a maior acurácia média, com valores de 89,58% para o segundo conjunto de dados, 92,01% para o terceiro conjunto de dados e 97,45% para o quarto conjunto de dados.

Com base nos resultados de classificação dos 4 conjuntos de dados, observa-se que as redes neurais convolucionais treinadas com os bancos de dados gerados pela interpolação cúbica de 6561 amostras são as mais recorrentes em relação aos maiores valores de acurácia média obtidos. Portanto, este modelo se mostrou como o mais adequado para aplicações de problemas de classificação de defeito de desbalanceamento em máquinas rotativas quando comparado com os outros modelos testados. Entretanto, ao comparar os valores de acurácia média de classificação entre as redes neurais convolucionais treinadas com os bancos de dados gerados pelos outros modelos substitutos observa-se que as diferenças percentuais não são significativas.

Por fim, é importante mencionar que a escolha do modelo substituto deve englobar outros fatores além da acurácia média de classificação, como o método de

classificação de dados a ser utilizado, e por consequência, o tipo de sinal de entrada, assim como o volume de dados mínimo necessário para classificação e o custo computacional dos modelos substitutos. Em relação ao custo computacional, a geração dos dados através do modelo substituto via interpolação cúbica mostra-se significativamente mais rápida do que com o modelo substituto por rede neural.

### **5.1 Sugestões para trabalhos futuros**

Conforme já mencionado, esta dissertação apresentou contribuições para a análise de classificação de defeitos utilizando redes neurais convolucionais treinadas com bancos de dados gerados artificialmente por diferentes modelos substitutos de mancais hidrodinâmicos. Entretanto, os dados classificados foram avaliados para apenas um tipo específico de defeito. Além disso, os modelos substitutos dos mancais são baseados na solução clássica da equação de Reynolds, considerando a condição de lubrificação hidrodinâmica. Portanto, visando avançar ainda mais neste tema de pesquisa, propõe-se as seguintes novas etapas:

- Avaliar a aplicação dos modelos substitutos em outros tipos de mancais hidrodinâmicos, tais como os mancais segmentados;
- Incluir os efeitos térmicos (lubrificação termohidrodinâmica) e de cavitação na solução da equação de Reynolds e, posteriormente, aprimorar os modelos substitutos dos mancais;
- Avaliar a aplicação da metodologia proposta em diferentes tipos de defeitos, em especial os defeitos presentes nos mancais hidrodinâmicos;
- Realizar a validação experimental dos resultados numéricos obtidos através da abordagem proposta neste trabalho.

## REFERÊNCIAS

ALPAYDIN, Ethem. **Introduction to Machine Learning**. [s. l.]: The MIT Press, 2014.

ALVES, Diogo S.; DANIEL, Gregory B.; De CASTRO, Helio F.; MACHADO, Tiago H.; CAVALCA, Katia L.; GECGEL, Ozhan; DIAS, João P.; EKWARO-OSIRE, Stephen. Uncertainty quantification in deep convolutional neural network diagnostics of journal bearings with ovalization fault. **Mechanism and Machine Theory**. vol. 149, 2020.

BISHOP, Christopher M. **Pattern Recognition and Machine Learning**. Information Science and Statistics. Springer, 2006.

BOUARD, L.; FILLON, M.; FRENE, J. Comparison between three turbulent models - application to thermohydrodynamic performances of tilting-pad journal bearings. **Tribology International**, v. 29, n. 1, p. 11-18, 1996.

CAMERON, A. Heat transfer in journal bearings: a preliminary investigation. **Proceedings of the General Discussion on Heat Transfer**, pp. 194–197, 1951.

CASTRO, Helio Fiori. **Análise de mancais hidrodinâmicos em rotores sob instabilidade fluido-induzida**. 199 f. Tese de Doutorado (Mecânica dos Sólidos e Projetos Mecânicos) - Universidade Estadual de Campinas. 2007.

CHACON, Juan L. F.; KAPPATOS, Vassilios; BALACHANDRAN, Wamadeva; GAN, Tat-Hean. A novel approach for incipient defect detection in rolling bearings using acoustic emission technique. **Applied Acoustics**, vol.89, p.88-100. 2015.

CHAPRA, Steven C.; CANALE, Raymond P. **Métodos Numéricos para Engenharia**. 5. ed. Porto Alegre: Amgh, 2011. Tradução técnica: Helena Castro.

CUNHA, Barbara Zapparoli. **Efeitos das Condições de Alimentação de Óleo de Mancais Lubrificadas no Comportamento Dinâmico do Rotor**. 111 f. Dissertação de Mestrado (Mecânica dos Sólidos e Projetos Mecânicos) - Universidade Estadual de Campinas. 2019.

DANIEL, Gregory Bregion. **Desenvolvimento de um modelo termohidrodinâmico para análise em mancais segmentados**. 218 f. Tese de Doutorado (Mecânica dos Sólidos e Projetos Mecânicos) - Universidade Estadual de Campinas. 2012.

DELGADO, Miguel; CIRRINCIONE, Giansalvo; ESPINOSA, Antonio Garcia; ORTEGA, Juan A.; HENAO, Humberto. Bearing Faults Detection by a Novel Condition

Monitoring Scheme based on Statistical-Time Features and Neural Networks. **IEEE Transactions on Industrial Electronics**, vol.60, no.8, p.3398-3407, 2013.

DIMOND, T. W.; SHETH, P. N.; ALLAIRE, P. E.; HE, M. Identification methods and test results for tilting pad and fixed geometry journal bearing dynamic coefficients – A review. **Shock and Vibration**, 2009. 13-43.

DOWSON, D. A generalized Reynolds equation for fluid-film lubrication. **International Journal of Mechanical Sciences**, v. 4, n. 2, p. 159-170, 1962.

DOWSON, D., HIGGINSON, G. R., ARCHARD, F. J., CROOK, A. W. *Elastohydrodynamic Lubrication*, SI Edition, Pergamon Press. 1977.

DUBOIS, George B.; OCVIRK, Fred W. Analytical Derivation and Experimental Evaluation of Short-Bearing Approximation for Full Journal Bearings. Report 1157. NACA: Washington, 1953.

DUBOIS, George B.; OCVIRK, Fred W. The Short Bearing Approximation for Full Journal Bearings. *Trans. ASME*, v. 77, p. 1173-1178, 1955.

DUBOIS, George B.; OCVIRK, Fred W.; WEHE, R. L. Experimental investigation of Eccentricity Ratio, Friction, and Oil Flow of Long and Short Journal Bearings with Load Number Charts. Technical Note 3491. NACA: Washington, 1955.

DUBOURG, Vincent. **Méta-modèles adaptatifs pour l'analyse de fiabilité et l'optimisation sous contrainte fiabiliste**. 2011. 282 f. Tese (Doutorado) - Curso de Génie Mécanique, Université Blaise Pascal - Clermont II, Clermont-Ferrand, 2011.

DUDA, Richard O.; HART, Peter E.; STORK, David G. **Pattern Classification**. [s. l.]: John Wiley & Sons, 2000.

DURAK, Ertuğrul; SALMAN, Özlem; KURBANOĞLU, Cahit. Analysis of effects of oil additive into friction coefficient variations on journal bearing using artificial neural network. **Industrial Lubrication And Tribology**, [S.L.], v. 60, n. 6, p. 309-316, 26 set. 2008. Emerald. <http://dx.doi.org/10.1108/00368790810902241>.

EHRICH, F. F. **Handbook of Rotordynamics**, New York: McGraw Hill, 1992.

FLOBERG, L. Lubrication of two rotating cylinders at variable lubricant supply with reference to the tensile strength of the liquid lubricant. **Journal of Lubrication Technology**, v. 95, n. 2, p. 155-163, 1973.

FRANCO, Neide Maria Bertoldi. *Cálculo Numérico*. 1. Ed. São Paulo: Pearson Universidades, 2006.

FRENE, J.; NICOLAS, D.; DEGUEURCE, B.; BERTHE, D.; GODE, M. *Hydrodynamic lubrication: Bearing and thrust bearing*. Amsterdam: Elsevier, 1997.

FUKUSHIMA, Kuniyiko. Neocognitron: A Self-Organized Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position. **Biological Cybernetics**. 1980.

GALAR, Mikel; FERNÁNDEZ, Alberto; BARRENECHEA, Edurne; BUSTINCE, Humberto; HERRERA, Francisco. An overview of ensemble methods for binary classifiers in multi-class problems: Experimental study on one-vs-one and one-vs-all schemes. **Pattern Recognition**, vol.44, p.1761-1776, 2011.

GENTA, Giancarlo. **Dynamics of Rotating Systems**. New York: Springer-Verlag New York, 2005. 658 p. (Mechanical Engineering Series).

GÉRON, Aurélien. Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems. 2. Ed. Sebastopol: O'Reilly, 2019.

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

GONZALEZ, R. C., WOODS, R. E., **Digital Image Processing**, Pearson, 3<sup>a</sup> ed., 2010.

HAGAN, Martin T.; MENHAJ, Mohammad B. Training Feedforward Networks with the Marquardt Algorithm. **IEEE Transactions on Neural Networks**, [S. L.], v. 5, n. 6, p. 989-993, nov. 1994.

HAMILL, F. A. Sayano Shushenskaya accident: presenting a possible direct cause. **International Water Power Dam Construction**, p.30-36. 2010.

HAN, T.; TIAN, Z.; YIN, Z.; TAN, A. C. Bearing fault identification based on convolutional neural network by different input modes. **Journal of the Brazilian Society of Mechanical Sciences and Engineering**. 42, 474. 2020.

HARNOY, Avraham. **Bearing Design in Machinery**. [S. L.]: CRC Press, 2002. (Engineering Tribology and Lubrication).

HAYKIN, Simon O. Neural Networks and Learning Machines, 3. ed. Ontario: Pearson Prentice Hall, 2009.

HOANG, Duy-Tang; KANG, Hee-Jun. Rolling element bearing fault diagnosis using convolutional neural network and vibration image. **Cognitive Systems Research**, 2018. DOI: <https://doi.org/10.1016/j.cogsys.2018.03.002>

HOU, Hsieh; ANDREWS, H.. Cubic splines for image interpolation and digital filtering. **IEEE Transactions On Acoustics, Speech, And Signal Processing**, [S.L.],

v. 26, n. 6, p. 508-517, dez. 1978. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/tassp.1978.1163154>.

Huang, D.-S. Systematic theory of neural networks for pattern recognition. **Publishing House of Electronic Industry of China**. 1996.

INTERNATIONAL STANDARD ORGANIZATION. **ISO 1940 - Mechanical vibration - Balance quality requirements for rotors in a constant (rigid) state**. Part 1 - Specification and verification of tolerances balance. Genebra. 2003.

JAKOBSSON, B. The finite journal bearing, considering vaporization. **Transactions of Chalmers University of Technology**, v. 190, 1957.

JANSSENS, O.; SLAVKOVIKI, V.; VERVISCH, B.; STOCKMAN, K.; LOCCUFIER, M.; VERSTOCKT, S.; VAN DE WALLE, R.; VAN HOECKE, S. Convolutional Neural Network Based Fault Detection for Rotating Machinery. **Journal of Sound and Vibration**. 2016.

JEONG, Haedong; PARK, Seungtae; WOO, Sunhee; LEE, Seungchul. Rotating Machinery Diagnostics using Deep Learning on Orbit Plot Images. **Procedia Manufacturing**. vol. 5, p.1107-1118. 2016.

KEYS, R.. Cubic convolution interpolation for digital image processing. **IEEE Transactions On Acoustics, Speech, And Signal Processing**, [S.L.], v. 29, n. 6, p. 1153-1160, dez. 1981. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/tassp.1981.1163711>.

KHARCHE, Prashant P.; KSHIRSAGAR, Sharad V. Review of Fault Detection in Rolling Element Bearing. **International Journal of Innovative Research in Advanced Engineering (IJIRAE)**. Vol.1, No.5, p.169-174, 2014. ISSN: 2349-2163.

KINGMA, Diederik; BA, Jimmy. Adam: A Method for Stochastic Optimization. **International Conference on Learning Representations**, 2015.

KNEŽEVIĆ, Darko; SAVIĆ, Vladimir. Mathematical Modeling of Changing of Dynamic Viscosity, as a Function of Temperature and Pressure, of Mineral Oils for Hydraulic Systems. **Mechanical Engineering**. Vol. 4, n.1, p. 27-34. 2006.

KOLDITZ, Olaf. Finite Volume Method. **Computational Methods In Environmental Fluid Mechanics**, [S.L.], p. 173-190, 2002. Springer Berlin Heidelberg. [http://dx.doi.org/10.1007/978-3-662-04761-3\\_8](http://dx.doi.org/10.1007/978-3-662-04761-3_8).

KORNAEV, Alexey V.; KORNAEV, Nickolay V.; KORNAEVA, Elena P.; SAVIN, Leonid A. Application of Artificial Neural Networks to Calculation of Oil Film Reaction Forces and Dynamics of Rotors on Journal Bearings. **International Journal Of**

**Rotating Machinery**, [S.L.], v. 2017, p. 1-11, 2017. Hindawi Limited. <http://dx.doi.org/10.1155/2017/9196701>.

KRIEGE, D. G. A statistical approach to some basic mine valuation problems on the Witwatersrand. **Journal Of The Chemical Metallurgical & Mining Society Of South Africa**, [S. L.], v. 52, n. 6, p. 119-139, dez. 1951.

LALANNE, Michel; FERRARIS, Guy. **Rotordynamics Prediction in Engineering**. New York: John Wiley and Sons Ltd., 1990.

LECUN, Yann; Botou, Léon; BENGIO, Yoshua; Haffner, Patrick. Gradient-Based Learning Applied to Document Recognition. In: **Proceedings of the IEEE**, Vol. 86, No. 11, nov. 1998.

LOPES, Álvaro Pereira; COSTA, Manuel de Jesus dos Santos. Comparação Entre Métodos de Aproximação Numérica Utilizando o Programa Matlab. **Revista Margens Interdisciplinar**, [S.L.], v. 11, n. 17, p. 14, 25 jan. 2018. Universidade Federal do Para. <http://dx.doi.org/10.18542/rmi.v11i17.5447>.

LUND, J. W. Review of the Concept of Dynamic Coefficients for the Fluid Film Journal Bearings. **Journal of Tribology**. vol.109, p.37, 1987.

LUND, J. W. Spring and Damping Coefficients for the Tilting-Pad Journal Bearing. **ASLE Transactions**, 1964.

MALISKA, C. R. **Transferência de Calor e Mecânica dos Fluidos Computacional**, 2ª Edição. Rio de Janeiro: Livros Técnicos e Científicos Editora SA, 2004.

MATHERON, Georges. Principles of geostatistics. **Economic Geology**, [S.L.], v. 58, n. 8, p. 1246-1266, 1 dez. 1963. Society of Economic Geologists. <http://dx.doi.org/10.2113/gsecongeo.58.8.1246>.

MAXWELL, Aaron E.; WARNER, Timothy A.; GUILLÉN, Luis A.. Accuracy Assessment in Convolutional Neural Network-Based Deep Learning Remote Sensing Studies - Part 1: Literature Review. **Remote Sensing**. Vol.13, p.2450, 2021. DOI:<https://doi.org/10.3390/rs13132450>

MCCULLOCH, Warren S.; PITTS, Walter. A logical calculus of the ideas immanent in nervous activity. **The Bulletin Of Mathematical Biophysics**, [S.L.], v. 5, n. 4, p. 115-133, dez. 1943. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/bf02478259>.

MCKINLEY, S.; LEVINE, M. Cubic spline interpolation. **College of the Redwoods**, v. 45, n. 1, p. 1049-1060, 1998.

MEIJERING, E.; UNSER, M.. A note on cubic convolution interpolation. **IEEE Transactions On Image Processing**, [S.L.], v. 12, n. 4, p. 477-479, abr. 2003. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/tip.2003.811493>.

MINASNY, B., MCBRATNEY, A. B. A conditioned Latin hypercube method for sampling in the presence of ancillary information. **Computers & geosciences**, v. 32, n. 9, p. 1378-1388, 2006.

MONTGOMERY, Douglas C., RUNGER, George C., Applied Statistics and Probability for Engineers, 6th edition, John Wiley & Sons, 2014.

NASSELQVIST, M. **Simulation and Characterization of Rotordynamic Properties for Vertical Machines**. 158 f. Tese (Doutorado em Engenharia) – Department of Engineering Sciences and Mathematics, Lulea University of Technology. Lulea, Sweden. 2011.

NBR 5462. **Confiabilidade e manutenibilidade**. ABNT, 1994.

NELSON, H. D. A Finite Rotating Shaft Element Using Timoshenko Beam Theory. **Journal Of Mechanical Design**, [S.L.], v. 102, n. 4, p. 793-803, 1 out. 1980. ASME International. <http://dx.doi.org/10.1115/1.3254824>.

NELSON, H. D.; MCVAUGH, J. M. The Dynamics of Rotor-Bearing Systems Using Finite Elements. **Asme Journal Of Engineering For Industry**, [s. l.], v. 98, n. 2, p. 593-600, maio 1976.

NEUPANE, Dhiraj; SEOK, Jongwon. Bearing Fault Detection and Diagnosis Using Case Western Reserve University Dataset With Deep Learning Approaches: A Review. **IEEE Access**. Ano 2020.

NORTON, Robert L. **Projeto de máquinas**: uma abordagem integrada. 4. ed. Porto Alegre: Bookman, 2013.

OCVIRK, Fred W. Short-bearing Approximation for full journal bearings. Technical Note 2808. NACA: Washington, 1952.

OLIVEIRA, M. V. M.; DANIEL, G. B. Signature of Oil Starvation Faults in Rotors Supported by Hydrodynamic Bearings. Conference: 26th **International Congress of Mechanical Engineering**. 2021.

OLSSON, K. Cavitation in dynamically loaded bearings. **Transactions of Chalmers University of Technology**, v. 308, 1965.

PARANJPE, R. S.; HAN, T. A Finite Volume Analysis of the Thermohydrodynamic Performance of Finite Journal Bearings. **Journal of Tribology**, v. 112, p. 557, 1990.

PARANJPE, R. S.; HAN, T. A transient thermohydrodynamic analysis including mass conserving cavitation for dynamically loaded journal bearings. **Journal of tribology**, v. 117, n. 3, p. 369-378, 1995.

PEDREIRA, Javã Atayde. **Dinâmica de Máquinas Rotativas em Mancais Hidrodinâmicos**. 2006. 113 f. Dissertação (Mestrado) - Curso de Engenharia Mecânica, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2006.

PATIR, N.; CHENG, H. S. An average flow model for determining effects of three-dimensional roughness on partial hydrodynamic lubrication. **Journal of lubrication Technology**, v. 100, n. 1, p. 12-17, 1978.

PATIR, N.; CHENG, H. S. Application of average flow model to lubrication between rough sliding surfaces. **ASME, Lubrication Division**, 1979.

PETROV, N. Friction in machines and the effect of the lubricant. **Inzhenernyj Zhurnal**, SanktPeterburg, v. 1, p. 71–140, 1883.

PINKUS, O.; LYNN, M. Analysis of elliptical bearings. **Trans. ASME**, v. 78, n. 16, p. 965–976, 1956.

RAIMONDI, A. A.; BOYD, John. A Solution for the Finite Journal Bearing and its Application to Analysis and Design: I, II, III. **ASLE Transactions**, [S.L.], v. 1, n. 1, p. 159-174, jan. 1958. Informa UK Limited. <http://dx.doi.org/10.1080/05698195808972328>.

RAMOS, Douglas Jhon. **Efeito da cavitação em mancais hidrodinâmicos no comportamento dinâmico de rotores**. 2019. 106 f. Dissertação (Mestrado) - Curso de Engenharia Mecânica, Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, Campinas, 2019.

RAO, S. S. **Mechanical vibrations**. 5ª. ed. [S.I.]: Prentice Hall, 2011.

REYNOLDS, Osborne. IV. On the theory of lubrication and its application to Mr. Beauchamp tower's experiments, including an experimental determination of the viscosity of olive oil. **Philosophical Transactions of The Royal Society of London**, [S.L.], v. 177, p. 157-234, 31 dez. 1886. The Royal Society. <http://dx.doi.org/10.1098/rstl.1886.0005>.

RIFMAN, S. Digital rectification of ERTS multispectral imagery. In Proc. Symp. Significant Results Obtained From the Earth Resources Technology Satellite-1, **NASA SP-327**, vol. 1, sec. B, pp. 1131–1142, 1973.

ROSENBLATT, F. Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms. Washington DC: Spartan Books, 1962. Report No. VG-1196-G-8.

SACKS, Jerome; SCHILLER, Susannah B.; WELCH, William J. Designs for Computer Experiments. **Technometrics**, [S.L.], v. 31, n. 1, p. 41-47, fev. 1989. Informa UK Limited. <http://dx.doi.org/10.1080/00401706.1989.10488474>.

SALAMON, Justin; BELLO, Juan P.. Deep Convolutional Neural Networks and Data Augmentation for Environmental Sound Classification. **IEEE Signal Processing Letters**. 2016. DOI 10.1109/LSP.2017.2657381.

SANTNER, Thomas J.; WILLIAMS, Brian J.; NOTZ, William I. **The Design and Analysis of Computer Experiments**. 2. ed. New York: Springer, 2018. (Springer Series in Statistics).

SAMANTA, B.; AL-BALUSHI, K. R. Artificial Neural Network based Fault Diagnostics of Rolling Element Bearing using Time-Domain Features. **Mechanical Systems and Signal Processing**, vol.17, no.2, p.317-328. 2003.

SFYRIS, D.; CHASALEVRIS, A. An exact analytical solution of the Reynolds equation for the finite journal bearing lubrication. **Tribology International**, [S.L.], v. 55, p. 46-58, nov. 2012. Elsevier BV. <http://dx.doi.org/10.1016/j.triboint.2012.05.013>.

SICCHIERI, Leonardo Campanine. **Metamodelagem Kriging aplicada em modelos de Mancais Hidrodinâmicos**. 2019. 110 f. Dissertação (Mestrado) - Curso de Engenharia Mecânica, Universidade Federal de Uberlândia, Uberlândia, 2019. <http://dx.doi.org/10.14393/ufu.di.2019.2209>.

SIMPSON, T. W.; POPLINSKI, J. D.; KOCH, P. N.; ALLEN, J. K.. Metamodels for Computer-based Engineering Design: survey and recommendations. **Engineering With Computers**, [S. L.], v. 17, n. 2, p. 129-150, jul. 2001. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/pl00007198>.

SINANOĞLU, C.; KURBAN, A.O.; YILDIRIM, Ş. Analysis of pressure variations on journal bearing system using artificial neural network. **Industrial Lubrication And Tribology**, [S.L.], v. 56, n. 2, p. 74-87, abr. 2004. Emerald. <http://dx.doi.org/10.1108/00368790410524038>.

SINGH Sukhjeet; KUMAR, Amit; KUMAR, Navin. Motor Current Signature Analysis for Bearing Fault Detection in Mechanical Systems. **Procedia Materials Science**. 2014, p. 171-177.

SOKOLOVA, Marina; LAPALME, Guy. A systematic analysis of performance measures for classification tasks. **Information Processing and Management**. Vol. 45, p.427-437, 2009.

SOMEYA, T. *et al.* (ed.). **Journal-Bearing Databook**. Berlin, New York: Springer-Verlag, 1989.

SOMMERFELD, A. The hydrodynamic theory of lubrication friction. **Z. Math. Phys**, v. 50, n. 1-2, p. 97–155, 1904.

STACHOWIAK, Gwidon; BATCHELOR, Andrew W. **Engineering Tribology**. 3. ed. [S. L.]: Butterworth-Heinemann, 2005. 832 p.

TOWER, Beauchamp. First Report on Friction Experiments. **Proceedings Of The Institution Of Mechanical Engineers**, [S.L.], v. 34, n. 1, p. 632-659, jun. 1883. SAGE Publications. [http://dx.doi.org/10.1243/pime\\_proc\\_1883\\_034\\_028\\_02](http://dx.doi.org/10.1243/pime_proc_1883_034_028_02).

TUCKMANTEL, Felipe Wenzel da Silva. **Integração de sistemas rotor-mancais hidrodinâmicos-estrutura de suporte para resolução numérica**. 2010. 159 f. Dissertação (Mestrado) - Curso de Engenharia Mecânica, Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, Campinas, 2010.

URBAN, Nathan M.; FRICKER, Thomas E. A comparison of Latin hypercube and grid ensemble designs for the multivariate emulation of an Earth system model. **Computers & Geosciences**, [S.L.], v. 36, n. 6, p. 746-755, jun. 2010. Elsevier BV. <http://dx.doi.org/10.1016/j.cageo.2009.11.004>.

WANG, Hu; LI, Enying; LI, G. Y.; ZHONG, Z. H. Development of metamodeling based optimization system for high nonlinear engineering problems. **Advances In Engineering Software**, [S. L.], v. 39, n. 8, p. 629-645, ago. 2008. Elsevier BV. <http://dx.doi.org/10.1016/j.advengsoft.2007.10.001>.

WANG, Jason; PEREZ, Luis. The Effectiveness of Data Augmentation in Image Classification using Deep Learning. **Stanford University research report**. 2017.

XIAOBO, Zhang. Comparison of response surface method and Kriging method for approximation modeling. In: 2017 2ND INTERNATIONAL CONFERENCE ON POWER AND RENEWABLE ENERGY (ICPRE), 2., 2017, Xi'An. **2017 2nd International Conference on Power and Renewable Energy (ICPRE)**. [S.L.]: IEEE, 2017. p. 66-70.

ZHANG, Y. Linear deformation of a journal bearing and its relationship to hydrodynamic pressure. **Wear**, v. 115, n. 1-2, p. 41-52, 1987.

ZHANG, Shen; ZHANG, Shibo; WANG, Bingnan; HABETLER, Thomas G. Deep Learning Algorithms for Bearing Fault Diagnostics - A Comprehensive Review. **IEEE Access**. vol. 8, p. 29857 – 29881, 2020.

## APÊNDICE A – SELEÇÃO DA CONFIGURAÇÃO DAS CAMADAS INTERMEDIÁRIAS APLICADAS NAS REDES NEURAIS ARTIFICIAS

Uma rede neural artificial do tipo MLP pode apresentar inúmeras configurações combinadas, podendo variar o número de neurônios de camadas intermediárias, o número de neurônios por camada e sua função de ativação. Neste trabalho, foi realizada uma análise combinando diferentes números de camadas intermediárias e neurônios, onde o número de camadas foi variado de 1 a 10 camadas e o número de neurônios por camada foi variado de 1 a 10, totalizando 100 redes neurais treinadas com 2401 amostras. O desempenho das redes foi avaliado considerando o erro relativo médio da força resultante ( $ERMF_R$ ) apresentada na seção 3.6.4 aplicando o banco de teste gerado aleatoriamente com 10000 amostras pelo método de volumes finitos.

Além do número de camadas intermediárias e o número de neurônios por camada, foram testadas três funções de ativação dos neurônios sendo elas, a tangente hiperbólica, função logística e a unidade linear retificada (ReLU, do inglês *Rectified Linear Unit*). A Tabela 1 apresenta o  $ERMF_R$  obtido com as diferentes configurações das redes neurais artificiais com a tangente hiperbólica aplicada como função de ativação dos neurônios.

Tabela 1:  $ERMF_R$  obtido com diferentes configurações de número de camadas e número de neurônios por camada com a função de ativação tangente hiperbólica.

		<i>Número de camadas intermediárias</i>									
		1	2	3	4	5	6	7	8	9	10
<i>Neurônios por camada</i>	1	281,66	235,96	231,00	228,76	229,42	230,81	226,72	225,59	233,10	233,33
	2	144,65	134,40	240,32	708,04	116,58	191,70	763,18	196,27	196,15	96,11
	3	138,85	71,42	72,77	77,85	158,29	132,27	68,15	84,02	245,89	466,52
	4	89,80	49,56	55,64	61,09	163,67	50,28	114,88	97,31	91,60	139,12
	5	91,98	45,70	39,08	25,38	12,38	14,45	31,38	21,83	191,65	35,38
	6	69,08	26,14	9,51	6,72	6,94	7,14	5,72	4,39	158,34	97,74
	7	59,83	18,93	20,72	7,97	8,64	5,66	6,27	4,26	5,69	6,83
	8	140,00	11,49	14,80	4,52	5,28	10,93	8,20	5,09	6,10	5,16
	9	96,24	17,49	8,39	5,50	5,00	3,09	3,86	2,94	2,64	64,11
	10	102,10	8,67	8,67	5,34	3,31	2,67	3,31	4,01	6,90	2,59

A Tabela 2 e a Tabela 3 apresentam o  $ERMF_R$  obtido com as diferentes configurações das redes neurais artificiais com a função logística e ReLU aplicadas como função de ativação dos neurônios, respectivamente.

Tabela 2:  $ERMF_R$  obtido com diferentes configurações de número de camadas e número de neurônios por camada com a função de ativação função logística.

		Número de camadas intermediárias									
		1	2	3	4	5	6	7	8	9	10
Neurônios por camada	1	751,42	752,29	752,06	751,90	751,83	752,41	751,81	751,98	751,68	751,99
	2	244,62	258,78	230,91	228,43	223,37	224,75	256,01	240,23	751,90	760,52
	3	128,30	160,56	112,69	125,78	95,15	135,42	154,10	129,68	751,45	838,18
	4	150,54	88,92	48,01	187,62	194,90	110,55	103,73	772,76	751,74	752,61
	5	101,42	86,78	57,24	48,82	67,45	152,58	759,16	147,70	113,52	842,20
	6	85,47	43,38	14,19	99,73	94,22	143,58	80,75	152,37	752,83	774,98
	7	90,59	45,12	53,16	41,44	145,35	119,61	133,32	818,98	751,38	753,79
	8	81,49	10,91	14,29	34,30	122,52	103,28	174,79	752,76	752,56	856,56
	9	66,69	28,06	23,77	12,66	119,44	115,11	121,07	109,93	751,55	751,45
	10	55,78	10,61	9,01	5,85	83,17	157,84	131,32	759,60	150,32	756,91

Tabela 3:  $ERMF_R$  obtido com diferentes configurações de número de camadas e número de neurônios por camada com a função de ativação ReLU.

		Número de camadas intermediárias									
		1	2	3	4	5	6	7	8	9	10
Neurônios por camada	1	294,80	463,20	294,04	285,06	752,73	752,49	751,45	752,09	751,43	752,20
	2	338,56	239,68	222,13	752,37	293,85	287,70	790,34	751,45	752,00	751,45
	3	154,96	207,06	131,08	751,44	112,10	157,99	98,67	751,45	228,29	751,83
	4	198,02	118,06	106,10	72,15	70,95	116,77	751,45	220,05	664,57	751,45
	5	110,86	88,08	106,43	99,35	87,56	152,28	146,40	92,25	97,85	751,45
	6	139,02	56,03	50,57	45,43	49,48	60,09	220,47	124,68	183,55	55,77
	7	115,90	99,13	36,77	138,96	51,21	36,52	147,97	104,30	61,56	57,93
	8	132,08	59,95	46,48	52,39	38,01	36,70	35,53	42,79	52,33	68,75
	9	73,79	45,52	41,67	37,41	80,60	39,59	60,74	37,13	57,08	47,64
	10	57,81	53,93	34,07	37,93	38,72	44,87	49,34	52,65	33,61	71,34

A Tabela 4 apresenta o menor  $ERMF_R$  obtido com as diferentes configurações de camadas intermediárias e neurônios por camada para cada função de ativação aplicada.

Tabela 4: Menor  $ERMF_R$  obtido com diferentes configurações funções de ativação dos neurônios.

<i><b>Função de ativação</b></i>	<i><b><math>ERMF_R</math> [%]</b></i>
<i>Tangente Hiperbólica</i>	2,59
<i>Função Logística</i>	5,85
<i>ReLU</i>	33,61

Ao observar a Tabela 4, é possível concluir que a rede neural artificial que apresentou o menor  $ERMF_R$  dentre todas as configurações de redes testadas foi a rede com 10 camadas intermediárias, 10 neurônios por camada com função de ativação tangente hiperbólica. Portanto, essa configuração será aplicada nos modelos substitutos via redes neurais artificiais.